

**RICARDO STEGH CAMATI**

**Reconhecimento Automático de Personalidade a partir de textos: uma abordagem baseada em técnicas projetivas.**

Tese de Doutorado apresentado ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná, como requisito para obtenção do título de Doutor em Informática.

Área de Concentração: Ciência da Computação.

Orientador: Prof. Dr. Fabrício Enembreck

**Curitiba**

**2021**

## **DEDICATÓRIA**

Dedico esta tese aos meus amados pais, Rocha Vitor Camati e Anna Stegh Camati.

## AGRADECIMENTOS

Agradeço em primeiro lugar a Deus por me dar saúde e permitir que eu pudesse realizar este trabalho. Agradeço ao prof. Dr. Fabrício Enembreck pela segura orientação, por ter sido amigo, compreensivo, paciente, sempre acreditando neste trabalho. Agradeço ao prof. Dr. João Carlos Alchieri, por ter supervisionado a quotação dos protocolos do Z-teste, participando ativamente desta pesquisa. Agradeço ao prof. Dr. Alessandro Scaduto, por ceder o *corpus* TAT, coletado em sua tese de Doutorado, para esta pesquisa, e também por ter aceitado o convite para de ser co-autor de um artigo publicado relacionado a esta tese. Agradeço aos meus queridos pais, Rocha Vitor Camati e Anna Stegh Camati, por terem me dado a vida, me amado incondicionalmente, sempre me apoiando de todas as formas possíveis, me encorajando para que eu nunca desistisse dos meus sonhos; vocês são meus melhores amigos, a maior preciosidade da minha vida. Agradeço a meus avós maternos, Martin Stegh e Maria Stegh (*in memoriam*), principalmente a minha vó que foi para mim uma segunda mãe. Agradeço a minha amada esposa, Denalzira Mariano, por estar sempre ao meu lado, acreditando e mim, me apoiando, sendo uma amiga e companheira inseparável; sem você eu nunca teria conseguido. Agradeço a minha irmã, Simone Stegh Camati, pelo amor e apoio. Agradeço a minha enteada, Gabrielle Cristine Mariano da Mota, pela importante ajuda no processo de organização dos protocolos. Agradeço aos professores e coordenadores do ensino superior dos cursos nos quais o protocolo do Z-teste foi aplicado. Agradeço às instituições PUCPR e CAPES pela concessão da bolsa de estudos que me propiciou auxílio financeiro. Agradeço ao prof. Dr. Alcides Calsavara, que foi meu orientador de mestrado; sua ajuda foi fundamental para a obtenção do título de Mestre, que possibilitou o meu ingresso no Doutorado. Finalmente agradeço aos professores do PPGIa, pela transmissão do conhecimento, através das aulas das disciplinas eletivas e de tronco comum; me sinto muito honrado em ter sido aluno de vocês!

## EPÍGRAFE

*“Nenhum ser humano é capaz de esconder um segredo.  
Se a boca se cala, falam os dedos.” (Sigmund Freud)*

## RESUMO

*A personalidade diz respeito a padrões de pensamentos, emoções e comportamentos relativamente estáveis de um indivíduo (Newman, 2016). Os trabalhos da Computação da Personalidade mostram que é possível reconhecer a personalidade automaticamente a partir de textos (TB-APR), utilizando os paradigmas da aprendizagem supervisionada. Nestes paradigmas, os textos precisam ser rotulados por um instrumento psicométrico e, sendo assim, inventários de personalidade são utilizados. Estes inventários de personalidade são questionários construídos a partir de teorias psicológicas disposicionais. Os resultados encontrados na literatura referente aos modelos de TB-APR possuem correlações baixas. Este trabalho propõe a construção de um novo modelo de TB-APR, utilizando técnicas projetivas para rotular os textos. As técnicas projetivas permitem que os modelos de TB-APR explorem diversas dimensões da personalidade que não são mensuradas pelos inventários. Adicionalmente, as técnicas projetivas não possuem a mesma vulnerabilidade que os inventários de personalidade. Neste sentido, a transparência dos itens dos inventários permitem a omissão de características indesejadas ou a falsificação das respostas. Por outro lado, as técnicas projetivas utilizam estímulos desestruturados para capturar pistas da personalidade através do mecanismo de projeção, ocultando do examinando o processo de investigação da personalidade. Neste trabalho, construímos dois corpora, específicos para TB-APR utilizando técnicas projetivas. Submetemos estes corpora aos indutores do estado da arte de ML, obtendo resultados promissores, com uma AUC-ROC média de 83% em 25 dimensões de personalidade. Finalmente, espera-se que os modelos inéditos nesta tese desenvolvidos permitam a criação de uma nova gama de sistemas computacionais, identificando a personalidade de forma mais eficiente.*

**Palavras-chave:** *Computação da Personalidade, Reconhecimento Automático da Personalidade, Inventários de Personalidade, Testes Projetivos, Técnicas Projetivas, Teorias da Personalidade, Machine Learning.*

## ABSTRACT

*Personality relates to an individual's relatively stable patterns of thinking, emotion and behavior (Newman, 2016). The research on Personality Computing shows that it is possible to recognize personality automatically from texts (TB-APR), using paradigms of supervised learning. As concerns these paradigms, texts need to be labeled by psychometric instruments and, in order to realize this task, personality inventories are used. These personality inventories are questionnaires constructed from dispositional psychological theories. Personality inventories display great facilities as concerns application and correction, but they do not evince efficient ways of controlling intentional or non-conscious omissions of undesired personality characteristics by the individual, which may explain the low correlations found in literature regarding TB-APR models. This work proposes the construction of a new model of TB-APR, using a projective test designed by psychodynamic theories to label texts. The projective tests will allow the TB-APR models to explore the various dimensions of personality not measured by existent inventories. Additionally, projective tests do not have the same vulnerability of inventories as regards the omission of unwanted characteristics. In this work, we build two textual corpora using projective techniques. We submit these corpora to ML state-of-the-art inducers, obtaining promising results, with an average AUC-ROC of 83% in 25 personality dimensions. Finally, it is expected that the unpublished models developed in this thesis allow the creation of a new range of computer systems, indentifying personality more efficiently,*

**Keywords:** Personality Computing, Automatic Personality Recognition, Personality Inventories, Projective Techniques, Personality Theories, Machine Learning.

# SUMÁRIO

LISTA DE FIGURAS / LISTA DE TABELAS	11
<b>Lista de abreviações</b>	<b>13</b>
<b>1. Introdução</b>	<b>16</b>
1.1 Contexto histórico	16
1.2 A computação da personalidade	17
1.3 Delimitação do problema	21
1.4 Objetivos	26
1.5 Hipóteses	27
1.6 Motivação	28
1.7 Estrutura desta tese	32
<b>2 Teorias da personalidade</b>	<b>33</b>
2.1 Teorias psicodinâmicas	35
2.1.1 Freud e a teoria psicanalítica	35
2.1.2 Alfred Adler e a Psicologia Individual	47
2.1.3 Jung e a Psicologia Analítica	48
2.1.4 Klein e a Teoria das Relações Objetais	49
2.1.5 Horney e a Teoria Social Psicanalítica	51
2.1.6 Fromm e a Psicanálise Humanista	53
2.1.7 Eickson e a Teoria Pós-Freudiana	54
2.2 Teorias Humanistas Existenciais	55
2.2.1 Maslow e a Teoria Holístico-Dinâmica	55
2.2.2 Rogers e a Teoria Centrada na Pessoa	56
2.2.3 May e a Psicologia Existencial	56
2.3 Teorias Disposicionais	57
2.3.1 Allport e a Psicologia do Indivíduo	57
2.3.2 McRae e Costa e a Teoria dos Cinco Fatores	58
2.4 Teorias Biológicas Evolucionistas	58
2.4.1 Eyesenck e a Teoria dos Fatores de Base Biológica	59
2.4.2 Buss e a Teoria Evolucionista de Personalidade	59
2.5 Teorias Cognitivistas e da Aprendizagem	60
2.5.1 Skinner e a Análise do Comportamento	60
2.5.2 Bandura e a Teoria Social Cognitiva	61
2.5.3 Rotter e Mischel e a Teoria da Aprendizagem Social Cognitiva	62
2.5.4 Kelly e a Teoria dos Constructos Pessoais	63
2.6 Desordens de Personalidade	64
2.7 Conclusão	69
<b>3 Instrumentos psicométricos de Aferição da Personalidade</b>	<b>70</b>
3.1 Inventários de Personalidade	70
3.1.1 O modelo Big Five	72
3.1.2 Myer Briggs Type indicator	75
3.1.3 Egograms	77
3.1.4 <i>Dark Triad</i>	78
3.1.5 Inventários de Transtornos da Personalidade	79

3.1.5	<i>Justice-Vengeance Scale (JVS)</i>	81
3.1.6	<i>Trait-Forgiveness Scale (TFS)</i>	82
3.1.7	<i>Interpersonal Reactivity Index (IRI)</i>	82
3.1.8.	<i>The hypersensitive Narcissism Scale (HSNS)</i>	83
3.1.9.	<i>Grandiose Narcissism</i>	83
<b>3.2</b>	<b>Técnicas Projetivas</b>	<b>83</b>
3.2.1	O Teste Desiderativo	84
3.2.2	O Z-Teste	86
3.2.3	O Teste de Apercepção Temática	87
<b>3.3</b>	<b>Conclusão</b>	<b>87</b>
<b>4</b>	<b>Técnicas de Extração de Características para TB-APR</b>	<b>88</b>
<b>4.1</b>	<b>Técnicas de Pré-Processamento</b>	<b>88</b>
<b>4.2</b>	<b>Técnicas Top-Down</b>	<b>89</b>
4.2.1	Léxicos Psicolinguísticos.	90
4.2.2	Léxicos Afetivos	92
4.2.3	Léxicos Semânticos	94
4.2.4	Léxicos Semânticos Afetivos	95
<b>4.3</b>	<b>Técnicas bottom-down</b>	<b>95</b>
4.3.1	Técnicas a nível de caracteres.	96
4.3.2	Técnicas a nível de palavras.	97
4.3.3	Técnicas a nível sintático.	98
4.3.4	Técnicas de estilometria.	98
<b>4.4</b>	<b>Técnicas Híbridas</b>	<b>99</b>
<b>4.5</b>	<b>Conclusão</b>	<b>100</b>
<b>5</b>	<b>Aprendizagem de Máquina Supervisionada para TB-APR</b>	<b>101</b>
<b>5.1</b>	<b>Amostragem de dados</b>	<b>101</b>
<b>5.2</b>	<b>Paradigmas de aprendizagem de máquina supervisionada para TB-APR</b>	<b>103</b>
5.2.1	Paradigma de classificação binária	104
5.2.2	Paradigma de classificação multi-classe	104
5.2.3	Paradigma de classificação multi-label	105
5.2.4	Paradigma de regressão	106
5.2.5	Paradigma de regressão multi-target	106
5.2.6	Paradigma de ranqueamento	107
5.2.7	Paradigma estruturado	107
5.2.8	Paradigma de distribuição de labels	109
<b>5.3</b>	<b>Conclusão</b>	<b>110</b>
<b>6</b>	<b>Fundações de TB-APR</b>	<b>111</b>
<b>6.1</b>	<b>Discussão geral sobre os trabalhos.</b>	<b>112</b>
<b>6.2</b>	<b>Tabela cronológica de artigos.</b>	<b>138</b>
<b>6.3</b>	<b>Conclusão</b>	<b>143</b>
<b>7.</b>	<b>Metodologia</b>	<b>144</b>
<b>7.1</b>	<b>O corpus do Z-teste, Coleta dos Scores de Personalidade.</b>	<b>146</b>
7.1.1	A Aplicação Coletiva do Z-teste.	147
7.1.2	A Correção do Z-teste.	152
7.1.3	O <i>Feedback</i> aos Participantes do Corpus Z-teste.	161
7.1.4	As Dimensões de Personalidade e a Interpretação do Z-teste.	162



7.1.4.1 Respostas ( $\Sigma R$ ): Capacidade de Desempenho e de Adaptação Geral.	163
7.1.4.2 Forma Pura ( $\Sigma F$ ): Controle Geral (dimensão racional), expressão lógica do processo perceptivo.	164
7.1.4.3 Forma e Precisão formal (F+): Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva.	165
7.1.4.4 Movimento Humano ( $\Sigma M$ ): Espontaneidade, criatividade, empatia.	166
7.1.4.5 Movimento Animal (FM): Impulsividade e dinamismo.	167
7.1.4.6 Relacionamento interpessoal (FC) e a tendência a excitabilidade emocional ((CF) + (C)).	168
7.1.4.7 Ansiedade com adaptação afetiva (FK) e ansiedade com precário controle ((K)+(KF)).	169
7.1.4.8 Cor Acromática (FC'), (C'F), (C'): Traços depressivos da personalidade.	170
7.1.4.9. Textura (Fc), (cF), (c): Contato humano e interação social.	171
7.1.4.10. Cor pura (C): Tendência à Reação Emocional Intensa.	173
7.1.4.11. Conteúdos Humanos ((H) + (Hd)): As pessoas na percepção do examinando.	174
7.1.4.12. Conteúdo Animal ((A) + (AD)): Percepções infantis, também presentes no mundo interno do adulto.	174
7.1.4.13. Globais (G): Percepção de conjunto e capacidade de síntese.	175
7.1.4.14. Detalhes Comuns (D): Discernimento e Senso de Objetividade.	176
7.1.4.15. Detalhes Incomuns (Dd): Capacidade de análise e senso de observação.	177
7.1.4.16. Espaço branco ( $\Sigma S$ ): Ansiedade Situacional.	178
7.1.4.17. Movimento Inanimado ((Fm), (mF), (m)): Conflito Intrapsíquico.	178
7.1.4.18. Sombreado Radiológico ((Fk), (kF), (k)): Ansiedade e Adaptação Racional.	179
7.1.4.19. Ressonância Interna (( $\Sigma M$ ) : ( $\Sigma C$ )).	180
7.1.5 Coleta Textual para o <i>Corpus</i> do Z-teste.	184
<b>7.2 O corpus TAT.</b>	<b>186</b>
7.2.1 Coleta dos Scores de Personalidade e dos Ensaios Textuais do TAT.	187
7.2.2 Detalhamento das Dimensões selecionadas para o modelo do TAT.	191
<b>7.3 Modelos de TB-APR</b>	<b>195</b>
<b>7.3 Considerações finais</b>	<b>195</b>
<b>8 Detalhamento dos Modelos de TB-APR e Experimentos.</b>	<b>197</b>
<b>8.1 Pré-Processamento</b>	<b>197</b>
<b>8.2 Extração de Características</b>	<b>199</b>
<b>8.3. Aprendizagem de Máquina.</b>	<b>200</b>
<b>8.4. Seleção de Características.</b>	<b>204</b>
<b>8.5 Métricas de Avaliação de Desempenho</b>	<b>206</b>
<b>8.6 Experimentos com o corpus z-teste.</b>	<b>209</b>
8.6.1 Respostas ( $\Sigma R$ ): Capacidade de Desempenho e de Adaptação Geral.	210
8.6.2 Forma Pura ( $\Sigma F$ ): Controle Geral (dimensão racional), Expressão Lógica do Processo Perceptivo.	210
8.6.3 Forma e Precisão formal (F+): Funcionamento do Pensamento Lógico, Capacidade para Estabelecer Diferenciação Perceptiva.	211
8.6.4 Movimento Humano ( $\Sigma M$ ): Espontaneidade, Criatividade e Empatia.	212
8.6.5 Movimento Animal (FM): Impulsividade e Dinamismo.	213
8.6.6 Relacionamento interpessoal (FC) e a tendência a excitabilidade emocional ((CF) + (C)).	214
8.6.7 Ansiedade com adaptação afetiva (FK) e ansiedade com precário controle ((K)+(KF)).	215
8.6.8 Cor Acromática (FC'), (C'F), (C'): Traços depressivos da personalidade.	216
8.6.9. Textura (Fc), (cF), (c): Contato humano e interação social.	217
8.6.10. Cor pura (C): Tendência à Reação Emocional Intensa.	218
8.6.11 Conteúdos Humanos ((H) + (Hd)): As pessoas na percepção do examinando.	219
8.6.12. Conteúdo Animal ((A) + (AD)): Percepções infantis, também presentes no mundo interno do adulto.	220
8.6.13. Globais (G): Percepção de conjunto e capacidade de síntese.	221
8.6.14. Detalhes Comuns (D): Discernimento e Senso de Objetividade.	222
8.6.15. Detalhes Incomuns (Dd): Capacidade de análise e senso de observação.	223
8.6.16. Espaço branco ( $\Sigma S$ ): Ansiedade Situacional.	224

8.6.17. Movimento Inanimado ((Fm), (mF), (m)): Conflito Intrapésico.	225
8.6.18. Sombreado Radiológico ((Fk), (kF), (k)): Ansiedade e Adaptação Racional.	226
8.6.19. Ressonância Interna (( $\Sigma$ M) : ( $\Sigma$ C)).	227
8.6.20. Discussão dos Resultados dos experimentos com o <i>corpus</i> Z-teste.	228
<b>8.7 Experimentos com o Corpus TAT.</b>	<b>232</b>
8.7.1 Autonomia Para a Tarefa	233
8.7.2 Atendimento às Instruções	234
8.7.3 Complexidade do Herói	235
8.7.4 Complexidade Temporal	236
8.7.5 Pressão do Ambiente	238
8.7.6 Qualidade Geral da História	239
8.7.7 Discussão dos experimentos com o corpus TAT.	240
<b>8.8. Discussão Geral de todos os Experimentos.</b>	<b>242</b>
<b>9 Conclusão geral</b>	<b>244</b>
9.1 Trabalhos Futuros	248
<b>Anexo 1. Experimentos preliminares</b>	<b>251</b>
<b>Anexo 1.1 O corpus do facebook-BR [Paim, 2016]</b>	<b>251</b>
<b>Anexo 1.2 Extração de características</b>	<b>252</b>
Anexo 1.2.1 Pré-processamento	252
Anexo 1.2.2 Aplicação do TF-IDF	253
Anexo 1.2.3 Aplicação do léxico LIWC	253
Anexo 1.2.4 Fórmula de aplicação dos léxicos afetivos	254
Anexo 1.2.5 Aplicação do léxico afetivo SentiStrenght	254
Anexo 1.2.6 Aplicação do léxico afetivo AnewBR	255
Anexo 1.2.7 Aplicação do léxico afetivo SentiLexPT	256
Anexo 1.2.8 Aplicação do léxico afetivo OpLexicon	256
Anexo 1.2.9 Merge de todos espaços de características	256
<b>Anexo 1.3 Aprendizagem de máquina</b>	<b>257</b>
Anexo 1.3.1 Medida de avaliação de performance.	257
Anexo 1.3.2 Métodos de transformação do problema (MULAN)	258
Anexo 1.3.3 Indutor Multi-target genético	260
<b>Anexo 1.4 Resultados obtidos</b>	<b>261</b>
Anexo 1.4.1 Facetas de Openess to Experience (O)	262
Anexo 1.4.2 Facetas de Conscientiousness (C)	263
Anexo 1.4.3 Facetas de Extraversion (E)	265
Anexo 1.4.4 Facetas de Agreebleness (A)	266
Anexo 1.4.5 Facetas de Neuroticism (N)	268
<b>Anexo 1.5 Análise dos resultados preliminares</b>	<b>270</b>
<b>BIBLIOGRAFIA</b>	<b>273</b>

## LISTA DE FIGURAS / LISTA DE TABELAS

Figura 1. Tarefas da computação da personalidade. Adaptado de [Vinciarelli & Mohammadi, 2014].	19
Figura 2. As diferenças das tarefas de APR e APP no rotulamento de indivíduos para corpus de TB-APR.	20
Figura 3. Sub-componentes de um corpus de TB-APR.	22
Figura 4. Extração e seleção de características nos modelos de TB-APR.	23
Figura 5. Paradigmas de ML para TB-APR.	24
Figura 6. Fluxograma da construção de Teorias da personalidade.	34
Figura 7. Fluxograma da primeira tópica freudiana.	36
Figura 8. Fluxograma da segunda tópica Freudiana.	38
Figura 9. A personalidade de acordo com a segunda tópica Freudiana.	41
Figura 10. Diferenças entre afetos, sensações, emotions, sentimentos e opiniões, adaptado de [Manuzero et.al., 2014].	92
Figura 11. Pos-tags (marcação de classe gramatical): Coarse Grain (alto nível) & Fine Grain (baixo nível). Adaptado de [Horsmann & Torsen, 2016].	98
Figura 12. Modelo Hidden Markov Model (HMM) adaptado de [Lacoste - Julien, 2007].	108
Figura 13. Indutores estruturados adaptado de [Lacoste-Julien, 2007].	109
Figura 14. Redução da dimensionalidade adaptado de [Park et al., 2015].	130
Figura 15. Aplicação coletiva do Z-teste.	151
Figura 16. Fluxograma de correção do Z-teste.	160
Figura 17. Metodologia utilizada para calcular as classes para as 19 dimensões do Z-teste.	163
Figura 18. Fluxograma de pré-processamento do corpus Z-teste.	198
Figura 19. Fluxograma de pré-processamento do corpus TAT.	198
Figura 20. Fluxograma de extração de características textuais.	199
Figura 21. Fluxograma do pipeline de aprendizagem de máquina.	201
Figura 22. Fluxograma do Indutor Multi-target Genético.	261
Figura 23. Rankeamento dos indutores para Openess to Experience [api R, 2018].	263
Figura 24. Rankeamento dos indutores para Conscientiousness [api R, 2018].	264
Figura 25. Rankeamento dos indutores para Extraversion [api R, 2018].	266
Figura 26. Rankeamento dos indutores para Agreeableness [api R, 2018].	268
Figura 27. Rankeamento dos indutores para Neuroticism [api R, 2018].	269

<i>Tabela 1. Os mecanismos mentais relacionados a segunda tópica freudiana [Freud, 1915].</i>	39
<i>Tabela 2. As Fases fálicas masculina e feminina [Feist &amp; Feist; Roberts, 2015, p. 31].</i>	46
<i>Tabela 3. Os tipos de personalidade da teoria psicanalítica.</i>	46
<i>Tabela 4. Inventários BigFive, adaptado de [Paim, 2016].</i>	75
<i>Tabela 5. Classificação de indutores multi-target, adaptado de [Bocharni et. al., 2015].</i>	106
<i>Tabela 6. Correlações entre os fatores LIWC e os testes TAT e PRF [Pennebaker &amp; king, 1999].</i>	116
<i>Tabela 7. LBA x Self reports BigFive (correlação) adaptado de [Park et. al., 2015].</i>	132
<i>Tabela 8. Validade discriminante (correlação) dos traços de personalidade do BigFive e também</i>	133
<i>Tabela 9. F1 score para os traços do BigFive utilizando diferentes corpus [Santos et al., 2017].</i>	135
<i>Tabela 10. Estado da arte de acurácia [Vu et al., 2017]. Acurácia para dataset essays – 2400 users [Majumder et al, 2017]. Acurácia para o dataset MyPersonality – 250 users [Vu et al., 2017].</i>	137
<i>Tabela 11. Tabela cronológica de trabalhos em TB-APR.</i>	142
<i>Tabela 12. Folha de administração do Z-teste. Adaptado de [Vaz &amp; Alchieri, 2016, p. 33].</i>	148
<i>Tabela 13. Tabela de cálculo do tipo de ressonância interna. Adaptado de [Vaz &amp; Alchieri, 2016, p. 108].</i>	182
<i>Tabela 14. Desbalanceamento de classes e seleção das dimensões personaldiade para o corpus TAT.</i>	190
<i>Tabela 15. Categorias do sistema MS relacionadas ao Comportamento. Adaptado de [Scaduto,2016].</i>	191
<i>Tabela 16. Categorias do sistema MS relacionadas a Análise de Conteúdo. Adaptado de [Scaduto,2016].</i>	192
<i>Tabela 17. Categorias do sistema MS relacionadas a Análise de Conteúdo. Adaptado de [Scaduto,2016].</i>	194
<i>Tabela 18. Detalhes do corpus Z-teste.</i>	209
<i>Tabela 19. Capacidade de Desempenho e de Adaptação Geral.</i>	210
<i>Tabela 20. Controle Geral, Expressão Lógica do Processo Perceptivo.</i>	211
<i>Tabela 21. Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva.</i>	212
<i>Tabela 22. Espontaneidade, Criatividade e Empatia.</i>	213
<i>Tabela 23. Impulsividade e Dinamismo.</i>	214
<i>Tabela 24. Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional.</i>	215
<i>Tabela 25. Ansiedade com Adaptação Afetiva e Ansiedade com Precário Controle.</i>	216
<i>Tabela 26. Traços Depressivos da Personalidade.</i>	217
<i>Tabela 27. Contato humano e interação social.</i>	218
<i>Tabela 28. Tendência à Reação Emocional Intensa.</i>	219
<i>Tabela 29. As Pessoas na Percepção do Examinando.</i>	220
<i>Tabela 30. Percepções Infantis, Também Presentes no Mundo Interno do Adulto.</i>	221
<i>Tabela 31. Percepção de Conjunto e Capacidade de Síntese.</i>	222
<i>Tabela 32. Discernimento e Senso de Objetividade.</i>	223
<i>Tabela 33. Capacidade de Análise e Senso de Observação.</i>	224
<i>Tabela 34. Ansiedade Situacional.</i>	225
<i>Tabela 35. Conflito Intrapsíquico.</i>	226
<i>Tabela 36. Ansiedade e Adaptação Racional.</i>	227
<i>Tabela 37. Ressonância Interna.</i>	228
<i>Tabela 38. Modelos Z-teste (19 Dimensões de Personalidade). Ordenados por AUC-ROC.</i>	229
<i>Tabela 39. Modelos Z-teste com dimensões enviesadas pela amostra. Ordenados por AUC-ROC.</i>	230
<i>Tabela 40. Modelo Z-teste que possui 5 classes.</i>	231
<i>Tabela 41. Modelos Z-teste que não tiveram as dimensões enviesadas pela amostra. Ordenados por AUC-ROC.</i>	231
<i>Tabela 42. Detalhes do corpus TAT.</i>	232
<i>Tabela 43. Autonomia para a Tarefa.</i>	234
<i>Tabela 44. Atendimento às Instruções.</i>	235
<i>Tabela 45. Complexidade do Herói.</i>	236
<i>Tabela 46. Complexidade Temporal.</i>	237
<i>Tabela 47. Pressão do Ambiente.</i>	239
<i>Tabela 48. Qualidade Geral da História.</i>	240
<i>Tabela 49. Desbalanceamento de classes do corpus TAT.</i>	241
<i>Tabela 50. Experimentos do corpus TAT com dimensões de 3 classes.</i>	241
<i>Tabela 51. O corpus utilizado nos experimentos preliminares [Paim, 2016].</i>	251
<i>Tabela 52. RRMSE para as facetas de Openess to Experience.</i>	262
<i>Tabela 53. RRMSE para as facetas de Conscientiousness.</i>	264
<i>Tabela 54. RRMSE para as facetas de Extraversion.</i>	265
<i>Tabela 55. RRMSE para as facetas de Agreebleness [api R, 2018].</i>	267
<i>Tabela 56. RRMSE para as facetas de Neuroticism [api R, 2018].</i>	269

## Lista de abreviações

TB-APR	Text-based automatic personality recognition.
( $\Sigma$ C)	Somatório de cores em um protocolo.
( $\Sigma$ F)	Somatório de formas em um protocolo.
( $\Sigma$ M)	Somatório de movimento humano em um protocolo.
( $\Sigma$ R)	Somatório de respostas em um protocolo.
( $\Sigma$ S)	Somatório da utilização dos espaços em branco em um protocolo.
(A)	Conteúdo percebido como animal inteiro.
(AD)	Conteúdo percebido como detalhe de animal.
(C)	Conteúdo percebido como cor pura.
(c)	Conteúdo de percepção tátil.
(C')	Conteúdo percebido como acromático.
(C'F)	Conteúdo percebido com acromático, mas sem precisão formal.
(CF)	Conteúdo percebido com foco em cor, mas sem precisão formal.
(D)	Respostas de detalhes comuns.
(Dd)	Respostas de detalhes incomuns.
(dd)	Respostas de detalhes diminutos.
(de)	Respostas de detalhes externos.
(DO)	Respostas de detalhes inibitórios.
(dr)	Respostas de detalhes raros.
(F+)	Forma com precisão formal.
(FC)	Conteúdo percebido com foco em cor, com precisão formal.
(Fc)	Conteúdo de percepção tátil, com precisão formal.
(Fc)	Conteúdo de percepção tátil, sem precisão formal.
(FC')	Conteúdo percebido como acromático, com a forma precisa.
(FK)	Conteúdo percebido com sombreado, com a forma bem definida.
(Fk)	Conteúdo percebido como sombreado radiológico, com a forma bem definida.

(FM)	Movimento animal.
(Fm)	Conteúdo percebido com movimento inanimado, com a forma bem definida.
(G)	Resposta do tipo global.
(Gcort)	Resposta do tipo global cortada.
(H)	Conteúdo percebido como ser humano inteiro.
(Hd)	Conteúdo percebido como membros de seres humanos.
(K)	Conteúdo percebido com sombreado.
(k)	Conteúdo percebido com sombreado radiológico.
(KF)	Conteúdo percebido com sombreado, sem a precisão da forma.
(kF)	Conteúdo percebido com sombreado radiológico, sem a precisão da forma.
(m)	Movimento inanimado.
(M-)	Movimento humano descaracterizado.
(M+)	Movimento humano de boa qualidade.
(M±)	Movimento humano duvidoso.
(mF)	Conteúdo percebido com movimento inanimado, com forma imprecisa.
(S)	Utilização do espaço em branco.
APP	Automatic personality perception.
APR	Automatic personality recognition.
APS	Automatic personality synthesis.
aRRMSE	Average relative root mean squared error.
BMA	Bayesian model averaging.
CRF	Conditional random fields.
ERCC	Ensemble of regressor chains.
ERCC	Ensemble of regressor chains corrected.
GB	Gradient boost.
IBK	Instance based learner.
IG	Information gain.
IPIP	International item pool.
KMO	Kaiser-meyer-olkin.
kNN	k nearest neighbours.
LBA	Language based assessment.

LDA	Latent dirichlet allocation.
LIWC	Linguistic inquiry word count.
MAE	Mean average Error.
MBTI	Myers Briggs types indicator.
MI	Mutual Information.
ML	Machine Learning.
MORF	Multi-objective random forests.
MRF	Makov random fields.
MSE	Mean squared error.
MTS	Multi-target stacking.
MTSC	Multi-target stacking correted.
NB	Naive bayes.
PC	Personality computing.
PCA	Principal component analysis.
PF	Parwise label-features factors.
PMI	Pointwise mutual information.
PRF	Personality research form.
RF	Random forest.
RMSE	Root mean square error.
RRMSE	Relative root mean squared error
SFG	Systemic functional grammar.
SMO	Sequential minimal optimization.
SOC	Stream of consciousness.
SVM	Suport vector machines.
TAT	Teste de percepção temática.
TF-IDF	Term frequency - inverse term frequency.
Z-Teste	Teste de zulliger.
(O C E A N)	São abreviações utilizadas por padrão na literatura para as dimensões do BigFive: (O)penness to experience, (C)onscientiousness, (E)xtraversion, (N)euroticism, (A)greebleness.
(J F T I E N P S)	São abreviações utilizadas por padrão na literatura para as dimensões do MBTI: (J)udging, (F)eeling, (T)hinking, (I)ntroversion, (E)xtraversion, Intuitio(N), (P)erceiving, (S)ensing.

# 1. Introdução

Etimologicamente, a palavra personalidade deriva do latim – *persona* – que significa “máscara”, ou seja, referindo-se a como nos apresentamos a outros indivíduos na sociedade [Schultz & Schultz, 2003]. Este capítulo foi dividido em em 7 seções. A seção 1.1 apresenta um contexto histórico sobre a personalidade, a seção 1.2 contextualiza a computação da personalidade, a seção 1.3 delimita o problema abordado por esta tese, a seção 1.4 desceve os objetivos desta tese, a seção 1.5 formula hipóteses, a seção 1.6 descreve a motivação para este trabalho e a seção 1.7 sumariza o conteúdo dos capítulos desta tese.

## 1.1 Contexto histórico

O interesse pela personalidade humana remonta à antiguidade; na Grécia antiga, as preocupações sobre a origem e a essência da existência humana evoluíram para a filosofia que abrangeu o estudo de vários campos de conhecimento, incluindo a metafísica, a ética, os princípios morais, entre outros. Hipócrates (460 - c. 370 aC), um médico grego conhecido como o “pai das ciências médicas”, foi o primeiro a relacionar a personalidade aos estudos médicos, identificando quatro fluidos corporais distintos – sangue, bílis amarela, bílis negra e fleuma – os quais ele chamou de humores. Acreditava que o excesso ou a falta desses fluidos poderia afetar os traços e o comportamento da personalidade humana, causando distúrbios de diferentes tipos [Stelmark & Stalikas, 1991]. Teofrasto (c. 371 - c. 287 aC), um filósofo grego da escola peripatética, delineou trinta tipos morais diferentes, a primeira tentativa registrada de pensar sistematicamente sobre a personalidade [Theophrastus, 4BC]. Ficou surpreso ao detectar uma grande heterogeneidade de traços individuais entre os gregos que, apesar de viverem no mesmo ambiente e compartilharem a mesma educação, eram tão diferentes [Theophrastus, 4BC]. Galeno (129 - c. 200 dC), o mais proeminente médico grego à época, cirurgião e pesquisador-médico, formulou uma teoria da personalidade mais elaborada, identificando quatro temperamentos que ele associou à teoria dos humores de Hipócrates [Lahaye, 1992]:

- 1) Sanguíneo: otimista, ativo, sociável (sangue).
- 2) Colérico: mal-humorado e irritável (bile amarela).
- 3) Melancólico: analítico, sábio, tranquilo (bile negra).
- 4) Fleumático: descontraído e tranquilo (fleuma).



No entanto, as teorias da personalidade e da psicologia ganharam reconhecimento como ciência apenas no final do século XIX, impulsionadas pela psicanálise freudiana [Freud, 1901/1905]. Depois de Freud, durante o século XX, dezenas de diferentes teorias da personalidade foram concebidas, o que mostrou que a personalidade está intrinsecamente relacionada à percepção, razão, aprendizado, memória e tomada de decisão [Damasio, 1996], despertando o interesse de outros campos do conhecimento sobre a personalidade humana entre eles a comunidade da ciência da computação. Neuman (2016) expressa sua opinião sobre a personalidade como um psicólogo e cientista da computação: “A personalidade diz respeito a padrões de pensamentos, emoções e comportamentos relativamente estáveis de um indivíduo. É nossa maneira ingênua ou erudita de conceituar de maneira simples a “produção” visível de dimensões biológicas, cognitivas, emocionais, comportamentais e culturais complexas”.

Nos últimos anos, surgiu um campo da ciência da computação influenciada pela psicologia e pela computação afetiva [Pickard, 1995] chamada *computação da personalidade*; essa especialidade é dedicada exclusivamente a inferir ou sintetizar a personalidade automaticamente. Estudos nesta área demonstram que é possível inferir a personalidade automaticamente através de textos [Mairesse et. al., 2007], paralinguagem (ou seja, variações no tom e timbre da voz, pausas, suspiros, velocidade ou hesitação da fala), prosódia, linguagem corporal (i.e. movimentos corporais, proximidade de indivíduos, expressões faciais), dados extraídos de redes sociais, características de imagem e jogos de computador, caligrafia e preferência musical [Vinciarelli & Mohammadi, 2014].

Esta tese é um trabalho de pesquisa relacionado a uma especialidade da computação da personalidade, chamada de *text based automatic personality recognition* (TB-APR), que se propõe a reconhecer a personalidade à partir de textos de forma automática. A próximas duas seções detalham a computação da personalidade, com foco nos temas que esta tese vai explorar.

## **1.2 A computação da personalidade**

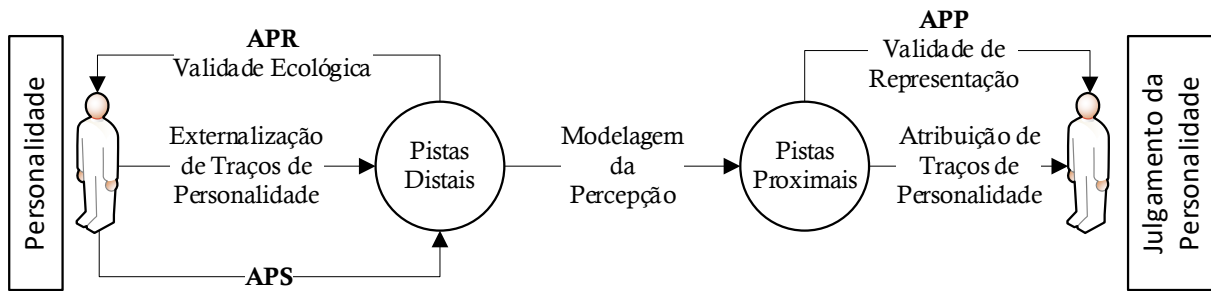
Podemos entender a *computação da personalidade* (PC) como uma especialização da *computação afetiva* (AC) [Piccard, 1995], uma área interdisciplinar que utiliza conhecimentos de inteligência artificial, da ciência cognitiva e da psicologia com o objetivo de elaborar técnicas computacionais para reconhecer, interpretar e simular afetos humanos.

Os autores Vinciarelli e Mohammadi sistematicamente realizaram estudos sobre as pesquisas no campo da computação de personalidade, a partir do surgimento dos primeiros trabalhos até a data

em que o artigo foi publicado no ano de 2014. Neste estudo, os autores propuseram uma taxonomia para as diferentes tarefas que a máquina deve executar automaticamente para computar a personalidade. O critério usado para distinguir essas tarefas foi uma adaptação do modelo cognitivo Brunswik Lens [Brunswik 1952, 1955a, 1966b] que detalha como os seres vivos capturam informações do ambiente. De acordo com este modelo a percepção humana é abstraída em uma metáfora que especifica a necessidade do uso de lentes para que os indivíduos consigam perceber os detalhes do meio ambiente complexo em que estão inseridos. Essas lentes possuem certa flexibilidade, permitindo a focalização de detalhes ambientais específicos. Brunswik (1952, p. 23) afirmava que os sistemas perceptuais humanos funcionam como “‘máquinas imperfeitas’, sendo as representações mentais também imperfeitas. O modelo Brunswik Lens possui os seguintes conceitos teóricos:

- 1) As lentes propostas são uma metáfora para os processos cognitivos da percepção que não são deterministas, mas probabilísticos.
- 2) As lentes são necessárias para lidar com o caos do meio ambiente, sem elas não é possível perceber nada. As lentes precisam ser flexíveis e abertas em relação à contradição e à ambiguidade, mediando múltiplas interpretações de pistas.
- 3) Não há redução de um único significado (material, concreto / ex: a representação de uma casa que eu conheço) para um único significante (imaterial, abstrato / ex: a palavra escrita, “casa”), caracterizando a imperfeição do sistema (podendo ser entendido com o erro) [Saussure, 1996].

Podemos imaginar que estas lentes teóricas funcionam de forma análoga a uma regressão linear, onde os termos referentes aos atributos podem ser entendidos como as pistas (significantes), os coeficientes de peso podem ser entendidos como a representação material da utilização das pistas (significados) e o erro pode ser entendido como a caracterização da imperfeição do processo. A partir desses pressupostos, os indivíduos externalizam a personalidade por meio de pistas distais, ou seja, produzem ações e/ou comportamentos que são observáveis e/ou mensuráveis por algum mecanismo de percepção. Um observador ao notar pistas no meio ambiente, utilizando seus órgãos sensoriais e sua cognição perceptiva, *transforma* as pistas distais em pistas proximais, como se as pistas distais passassem pelas lentes teóricas de Brunswik. A partir do modelo teórico das lentes, Vinciarelli e Mohammadi definiram três tarefas distintas para a computação da personalidade (Figura 1):

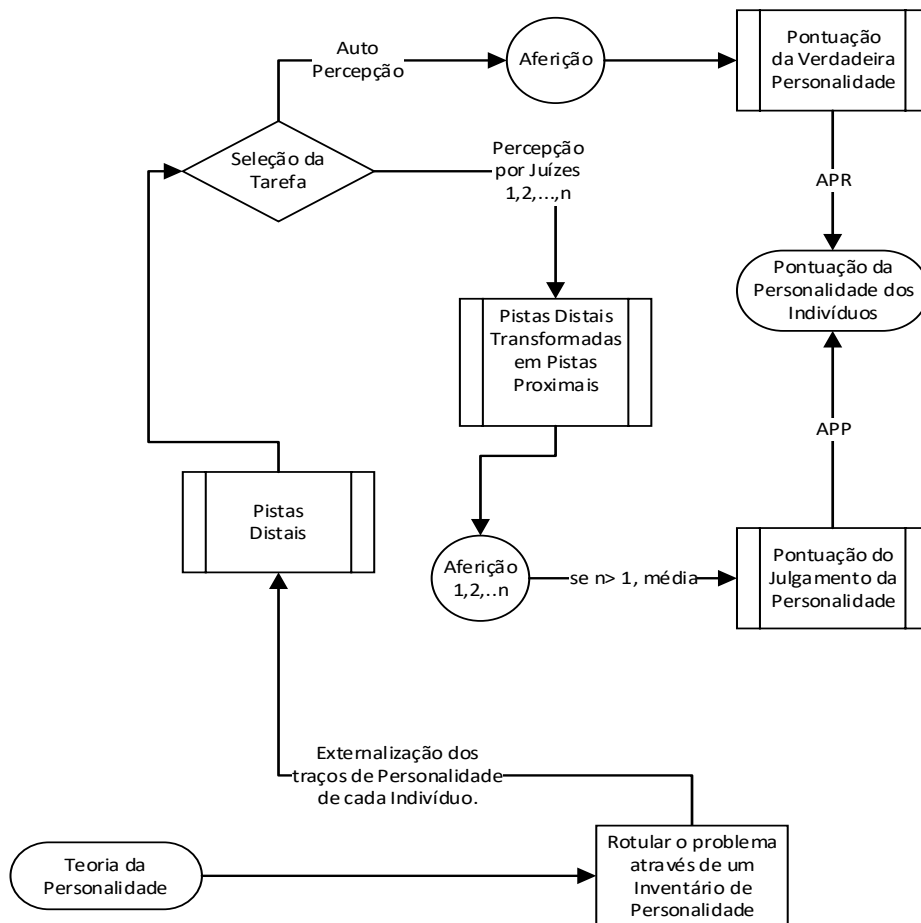


**Figura 1.** Tarefas da computação da personalidade. Adaptado de [Vinciarelli & Mohammadi, 2014].

Observando a Figura 1, notamos que a *validade ecológica* (VE) se refere a qualquer medida de correlação entre a personalidade e as pistas distais. A *validade de representação* (VR) se refere a qualquer medida de correlação entre as pistas distais e a percepção da personalidade por algum julgador. Sendo assim, existem três tarefas que pertencem à computação da personalidade:

- 1) A inferência de traços de personalidade a partir de *pistas distais* – Reconhecimento Automático da Personalidade/ *Automatic Personality Recognition* (APR).
- 2) A inferência de traços de personalidade a partir de *pistas proximas* – Percepção Automática de Personalidade/ *Automatic Personality Perception* (APP).
- 3) A geração de *pistas distais sintéticas* – Síntese Automática da Personalidade/ *Automatic Personality Synthesis* (APS).

A personalidade é um conceito multidimensional complexo que os seres humanos tentam abstrair em forma de teorias e medir com instrumentos psicométricos baseados nestas teorias. Se um instrumento psicométrico é aplicado diretamente no indivíduo que está tendo a personalidade investigada, pressupomos teoricamente que tal instrumento consiga capturar as *pistas distais*; sendo assim a tarefa computacional será a de APR. Caso o instrumento psicométrico não seja aplicado diretamente no indivíduo e sim em um julgador que de alguma forma percebe as *pistas proximas* de personalidade deixadas por este indivíduo, a tarefa computacional será de APP. O fluxograma da Figura 2 mostra em detalhes as diferenças das duas tarefas computacionais de reconhecimento de personalidade. Esta diferença está no método de como rotular os indivíduos.



**Figura 2.** As diferenças das tarefas de APR e APP no rotulamento de indivíduos para corpus de TB-APR.

Conforme podemos observar no fluxograma da Figura 2, para rotular um *corpus* concebido para as tarefas de APR e/ ou APP, se faz necessário utilizar um inventário de personalidade (um questionário sobre a personalidade, que espera respostas em uma escala *likert*). Os inventários de personalidade são instrumentos psicométricos construídos à partir de uma teoria de personalidade, por este motivo o fluxograma inicia em “Teoria da Personalidade”. Em relação as tarefas de APR e APP, o fluxograma deixa evidente que o processo de reconhecimento da personalidade por autopercepção de pistas distais é diferente do processo da percepção da personalidade de outros indivíduos, sendo que este último é realizado por um ou mais juízes observadores. Finalmente, como o objeto de estudo desta tese é a tarefa de APR, não comentaremos mais sobre julgadores de personalidade, que é um assunto relacionado à tarefa de APP.

A próxima seção irá expor em detalhes a delimitação do problema a ser explorado nesta tese.

### 1.3 Delimitação do problema

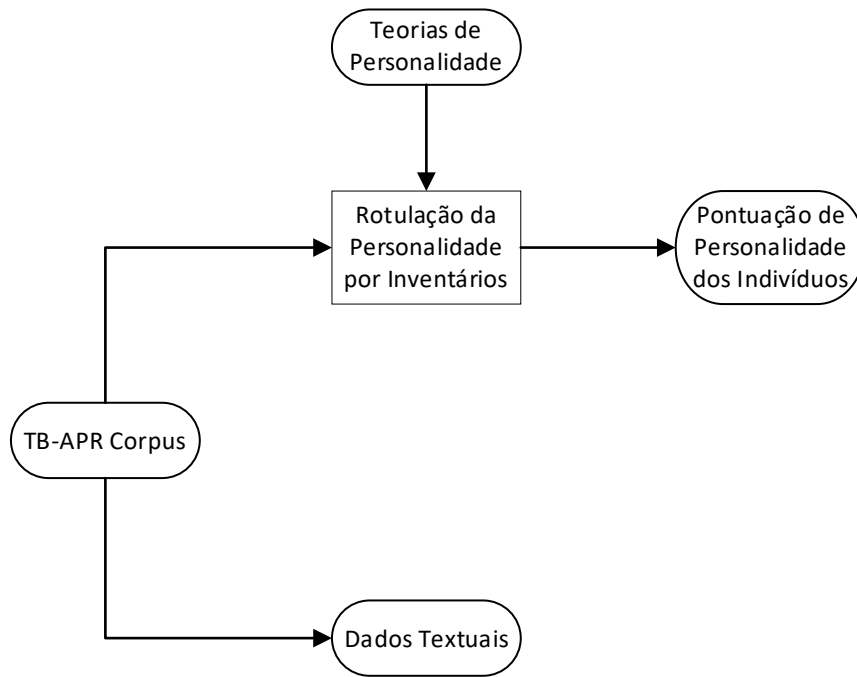
O objeto de estudo dessa tese é a tarefa de APR, especificamente uma especialidade da tarefa de APR em que o reconhecimento automático de personalidade é realizado através dos textos (TB-APR) dos indivíduos.

A tarefa de TB-APR parte do princípio da hipótese léxica [Crowne, 2007], incluindo diferenças de personalidade de indivíduos de uma cultura específica em termos de linguagem e, se estas diferenças estão na linguagem, também estão nos textos. Mairesse (2007) pontua os seguintes passos para esta tarefa computacional:

- 1) Coletar os textos dos indivíduos que fazem parte do *corpus*.
- 2) Coletar os *scores* de personalidade de cada participante.
- 3) Extrair as características textuais dos textos coletados.
- 4) Construir modelos estatísticos dos scores de personalidade a partir das características textuais.
- 5) Testar o modelo estatístico apreendido em textos de indivíduos que não participaram da construção dos modelos estatísticos.

Os passos definidos por Mairesse se referem à *aprendizagem de máquina supervisionada* (ML), uma especialidade da inteligência artificial que utiliza algoritmos que são chamados de indutores para a construção de modelos de previsão estatísticos. Em outras palavras, para a construção de um modelo de TB-APR se faz necessário utilizar um *corpus* específico para esta tarefa, que comporte o paradigma supervisionado de ML. A formalização do problema de TB-APR e a explicação destes paradigmas estão detalhados na seção 5.2.

Para construir um modelo de TB-APR, os indutores necessitam de um *corpus* textual (Figura 3), rotulado por um instrumento psicométrico de aferição da personalidade baseado em teorias psicológicas (geralmente um inventário de personalidade), produzindo uma escala n-dimensional, onde cada dimensão corresponde a um traço ou faceta da personalidade. No que diz respeito a construção do *corpus*, é essencial que o processo siga todas as prerrogativas éticas e legais, necessitando a permissão explícita dos indivíduos participantes. O fluxograma da Figura 3 mostra em detalhes, as duas partes essenciais de um corpus de TB-APR: (i) os textos dos indivíduos e (ii) a pontuação de personalidade dos indivíduos, onde esta última geralmente é obtida através de um inventário de personalidade baseado em alguma teoria psicológica.

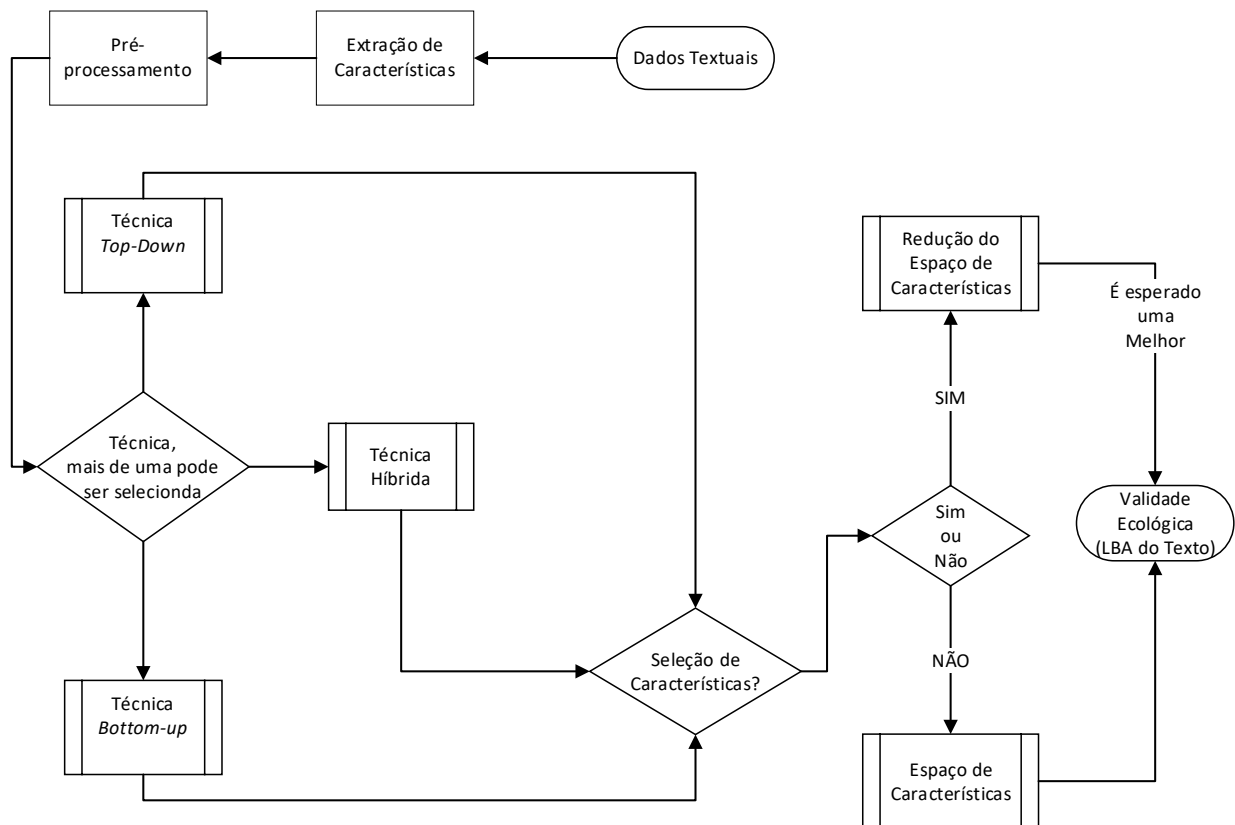


**Figura 3.** Sub-componentes de um corpus de TB-APR.

Em relação aos dados textuais, eles podem ser capturados de várias fontes de dados pré-existentes, podendo ser textos mais formais, como e-mails [Gill et. al., 2002] [Oberlander & Gill, 2004], ou textos informais, como postagens de redes sociais [Celli, 2016] ou transcrições de *vlogs* [Farnandi et. al., 2014]. Além disso, os textos podem ser elaborados no momento da coleta, através de tópicos textuais, que podem ser direcionados a um determinado assunto ou podem ser livres [Argamon et al, 2005] [Mairesse, 2007]. Neste sentido, os modelos de TB-APR pode ser contruídos a partir de um único tipo de texto ou a partir da combinação de textos diferentes. O impacto da diversidade textual em modelos de TB-APR foi explorado no trabalho de Santos e seus colegas em 2017, detalhado na seção 6.1 desta tese.

Após o processo de construção do *corpus*, os textos em sua forma bruta devem passar por um pré-processamento, eliminando todo conteúdo ruidoso ou considerado não relevante para a construção do modelo. Depois do texto ser pré-processado, técnicas de extração de características textuais são aplicadas, produzindo um espaço finito de características textuais para cada indivíduo. As técnicas *top-down* (seção 4.2) geram atributos baseados em categorias pré-especificadas por dicionários. As técnicas *bottom-up* (seção 4.2) utilizam contagens de letras, palavras ou sequências de palavras (*n-grams*) junto com métodos estatísticos. A literatura chama os atributos textuais de *language based assessment* (LBA) [Park et. al., 2015].

Muitas vezes, após o processo de extração de características textuais, são gerados centenas, milhares ou milhões de atributos textuais, produzindo um espaço de características muito grande, tornando os indutores ineficientes devido à “maldição da dimensionalidade”, sendo, nestes casos, necessário aplicar *técnicas de redução da dimensionalidade*. As etapas sequenciais de pré-processamento, extração de características e redução da dimensionalidade são demonstradas no fluxograma da figura 4.

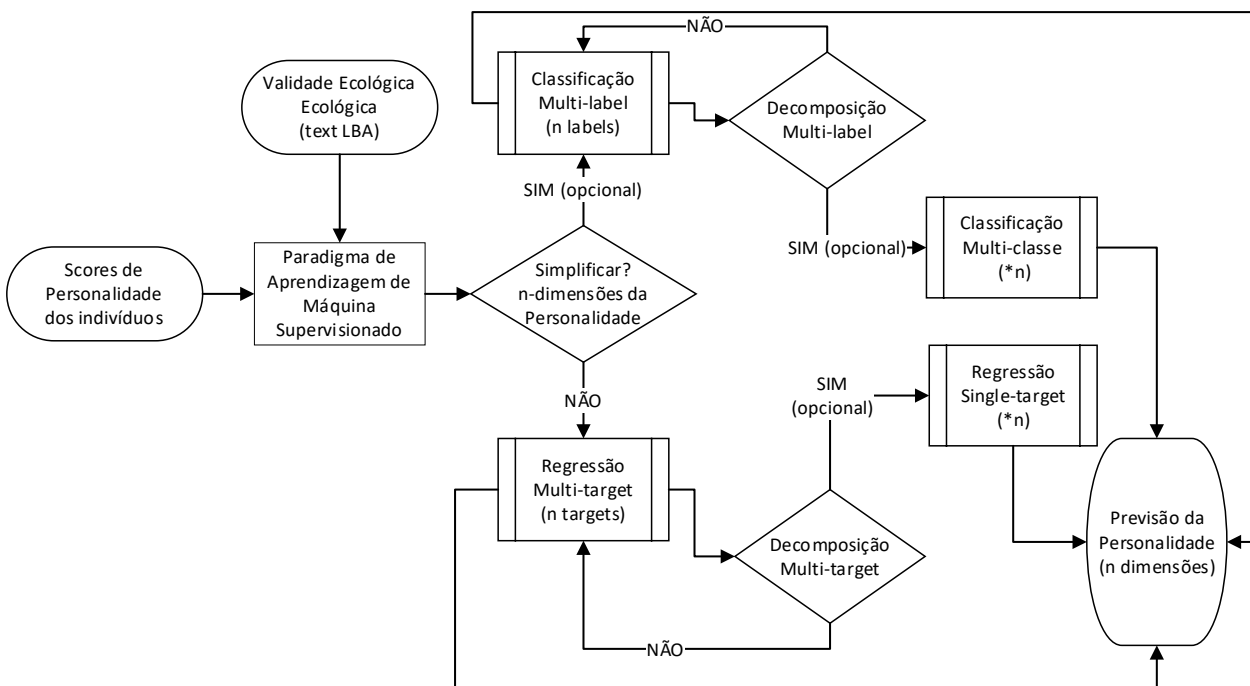


**Figura 4.** Extração e seleção de características nos modelos de TB-APR.

Finalmente após as etapas especificadas na Figura 4, o espaço de características é utilizado pelos indutores para construir os modelos de previsão da personalidade. Em seguida, os indutores testam o modelo construído; para isso o *corpus* é dividido em duas amostras, uma de treinamento e outra de teste. Este processo é chamado de técnica de amostragem (seção 5.1), no qual geralmente é utilizada a técnica de validação cruzada [Kohavi, 1995].

No que diz respeito aos paradigmas de ML (seção 5.2), a tarefa de TB-APR é tipicamente um problema de regressão multi-target, pois os atributos meta geralmente são valores numéricos n-

dimensionais oriundos da aplicação de um instrumento psicométrico. Geralmente o problema de regressão multi-target é simplificado e decomposto em n-problemas de classificação binária ou classificação multi-classe. Para decompor o problema, a técnica dos *z-scores* pode ser aplicada. Esta técnica consiste em tentar aproximar a distribuição de cada dimensão da personalidade a uma curva normal, utilizando os desvios padrões para converter o problema de regressão multi-target em n-problemas de classificação binária ou classificação multi-classe. A Figura 5 mostra alguns dos paradigmas de ML compatíveis com os modelos de TB-APR.



**Figura 5.** Paradigmas de ML para TB-APR.

Uma vez tendo detalhado o modelo de TB-APR, é dado o prosseguimento da delimitação do problema abordado por este estudo. Considerando a personalidade como um conjunto de características que determinam as diferenças individuais referentes a modos de pensar, sentir e agir, expressando tudo aquilo que é mais significativo em um indivíduo, é natural que os modelos de TB-APR sejam ferramentas importantes para a melhoria dos sistemas de recomendação, reputação, recrutamento, avaliação de itens e produto, autônomos, financeiros. Além disso, inúmeras outras aplicações podem se beneficiar no contexto da *world wide web*, principalmente no que se refere às redes sociais, consideradas um complexo ecossistema, no qual os mais variados tipos de personalidades se relacionam.



Apesar dos modelos de TB-APR possuírem um papel fundamental nestes sistemas, notamos que eles pouco têm contribuído para o aprimoramento dos mesmos [Granatyr, 2017], visto que as técnicas atuais de extração de personalidade a partir de textos possuem uma série de limitações, a saber:

- 1) Abordam a personalidade de maneira ingênua, por exemplo, reduzindo a personalidade a um problema de classificação binária [Argamon et. al., 2005]; [Oberlander & Nowson, 2006]; [Marisse, 2007]; [Minamikawa & Yokoyama, 2011]; [Celli et. al, 2013]; [Newmann, 2016]; [Majumder et. al., 2017]; [Vu et. al., 2017]. Alguns destes trabalhos possuem acurácia alta, chegando em alguns casos a 100%, quando consideram apenas os dois extremos da personalidade (high e low). Os trabalhos que abordam o problema corretamente possuem resultados mais modestos.
- 2) Alguns trabalhos utilizam regressão ao invés de classificação, pois alguns inventários de personalidade fornecem escalas numéricas em sua saída. Devido ao grau de dificuldade da tarefa computacional, estes trabalhos não conseguem capturar a diversidade da personalidade com confiabilidade. Neste sentido, as correlações entre o score de personalidade previsto e o score de personalidade real são geralmente fracas [Mairesse, 2007]; [Park et. al., 2015].
- 3) As metodologias de TB-APR geralmente não valorizam e não agregam o conhecimento das teorias psicológicas. Elas também não examinam, em um nível mais baixo, os detalhes dos instrumentos de aferição da personalidade. Conhecer estas teorias [Feist& Feist; Roberts, 2015] e os detalhes de como a personalidade é calculada, é fundamental para melhor compreender o processo de TB-APR. Este conhecimento poderá permitir escolher os melhores indutores, utilizando um paradigma de aprendizagem de máquina adequado.
- 4) São bastante raros os modelos que utilizam combinações de diferentes tipos de tópicos textuais para prever a personalidade, como é o caso do trabalho de Santos e seus colegas (2017). Geralmente os modelos de TB-APR utilizam textos genéricos, capturados de mídias sociais. Neste sentido, uma metodologia de coleta de textos adequada poderia melhorar a previsão automática da personalidade.
- 5) Os modelos de TB-APR, em sua totalidade [Vinciarelli & Mohammadi, 2014], utilizam inventários como instrumento de aferição da personalidade. Apesar destes inventários possuírem vantagens referentes ao tempo de aplicação e facilidade de correção, eles geralmente são baseados em teorias disposicionais [Costa & McCrae, 1992] ou genéticas [Eysenck, 1991]. Estes inventários são suscetíveis a diversos *bias*,

entre eles a resistência do ego (eu) [Freud, 1901/1905] (mecanismo de defesa que tende a proteger o ego quando este é colocado em uma posição de desconforto ou perigo), podendo ocorrer omissões, adulterações e até mesmo mentiras.

- 6) Os inventários de personalidade, que são utilizados para capturar os *scores* de personalidade nos modelos de TB-APR, podem possuir poucos itens (perguntas esperando respostas em uma escala *likert*), possuindo uma confiabilidade menor, ou podem possuir muitos itens, possuindo uma confiabilidade maior (seção 3.1.1). Neste sentido, um inventário com muitas questões pode ser exaustivo a ponto de o examinando responder às perguntas aleatoriamente. Por outro lado, um inventário com poucas questões, irá introduzir um *bias* na representatividade da escala de personalidade.

Sendo o reconhecimento automático de personalidade a partir de textos o objeto de estudo de esta tese, delimitamos como os problemas que abordaremos os itens listados acima. A próxima seção detalha os objetivos e hipóteses deste trabalho.

## 1.4 Objetivos

Propomos, como objetivos gerais para este trabalho, a construção de um novo modelo de TB-APR, permitindo que instrumentos psicométricos concebidos a partir de diferentes teorias psicológicas contribuam para a construção deste modelo. Nesse sentido, enumeramos os seguintes objetivos específicos:

- 1) Estudar as teorias da personalidade [Feist & Feist; Roberts, 2015], com o intuito de encontrar apoio na psicologia, no sentido de fornecer *insights* que permitam desenvolver uma metodologia para a construção de modelos de TB-APR mais eficientes, produzindo uma maior correlação entre os acessos da linguagem (LBA) e as dimensões da personalidade.
- 2) Agregar o conhecimento das teorias de personalidade no processo de coleta textual, utilizando uma metodologia concebida para capturar aspectos relacionados à personalidade nos textos, permitindo que uma pequena quantidade de textos seja suficiente para o reconhecimento automático da personalidade.
- 3) Utilizar instrumentos de aferição da personalidade projetivos ao invés de um questionário estruturado, como os inventários de personalidade. Os instrumentos projetivos possuem tarefas muito mais livres, interessantes e divertidas de serem realizadas, tais como contar histórias, ou utilizar a imaginação para perceber objetos

[Ocampo, 1999]; [Scaduto, 2016]; [Vaz & Alchieri, 2016]. Neste sentido, as técnicas projetivas estão menos sujeitas aos *bias* relativos às oscilações do humor [Scheefer, 1962] que podem induzir a respostas aleatórias (ex: por saturação ou fadiga do examinando). Além disso, as transparências dos itens dos inventários de personalidade facilitam a falsificação das respostas [Scheefer, 1962]. Sendo assim, as técnicas projetivas exploram a personalidade de uma forma mais sutil e incisiva, investigando a personalidade do indivíduo sem revelar o processo de investigação [Urbina, 2007]. Estas técnicas permitem driblar o mecanismo de censura (seção 2.1.1), permitindo a construção de *corpora* mais representativos da personalidade.

- 4) Verificar a confiabilidade do novo modelo proposto, realizando experimentos de aprendizagem de máquina. Estes experimentos irão identificar padrões nos textos para prever as dimensões de personalidade inferidas através das técnicas projetivas. As técnicas projetivas que utilizamos [Vaz & Alchieri, 2017] [Scaduto, 2016] devem permitir realizar a tarefa de TB-APR através do paradigma de classificação multi-classe (seção 5.2.2), sem prejuízo às escalas originais de personalidade. Estas técnicas projetivas serão melhor detalhadas no capítulo 7. Finalmente, compararemos os resultados obtidos nos experimentos com os trabalhos do estado da arte.

A próxima seção discorre sobre as hipóteses que formulamos, mostrando como estes objetivos serão atingidos.

## 1.5 Hipóteses

A partir dos objetivos selecionados para este trabalho, formulamos as seguintes hipóteses:

- 1) Ao estudar as teorias da personalidade, conheceremos a essência daquilo que os modelos de TB-APR tentam prever. Neste sentido, esta tese poderá construir uma base de conhecimento científico de psicologia em paralelo com uma base de conhecimento na computação, objetivando aprimorar as correlações dos modelos de TB-APR. Neste sentido, as teorias da personalidade poderão trazer *insights* em relação ao processo de coleta textual e escolha do instrumento psicológico de aferição da personalidade.
- 2) Aplicando uma técnica projetiva no lugar de um inventário de personalidade, será possível presumir uma confiabilidade maior ao modelo de TB-APR; as técnicas projetivas são menos suscetíveis a mentiras [Scheefer, 1962] e ao mecanismo de censura [Freud, 1901 / 1905].

- 3) Ao tratar a personalidade como um problema complexo, utilizando a escala das  $n$ -dimensões originais do instrumento de aferição da personalidade, aproximaremos o modelo de TB-APR destas escalas originais, permitindo correlações mais realistas entre as técnicas de acesso à linguagem e os scores  $n$ -dimensionais da personalidade.

A próxima seção apresenta a motivação desta tese. Para tanto, promovemos uma crítica aos modelos existentes com a exemplificação de casos da literatura.

## 1.6 Motivação

A maior parte das técnicas de construção de modelos para TB-APR encontradas na literatura utilizam artifícios para melhorar a resposta dos indutores, fazendo uma simplificação das escalas de personalidade. É comum estas técnicas considerarem apenas os extremos dos traços de personalidade a partir dos  $z$ -scores, transformando o problema, tipicamente de regressão multi-target, em  $n$ -problemas de classificação binária. Esta simplificação diminui a complexidade dos modelos mas introduz diversos *bias*:

- 1) Empregar os Z-scores com base em desvios padrões, considerando apenas os casos extremos da personalidade, irá aumentar artificialmente a performance de classificação, introduzindo *overfitting* e pouca capacidade de generalização, pois esta aparente melhora não é compatível com a diversidade da personalidade humana. Caso este modelo seja colocado em produção em um ambiente real, fará uma espécie de *random guess* na parte da população com scores medianos.
- 2) As escalas utilizadas em inventários de personalidade [Johnson, 2014] muitas vezes são numéricas, neste sentido, não foram concebidas para funcionar em extremos. Em relação aos paradigmas de ML, seria muito mais adequado trabalhar com algum paradigma de regressão com estas escalas. A comunidade de TB-APR tenta utilizar este paradigma desde 2002 [Gill et. Al, 2002], sem conseguir correlações satisfatórias com esta metodologia [Marisse, 2007]; [Park et. al, 2015]. Estudos mais recentes focaram em medidas de erro [Celli et al, 2016]; [Karanatsiou et. al, 2020] ao invés da correlação.
- 3) Empregar os Z-scores com o paradigma de classificação binária (seção 5.2.1), considerando os extremos da personalidade, certamente obrigará o modelo a produzir

análises de personalidade incompletas para grande parte da população. Tipicamente, pode ocorrer que um indivíduo tenha um score extremo em uma dimensão (ex. extroversão), com um score mediano em outra dimensão (ex. neuroticismo). Utilizar esta técnica irá obrigar o modelo a ignorar a dimensão neuroticismo.

- 4) Quanto ao item 3, existe mais um *bias*, relacionado às distribuições dos scores de personalidade. Estas distribuições nem sempre se aproximam de uma curva normal. Se uma escala de personalidade é concebida por um instrumento como numérica, caso na construção do modelo se opte por simplificar o problema de regressão em um problema de classificação, um desbalanceamento de classes pode ser introduzido. Dependendo da distribuição da amostra, este problema pode vir a inviabilizar a inferência automática de personalidade em diversas dimensões.
- 5) O paradigma de classificação binária também pode ser utilizado de uma forma diferente, dividindo a amostra em extremos através da média da escala. Este artifício certamente irá provocar uma alteração artificial do conceito da escala, confundindo os classificadores.

Talvez o trabalho que melhor exemplifica os artefatos gerados pela utilização de *Z-scores* é o de Oberlander e Nowson (2006), no qual os autores utilizaram os textos de 71 bloggers rotulados pelos scores de um inventário Big Five. Neste trabalho, diversos experimentos foram realizados, fazendo a decomposição e a simplificação das escalas dos scores de personalidade. As acurácias reportadas para estes experimentos foram de até 100% para a classificação binária, mas à medida que classes adicionais foram incluídas, a performance dos modelos baixou consideravelmente, com acurácias reportadas entre 0.44 e 0.69 para modelos com 5 classes. Seguindo uma metodologia parecida, Minamikawa e Yokoyama (2011) desenvolveram modelos com 2, 3 e 5 classes, utilizando um corpus de 551 indivíduos, rotulados por um inventário de personalidade chamado *Todai-Shiki Egogram*. A acurácia reportada nestes experimentos variou entre 0.63 e 0.85 para experimentos de classificação binária, 0.55 a 0.69 para experimentos de 3 classes e 0.47 a 0.62 para os experimentos utilizando de 5 classes. Neste sentido, os modelos de classificação binária possivelmente estão com *overfitting*, sendo bastante provável que o primeiro trabalho obteve uma acurácia perfeita devido ao tamanho reduzido da amostra ( $n=71$ ).

Para evitar o *overfitting*, devemos abordar o problema TB-APR de forma coerente em relação ao instrumento utilizado para calcular os scores dimensionais da personalidade. Como muitos inventários de personalidade utilizam escalas numéricas, o paradigma de regressão seria mais adequado do que utilizar *Z-Scores*, pois estes últimos provocam diversos artefatos. Entretanto, o

problema de regressão pode ser muito complexo, um indício disso é que a comunidade de TB-APR não tem encontrado sucesso utilizando este paradigma em relação a medidas de correlação que geralmente são fracas [Pennebaker & King, 1999]; [Park et. al, 2015]. Neste sentido, os últimos trabalhos de regressão procuraram focar na redução do erro [Celli et. al, 2016]; [Karanatsiou et. al, 2020], obtendo algum sucesso acima de *baselines*, mas não informaram medidas de correlação. Por outro lado, em relação à tarefa de classificação, existem efeitos colaterais introduzidos por *Zscores*: (i) a necessidade de descartar traços de personalidade devido a distribuições distorcidas, (ii) a geração de modelos ingênuos, utilizando o paradigma de classificação binária, que apesar de uma alta performance teórica, em um ambiente real seria pouco provável que generalizassem. Na tarefa de classificação, existe ainda a possibilidade de gerar modelos que considerem a divisão da escala de personalidade em dois extremos a partir da média, por exemplo. Estes modelos certamente confundiriam os classificadores não generalizando adequadamente. Neste sentido, as técnicas projetivas que selecionamos para esta tese, utilizam classes em suas escalas de personalidade nativas: o Z-teste [Vaz & Alchieri, 2016] faz o uso de *Z-scores* (3 a 5 classes dependendo da dimensão) e o TAT [Scaduto, 2016] que faz o uso de classes customizadas.

Outro ponto importante, conforme apresentado no Capítulo 2 desta tese, é a constatação de que as teorias psicológicas são fundamentais para uma melhor elaboração do conceito-chave para a personalidade. O único autor, de acordo com o nosso conhecimento, que utiliza e valoriza as teorias da personalidade em seus modelos de TB-APR, é o psicólogo e cientista da computação Newmann (2016). Este autor, em seu livro, mostra a grande importância das teorias da personalidade, demonstrando que conceitos-chave das teorias psicológicas podem ajudar prever a personalidade, utilizando para isso diferentes técnicas computacionais, tais como: vetores semânticos, *parsers* de análise sintática e semântica e até mesmo protótipos de técnicas de extração de características, como é o caso da computação psicanalítica.

É importante ressaltar, ainda, que muitos trabalhos de TB-APR desconsideram estudos de confiabilidade referentes à pontuação de personalidade. Neste sentido, existem *corpus* de TB-APR em que os inventários de personalidade não possuem validação científica [Nowson e Oberlander, 2007]. Apesar disso, também existem trabalhos de TB-APR que utilizam inventários de personalidade com uma consistência interna maior (*alfa de Cronbach*), possuindo inclusive mecanismos para acessar os scores de personalidade referentes a sub-traços, chamados de facetas [Johnson, 2014], sendo que estas também possuem um índice elevado de confiabilidade por serem aspectos fatoriais essenciais dos traços psicológicos. Temos conhecimento de dois trabalhos de TB-APR que utilizam o paradigma de regressão para inferir facetas de personalidade [Santos & Paraboni,

2019]; [Karanatsiou et. al, 2020]. Neste sentido, a inferência automática de facetas psicológicas é tópico pouco explorado. Acreditamos que estas facetas poderiam fornecer informações mais específicas sobre a personalidade, podendo também ser utilizadas para aumentar a precisão da previsão dos traços psicológicos principais. Nesta tese, exploramos as facetas de personalidade em alguns experimentos preliminares. Estes experimentos estão descritos no anexo 1. Nestes experimentos tentamos inovar utilizando técnicas de extração de características híbridas (*top-down e bottom-up*) em conjunto com paradigma de regressão multi-target. Estes experimentos, até nosso conhecimento, possuem características inéditas em comparação com os modelos do estado da arte. Os *insights* destes experimentos em relação aos resultados obtidos, foram descritos na seção do anexo 1.5.

Um dos principais trabalhos, que motivou o desenvolvimento desta tese, foi realizado pelos autores Pennebaker e King no ano de 1999, no qual eles fizeram um estudo com diversos *corpora* textuais. Nesse caso, não se trata de um trabalho de TP-APR no sentido de testar diferentes modelos para reconhecer a personalidade. O principal objetivo foi verificar a confiabilidade de cada categoria do léxico LIWC [Pennebaker et. al., 2015]. Neste estudo, foi mensurada a consistência interna e a confiabilidade das categorias do LIWC. Para isso foram coletados diversos tópicos textuais submetidos a contagens de palavras. Na última fase do estudo (terceira fase), as categorias do LIWC foram correlacionadas com um inventário de personalidade Big Five (seção 3.1.1) e a técnica projetiva TAT [Murray, 1943/2005]. A técnica do TAT utilizou um sistema de quotação com 3 escalas de personalidade [Winter, 1989]. As correlações das dimensões entre o LIWC e as categorias do inventário Big Five foram reportadas entre 0.02 e 0.15. As correlações entre as categorias do léxico LIWC e a técnica projetiva TAT foram reportadas entre 0.3 e 0.33. Como a correlação entre as dimensões *Immediacy* do LIWC e *Need For Achievement* do TAT foi mais notável (0.33), os autores fizeram um experimento extraído uma dimensão fatorizada do LIWC, obtida através das dimensões léxicas mais promissoras correlacionadas com *Need for Achievement*, obtendo uma correlação de 0.44. Apesar desta correlação ainda ser fraca, foi quase 200% maior que as correlações obtidas através do inventário Big Five. Finalmente, pouco se sabe sobre a influência de diferentes tópicos textuais controlados para previsão de personalidade. Além desse trabalho, outro trabalho que nos inspirou, foi um estudo mais recente, utilizando um *corpus* em português-br, que verificou aspectos relacionados à quantidade de textos e tópicos controlados [Santos et. al., 2017]. Nesse sentido, seria interessante que o *corpus* utilizado para construir modelos de TB-APR contemple uma metodologia adequada para realizar a coleta textual, além de explorar as técnicas projetivas.

Consideramos que a crítica mais importante que esta tese faz aos modelos existentes de TB-APR seja relacionada aos *bias*, que via de regra são sempre ignorados, relacionados aos inventários de personalidade utilizados para rotular o *corpus*. Os inventários de personalidade possuem uma grande facilidade de aplicação e podem ter, inclusive, o processo de aplicação automatizado eletronicamente. Entretanto, os scores de personalidade destes inventários podem não ser totalmente confiáveis. Neste sentido, mesmo que a consistência interna do inventário seja alta ( $\alpha > 0.90$ ), o indivíduo que responde o inventário pode omitir características não desejáveis, ao saber que a personalidade está sendo investigada. Isso pode acontecer de forma consciente (proposital) ou de forma inconsciente (sem intenção) através de algum mecanismo de defesa do ego. Os Testes projetivos [Rorschach, 1974]; [Vaz & Alchieri, 2016]; [Murray, 1943/2005] possuem vantagens e desvantagens em relação aos inventários de personalidade. A principal desvantagem é que estes testes requerem um tempo maior de aplicação e, geralmente, necessitam de um profissional qualificado (psicólogo) com conhecimento em teorias da personalidade para calcular os *scores* de personalidade. Por outro lado, a vantagem destes testes está relacionada à possibilidade de fazer o *by-pass* do mecanismo de censura, permitindo capturar pistas mais significativas, relacionadas a projeções do mundo interno do indivíduo. Estas pistas os inventários de personalidade muito dificilmente conseguiriam capturar, pois nas técnicas projetivas é praticamente impossível omitir ou mentir sobre detalhes da personalidade.

Estando esclarecida a motivação, deixamos explícita a contribuição desta tese: (i) a elaboração de novos corpora de TB-APR que utilizam técnicas projetivas ao invés de inventários de personalidade e (ii) o desenvolvimento de modelos de aprendizagem de máquina que não utilizam técnicas de simplificações das escalas originais de personalidade, tratando a personalidade como um sistema n-dimensional complexo. A próxima seção explica como estruturamos nossos estudos.

## 1.7 Estrutura desta tese

Esta tese está organizada da seguinte forma: O Capítulo 2 aborda os principais conceitos relacionados às teorias da personalidade. O Capítulo 3 faz um apanhado geral dos instrumentos psicométricos de aferição da personalidade. O Capítulo 4 explora as técnicas de extração de características. O Capítulo 5 analisa os diferentes paradigmas de aprendizagem de máquina. O Capítulo 6 aborda os trabalhos relacionados encontrados na literatura. O Capítulo 7 mostra a metodologia que será utilizada. O Capítulo 8 detalha os experimentos preliminares. O Capítulo 9 apresenta as considerações finais desta tese, propondo alguns trabalhos futuros.



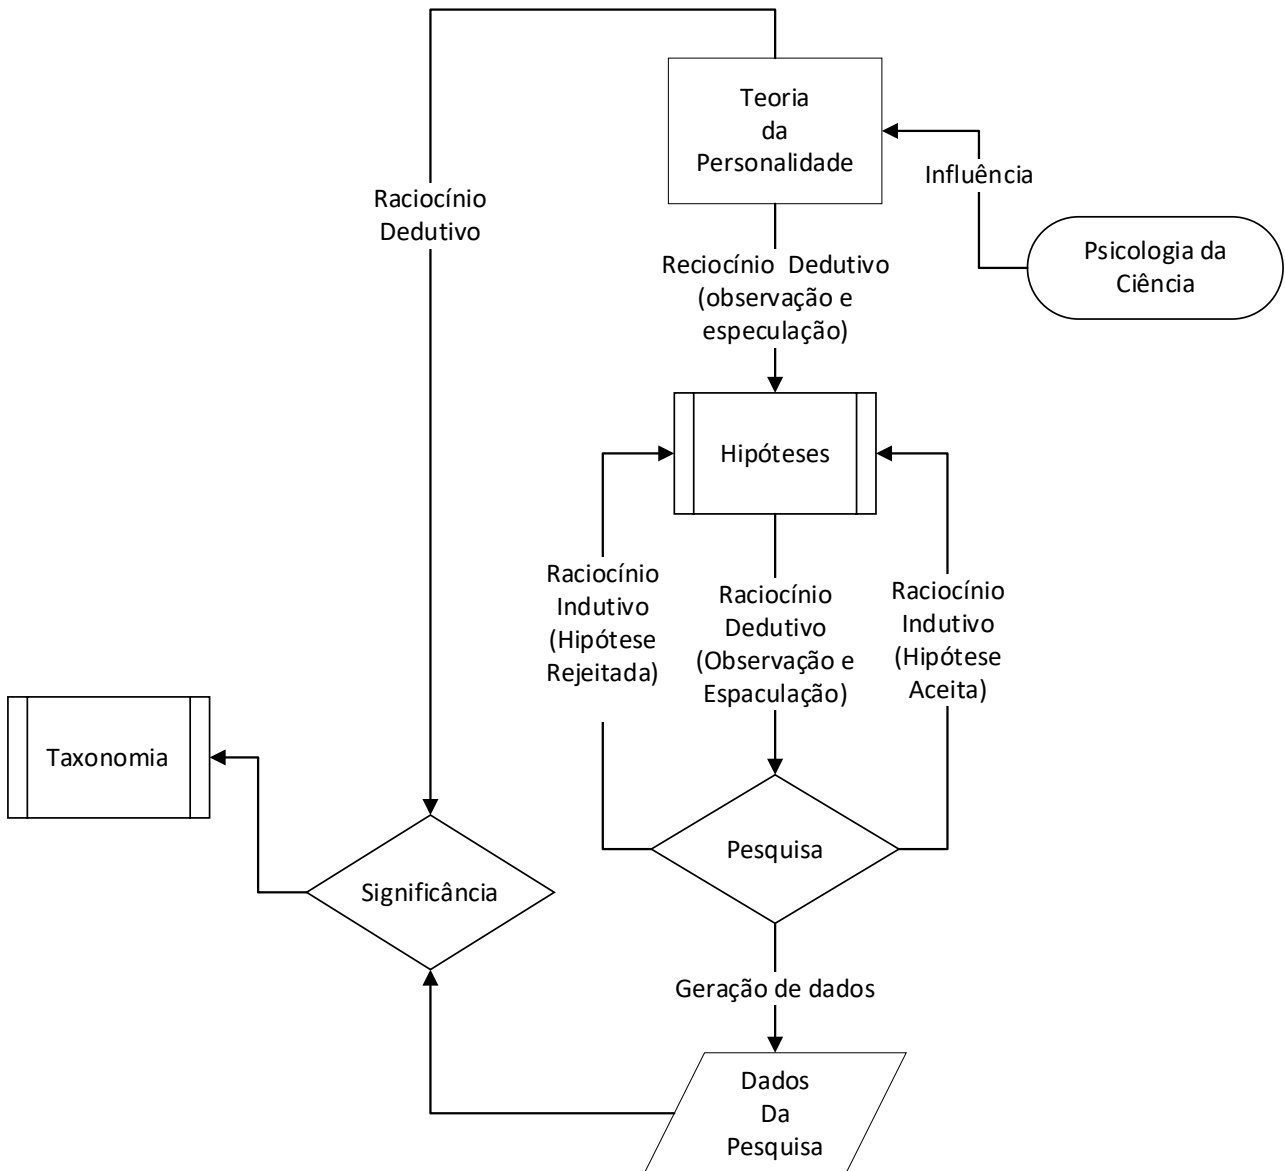
## 2 Teorias da personalidade

As teorias de personalidade podem ser entendidas como conjuntos de conceitos relacionados inerentes à cognição e ao comportamento humano. Quanto à psicologia, o conceito de personalidade é subjetivo; há muitas perspectivas teóricas diferentes que são influenciadas pelo conceito de humanidade do teórico, fazendo com que a própria personalidade do criador da teoria tenha um papel determinante em sua construção. Nos últimos anos este fato ganhou expressão, levando à criação de uma subdisciplina dentro da psicologia, chamada de “*Psicologia da Ciência*” [Feist & Feist; Roberts, 2015], que tem como objetivo estudar a personalidade, o contexto histórico e outros detalhes pessoais da vida do ser humano que elaborou alguma teoria, sendo uma tentativa de explicar a subjetividade no modelo teórico elaborado.

Geralmente, as variantes de três métodos científicos são usualmente utilizados para a construção de uma teoria da personalidade [Schultz & Schultz, 2003]:

1. O método clínico que utiliza estudos de casos de pacientes.
2. O método experimental que inclui a observação objetiva e sistemática em um ambiente controlado.
3. O método correlacional que avalia a relação entre variáveis.

A construção de uma teoria de personalidade inicia-se a partir da subjetividade do teórico (*Psicologia da Ciência*), seguindo um protocolo científico. Este protocolo parte da observação empírica seguida de especulação, permitindo a dedução de hipóteses. Estas hipóteses poderão ser validadas ou rejeitadas através da pesquisa, tornando possível a reformulação da teoria por indução. À medida que a teoria amadurece, ela irá inferir os significados e as relações entre os dados estudados na pesquisa, criando uma taxonomia. O fluxograma, apresentado na Figura 6, mostra em detalhes o processo da criação de uma teoria da personalidade.



**Figura 6.** Fluxograma da construção de Teorias da personalidade.

Todas teorias de personalidade possuem particularidades, podendo algumas teorias terem muitas similaridades, inclusive com algumas sendo uma espécie de extensão de outras teorias, enquanto que outras podem ser completamente diferentes. Estas teorias investigam a influência de diversos fatores na formação da personalidade: genético, ambiental, aprendido, parental, desenvolvimento, consciência e inconsciência [Schultz & Schultz, 2003].

As teorias da personalidade podem ser classificadas em psicodinâmicas, humanistas existenciais, disposicionais, biológicas evolucionistas e cognitivas e da aprendizagem [Feist & Feist; Roberts, 2015]. Reservamos, neste capítulo, uma seção com diversas subseções detalhando 17 teorias

diferentes. A penúltima seção foi reservada para falar de desordens da personalidade, um conceito a-teórico sobre a personalidade. A última seção faz considerações finais sobre o capítulo.

## **2.1 Teorias psicodinâmicas**

As teorias psicodinâmicas se concentram nas diferentes estruturas conceituais do aparelho psíquico, admitindo a existência de uma dinâmica energética mental. Apesar destas teorias terem o berço na psicanálise freudiana, muitas outras teorias contribuíram para o legado psicodinâmico.

Os testes projetivos que utilizaremos em nosso modelo de TB-APR possuem uma base teórica herdada das teorias psicodinâmicas, partindo da premissa da existência de um inconsciente [Freud, 1915/1957b] e do mecanismo de projeção [Freud, 1936]. A projeção é um mecanismo psíquico que permite que um indivíduo projete em outro objeto aspectos de sua personalidade. Este mecanismo pode ser ativado como uma resposta de defesa do ego (eu) [Freud, 1923/1961a] a impulsos energéticos (pulsões) inconscientes.

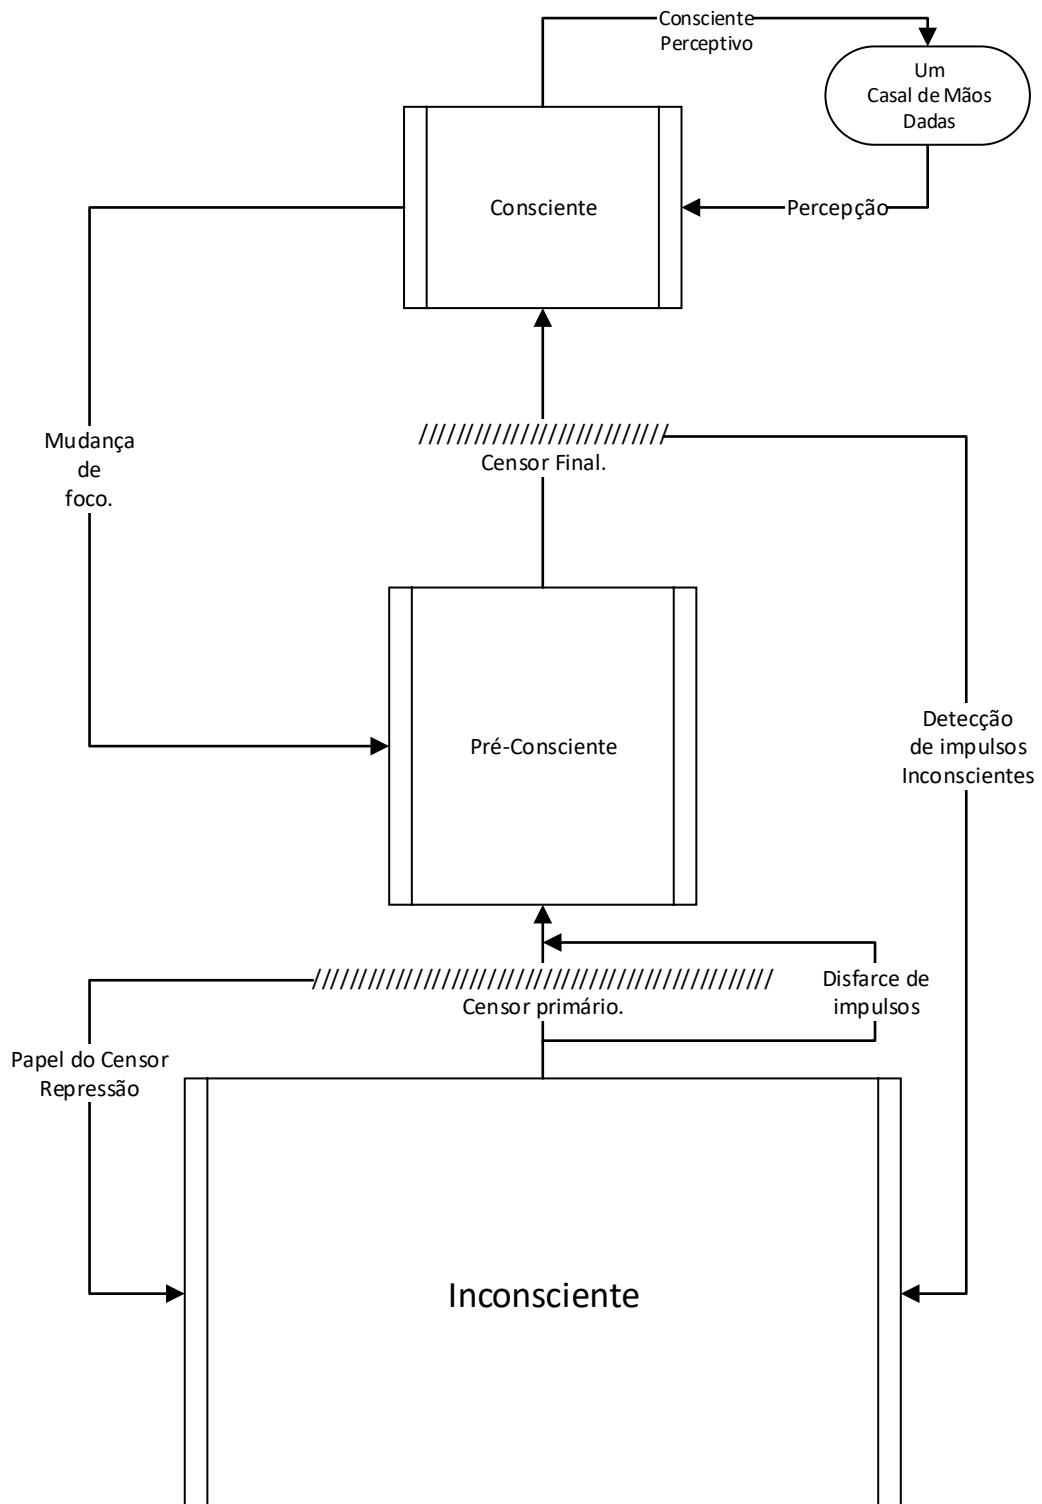
Na próxima subseção, exploraremos um pouco mais detalhadamente a teoria psicanalítica. Estes conceitos serão necessários posteriormente para interpretar os resultados dos testes projetivos. Logo em seguida, cada subseção irá apresentar um breve resumo das outras teorias psicodinâmicas da personalidade.

### **2.1.1 Freud e a teoria psicanalítica**

A primeira teoria da personalidade, chamada de “teoria psicanalítica”, está relacionada à descoberta do inconsciente. Esta teoria foi inferida através do método psicanalítico (uma especialização do método clínico) criado por Freud (1903). O inconsciente é uma atividade mental, regida pelo princípio do prazer que busca a satisfação imediata de seus impulsos. Em oposição ao inconsciente, a consciência é regulada pelo princípio da realidade, utilizando mecanismos de defesa contra impulsos, não considerados apropriados, que surgem do inconsciente.

A primeira tópica freudiana [Freud, 1920 / 1955a] explica a dinâmica destas forças mentais. Para isso, Freud dividiu o inconsciente em dois principais níveis: o pré-consciente [Freud, 1917/1963, p. 295-296] que funciona como uma antessala, onde elementos não conscientes podem vir a se tornar conscientes a qualquer momento, de forma imediata ou com certa dificuldade, e o inconsciente propriamente dito. Adicionalmente, Freud incluiu uma espécie de barreira simbólica entre o consciente e o inconsciente, a qual ele chamou de censor [Freud, 1915], esta barreira é responsável

por impedir que pensamentos, imagens ou ideias ameaçadoras se tornem conscientes. A primeira tópica é detalhada na Figura 7.



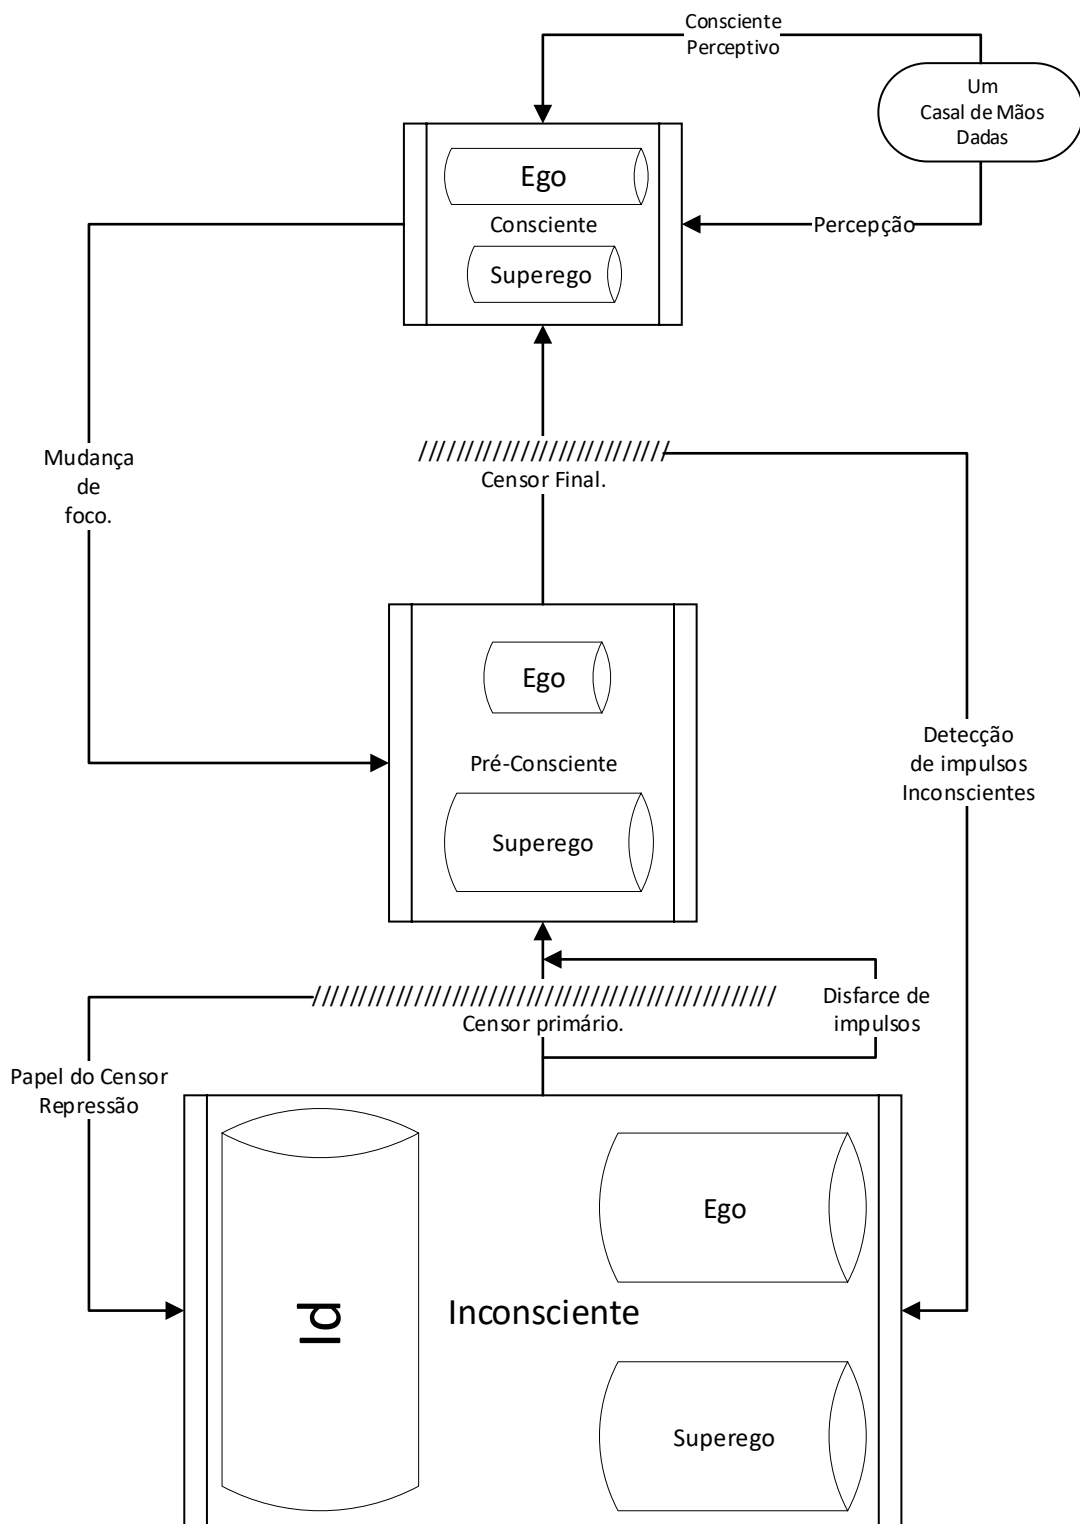
**Figura 7.** Fluxograma da primeira tópica freudiana.

Na teoria psicanalítica, o consciente desempenha um papel menor que o inconsciente, tanto que a primeira tópica pode ser representada pela metáfora do *iceberg*, onde a parte visível acima do nível do mar representa o consciente e a parte invisível, abaixo do nível do mar, representa o inconsciente. Sabemos que a parte visível de um *iceberg* é desprezível em relação à parte não visível (submersa).

Os pensamentos podem ser entendidos como uma energia psíquica [Freud, 1905/1953b] que chegam ao consciente através de duas principais vias. A primeira que Freud chamou de consciente perceptivo [Freud, 1933/1964] é a parte consciente, responsável por receber os estímulos exteriores, os quais são recebidos dos órgãos sensoriais. Sendo assim, caso estes estímulos não sejam extremamente ameaçadores, serão disponibilizados rapidamente ao consciente. A outra via ocorre através de pensamentos ou ideias pré-conscientes que, do mesmo modo, caso não sejam ameaçadoras, podem tornar-se conscientes. Os pensamentos conscientes estão sempre sujeitos a uma espécie de dinâmica de trânsito entre o pré-consciente e consciente; neste aspecto, o censor final desempenha um papel importante, permitindo que os indivíduos mudem de foco rapidamente.

Os pensamentos, que não são do consciente ou do pré-consciente, são do inconsciente propriamente dito. Do ponto de vista dinâmico da personalidade, estes pensamentos inconscientes são uma energia que precisam de um escape para a satisfação; para isso necessitam tornar-se conscientes. Sendo assim, o censor, que já foi mencionado no segundo parágrafo desta subseção, desempenha diversos papéis, tais como: (i) impedir que pensamentos ameaçadores do inconsciente entrem no pré-consciente (censor primário). (ii) Impedir que pensamentos ameaçadores do pré-consciente se tornem conscientes (censor final). Em outras palavras, caso os pensamentos, imagens e ideias ameaçadoras do inconsciente consigam chegar ao pré-consciente de maneira disfarçada, driblando o mecanismo de barreira imposto pelo censor primário, existe ainda o censor final. Caso este último ainda identifique este pensamento (ou qualquer outro) como ameaçador, ele poderá “expulsar” este pensamento novamente para o inconsciente. Qualquer processo de expulsão de um pensamento para inconsciente é chamado de repressão.

No fluxograma da Figura 7, a repressão está sendo representada pela dinâmica de fluxo inverso, significando que o censor verificou que aquela energia psíquica era ameaçadora. O censor é o guardião do pré-consciente e do consciente, o elemento que faz a divisão entre as instâncias mentais. O censor é o ativador do *mecanismo de defesa* da repressão [Freud, 1946] e o elemento-chave para o entendimento da primeira tópica freudiana.



**Figura 8.** Fluxograma da segunda tópica Freudiana.

Após 20 anos da primeira tópica ser proposta, Freud propôs uma segunda tópica para o funcionamento dos mecanismos mentais [Freud, 1923/1961a]. A segunda tópica não invalida a primeira tópica, mas constitui uma complementação. Com a segunda tópica foi possível explicar os pensamentos (representações mentais) de acordo com a sua natureza, flexibilizando a estrutura proposta na primeira tópica. A segunda tópica propõe que os pensamentos são funções de mecanismos mentais chamados de Id, ego e superego. Estes mecanismos são detalhados na Figura 8.

Ao referir-se à parte mais primitiva da mente, Freud utilizava a palavra em alemão “*das es*”, traduzido para o inglês como “*it*” que, ao ser traduzido para outras línguas, como o português, ficou denominado como “*Id*”. A denominação de superego deriva da tradução do alemão “*Über-Ich*” (super-eu). O ego se forma no desenvolvimento da personalidade a partir da instância mais primitiva, o Id. O ego possui elementos conscientes, pré-conscientes e inconscientes. O superego se forma a partir do ego, possuindo elementos pré-conscientes e inconscientes. A Tabela 1 descreve as diferenças das partes conscientes, pré-conscientes e inconscientes destas três “regiões” ou instâncias mentais.

Id	Ego	SuperEgo
Fonte dos instintos ou pulsões, inato.	É desenvolvido a partir do Id.	É desenvolvido a partir do Ego.
Não possui moral	Possui moral	Conceito de Hipermoral
Atividade exclusivamente inconsciente.	Pode controlar os impulsos do Id, mas está a mercê dele, atividade sobretudo consciente mas também inconsciente.	Se empenha cegamente pela perfeição, sem se importar com a felicidade do Ego, atividade sobretudo inconsciente mas também consciente.
Ilógico e desorganizado	Lógico, organizado.	Vigia e julga o Ego.
Princípio do prazer, processo primário.	Princípio da realidade, processo secundário.	Princípio do dever.

**Tabela 1.** Os mecanismos mentais relacionados a segunda tópica freudiana [Freud, 1915].


O Id, sendo totalmente inconsciente e instintivo, obedece apenas e somente ao princípio do prazer, pois é, em sua totalidade, inconsciente. Ao ser inconsciente, ele não está sujeito a regras, ou seja, ao confrontar o Id com qualquer ideologia, verificamos que ele é amoral e ilógico. Sendo assim, é possível, de forma inconsciente, alguém ter uma tremenda admiração por um amigo e, ao mesmo tempo, desejar matá-lo. Esta antítese, só pode ser possível em um ambiente que não exista o bem ou o mal. Podemos entender o Id, como o reservatório primário da energia psíquica. O termo, utilizado na psicanálise para descrever esta energia, é pulsões [Freud, 1915/1957a], [Freud, 1905/1953b]. Estas

pulsões possuem o único objetivo de conseguir a satisfação, tornando-se conscientes. Freud caracterizava Id, o centro das pulsões, como um processo primário que depende de um processo secundário. O processo secundário é justamente a via por onde satisfação pulsional é consumada, através da externalização destes impulsos ao mundo exterior por meio do Ego. O Ego ao contrário do Id, obedece ao princípio da realidade, podendo conviver com os impulsos do Id através do mecanismo de repressão e outros mecanismos de defesa. No desenvolvimento da personalidade humana, a formação do ego ocorre a partir do Id, quando nos primeiros meses de vida os bebês aprendem a distinguir as coisas do mundo exterior, sendo esta distinção os primeiros indícios do princípio de realidade.

O Superego é desenvolvido a partir do Ego. Esta instância é guiada pelo princípio moral e ideal. Entretanto, o Superego não tem contato direto com o mundo externo. Sendo assim, o Superego é irrealista, procurando sempre encontrar a perfeição. Freud dividiu o Superego internamente em consciência e ideal de ego. A consciência é a parte do Superego resultante de vivências punitivas por comportamentos inadequados, ditando o que não devemos fazer. O ideal de Ego, que é a parte do Superego resultante de experiências recompensadoras, dita o que devemos fazer. Podemos comparar o Superego a uma espécie de julgador do Ego, podendo inferir sentimentos de inferioridade e culpa ao Ego.

No que diz respeito às divisões das instâncias mentais entre Ego, Superego e Id, elas podem variar de acordo com a personalidade de cada um, fazendo com que uma instância seja mais significativa que a outra [Feist & Feist; Roberts, 2015, p. 22]. A Figura 9 exemplifica três tipos diferentes de personalidade sobre o ponto de vista da segunda tópica freudiana. O primeiro círculo indica uma pessoa perturbada, dominada pelo Id, vivendo em uma busca incansável pelo prazer. O segundo círculo indica uma pessoa sofrida, vítima de sentimentos de culpa e inferioridade, sendo dominada pelo Superego com suas exigências moralistas. O terceiro círculo mostra uma pessoa equilibrada, prevalecendo o Ego e o princípio da realidade.





**Figura 9.** A personalidade de acordo com a segunda tópica Freudiana.

Após a compreensão de como o aparelho mental é estruturado, também será possível entender como funciona a dinâmica da energia psíquica. Como já relatamos, os pensamentos fluem nas instâncias mentais através de pulsões, do alemão “*Trieb*” [Freud, 1905/1953b], que foi traduzido como “impulso” ou “pulsão”. Freud nomeou dois tipos principais de impulsos: (i) a pulsão de vida, a qual ele denominou por “Eros”, e a pulsão de morte, denominada por “Thanatos” [Freud, 1933/1964]. Estes impulsos se originam no Id e são controlados pelo Ego. Toda pulsão na teoria freudiana possui uma fonte (região corporal de excitação ou tensão), uma finalidade (remover a excitação ou tensão, buscando o prazer) e um objeto (pessoa ou coisa que satisfaz a pulsão) [Feist & Feist; Roberts, 2015].

Tanto as pulsões inconscientes de vida (Eros) como as pulsões de morte (Thanatos) que provém do Id, demandam que o Ego as apresente ao mundo exterior. A censura não deixa estas pulsões atingirem seus objetivos, protegendo a parte consciente do Ego. Para entender melhor o papel da censura na segunda tópica, podemos utilizar uma nova metáfora. Podemos considerar o censor como um policial de fronteiras do aparelho psíquico. Nesta analogia, o Id é um contrabandista, no nível da inconsciência, que deseja entregar o contrabando (as pulsões) ao Ego, no nível da consciência. O Id contrabandista necessita passar pelo policial (censor primário) para sobreviver, disfarçando suas mercadorias e permitindo que elas cheguem ao nível da pré-consciência. Mesmo disfarçadas, um pouco antes de se tornarem conscientes e apresentadas ao Ego (pré-conscientes), estas mercadorias ainda estão sujeitas à apreensão pelo policial (censor final). Caso o policial não indentifique o contrabando, a mercadoria será apresentada ao Ego na consciência, mas de forma disfarçada. Sendo assim a segunda tópica (Figura 9) flexibiliza os conceitos da primeira tópica (Figura

7), complementando-os. A consciência não é composta apenas de pensamentos conscientes, pois o Ego (seu núcleo) também é composto de partes contrabandeadas do Id, que foram incorporadas a ele de maneira disfarçada. A Figura 8 mostra como parte do Ego também é inconsciente. O Ego apenas concorda em apresentar estas pulsões ao mundo exterior porque estão disfarçadas o suficiente, sendo assim dizemos que mecanismos de defesa foram utilizados pelo Ego.

A teoria psicanalítica classifica os diferentes mecanismos de defesa do Ego [Freud, 1946]. Os mecanismos de defesa podem ser identificados em testes projetivos [Vaz & Alchieri, 2016], instrumentos usados para pontuar a personalidade admitindo a existência do inconsciente; os mecanismos de defesa são: a repressão, a formação reativa, o deslocamento, a fixação, a regressão, ***a projeção***, a introjeção e a sublimação. A projeção foi colocada em negrito e itálico, pois é o mecanismo de defesa mais importante para entender o funcionamento dos testes projetivos.

- 1) O mecanismo da repressão ocorre sempre que o Ego se sente ameaçado por impulsos do Id, forçando tais impulsos a voltarem para o inconsciente: ao reprimir tais impulsos, o nível de ansiedade do Ego torna-se mais suportável. Entretanto, estes impulsos podem voltar a atormentar o Ego, pois no inconsciente eles podem ser intensificados ou disfarçados, enganando o Ego.
- 2) A formação reativa é o nome que se dá quando um impulso reprimido se disfarça para atingir seu objetivo de satisfação, passando pelo sensor que regula o processo secundário (Ego). Na formação reativa, o objeto de pulsão permanece o mesmo, mas o impulso é disfarçado.
- 3) O deslocamento se dá quando os impulsos são direcionados para outro objeto, podendo passar desta forma pela barreira da censura, ocultando o impulso direcionado ao objeto original.
- 4) O mecanismo da fixação acontece quando ocorre uma associação permanente dos impulsos a um estágio de desenvolvimento da personalidade mais primitivo (ex: fase oral); se esta associação não for permanente e apenas ocorrer em certos momentos de estresse ou ansiedade, ela é chamada de regressão.
- 5) ***A projeção ocorre quando um impulso produz um nível muito elevado de ansiedade e é direcionado a outro objeto externo.***
- 6) A introjeção se dá quando ocorre a incorporação de qualidades externas (outros indivíduos) pelo próprio ego.
- 7) Na sublimação, o ego se protege da ansiedade, substituindo o impulso de Eros por um propósito cultural ou social.

Na teoria freudiana, todas as atividades oriundas de pulsões de Eros estão ligadas às zonas erógenas, por isso as pulsões de Eros também são chamadas de pulsões sexuais (não se referindo aqui apenas aos órgãos genitais). Qualquer atividade prazerosa para um indivíduo, ao ter sua origem investigada, sempre será proveniente de um impulso sexual (pulsão de Eros). A pulsão pode mudar seu objeto. Um exemplo pode ser testemunhado no desmame de um bebê, que passa a usar a chupeta como substituto ao objeto “sexual” anterior (mamilo). Este exemplo, caracteriza como o objeto pulsional pode ser de certa forma flexibilizado e trocado, continuando a satisfazer a zona erógena (boca) do bebê. Pensando nesta flexibilização, a energia sexual proveniente das pulsões de Eros pode aparecer disfarçada ou transformada, como é o caso da amizade, do amor, narcisismo, masoquismo, sadismo, entre outros. Sendo assim, Freud associou as pulsões de Eros com a palavra libido, descrevendo como sexual a sua natureza.

Quanto aos bebês, Freud identificou que, nos primeiros meses de vida, a libido de Eros é direcionada quase que exclusivamente ao Ego, e chamou isto de narcisismo primário. Ao desenvolver a personalidade, o indivíduo começa gradativamente a abandonar o narcisismo primário, tirando o Ego como objeto e colocando outros objetos em substituição. Sendo assim, a libido narcisista primária muda para uma libido objetal. Entretanto, certas pessoas não conseguem se desvencilhar facilmente do narcisismo primário, produzindo uma espécie de narcisismo secundário que pode ser patológico se for exagerado [Freud, 1914 / 1957].

Os impulsos de agressividade, caracterizados como pulsão de morte ou Thanatos, também possuem a finalidade de satisfação, mas esta satisfação só pode ser encontrada com a morte ou a volta do organismo ao estado inorgânico, tendo como objetivo final a autodestruição. As pulsões de morte possuem a mesma flexibilidade das pulsões de vida (ou libido), fazendo com que estes impulsos apareçam como brigas, incitação a guerras, perseguições, humor negro, humilhações, sarcasmos, etc. Muitos dos impulsos provenientes de Thanatos são reprimidos através do que os psicanalistas chamam de formações reativas; um exemplo pode ser encontrado em ditados populares, como “Não faça aos outros o que não gostaria que fizessem com você”.

Tanto as pulsões de vida como as pulsões de morte produzem ansiedade no Ego. A ansiedade pode ser entendida como um estado afetivo desagradável e, ao mesmo tempo, difícil de ter sua origem rastreada. Freud descreveu três tipos de ansiedade, a ansiedade neurótica, referente a um perigo não conhecido pelo ego e originado dos impulsos do Id (ex. uma entrevista de emprego com o futuro chefe), a ansiedade moral que provém de uma desavença entre o Ego e Superego (ex. tentações sexuais), e a ansiedade realista, relacionada a perigos eminentes (ex: caminhar em uma região

desconhecida). Podemos dizer, de um modo geral, que a ansiedade ajuda a preservar o Ego [Freud, 1933/1964], precipitando o mecanismo de repressão. Contudo, nem sempre ela é positiva, muitos conflitos pulsionais internos produzem uma ansiedade excessiva e patológica.

A partir do entendimento da dinâmica das pulsões, podemos continuar o raciocínio sobre o que Freud descreveu como fases do desenvolvimento da personalidade. Para os psicanalistas, o aparelho psíquico de um bebê recém-nascido é composto apenas pelo Id; o Ego e sua personalidade vem a se desenvolver posteriormente. Na teoria freudiana, os primeiros 5 anos de vida são os mais significativos na formação da personalidade, compreendendo três principais fases distintas: a fase oral, a fase anal e a fase fálica. Após estas três fases do desenvolvimento, a personalidade segue um período de latência, desenvolvendo-se de forma muito mais lenta até o fim da pré-adolescência, período em que, finalmente, a personalidade adquire sua maturidade durante o período genital, que irá reger a vida adulta. Diversas fixações em cada uma destas fases podem ocorrer, prejudicando a vida adulta.

A primeira fase do desenvolvimento da personalidade é a fase oral [Feist & Feist; Roberts, 2015, p.27]. Para um bebê, a boca é a primeira zona erógena: é através da boca que ele encontra satisfação de seus impulsos, saciando-os. Sua fome é saciada no seio da mãe, com o ato de sugar proporcionando prazer, sendo este seu objeto pulsional. No início, os bebês apenas sugam o seio e obtêm prazer em uma espécie de tentativa de incorporar o seio a seu corpo através da sucção: este período é referenciado como oral-receptivo. Com o passar do tempo, os bebês começam a experimentar a ansiedade, devido a horários restringindo sua alimentação, causando outros sentimentos como o de frustração: este período é referenciado como oral-sádico, produzindo reações como mordidas e choro. Neste período, podemos observar os bebês utilizando chupetas ou chupando o próprio dedo, caracterizando o desvio objetual da pulsão de Eros inconsciente, direcionando a energia a um objeto diferente. Fixações na fase oral estão relacionadas ao tabagismo, comer sem limites, morder canetas, chupar balas compulsivamente, etc.

Após a fase oral, a personalidade continua a se desenvolver, deslocando a zona erógena para a região anal com o início do treinamento esfinteriano. Durante o período anal inicial [Feist & Feist; Roberts, 2015, p.28], as crianças encontram satisfação destruindo e perdendo objetos e, também, produzindo comportamentos agressivos como resposta ao treinamento esfinteriano. No período anal final, as crianças começam a ter comportamentos mais amistosos em relação ao treinamento esfinteriano, muitas se gabam ao mostrar as fezes para os pais. Fixações na fase anal se caracterizam por pessoas que praticam o colecionismo, senso de limpeza excessivo e mesquinhez.

A fase fálica ocorre entre os 3 e 4 anos de idade, na qual o desenvolvimento da personalidade tem nos genitais a sua principal zona erógena. Durante esta fase ocorre o evento mais importante de todos no que diz respeito à personalidade, que os psicanalistas representam pela metáfora do complexo de Édipo [Freud, 1924/1961]. A fase fálica provém da dicotomia masculina e feminina, sendo que o complexo de Édipo ocorre de forma diferente nos meninos e nas meninas.

No que diz respeito ao complexo de Édipo nos meninos, ocorre uma identificação com o pai, na qual inconscientemente ele deseja ser o pai, desenvolvendo pulsões de Eros por sua mãe, tais desejos ainda não são contraditórios para o Ego, pois este ainda não está totalmente desenvolvido. Ao reconhecer a contradição destes desejos, ele abandona a ideia de ser o seu pai, mas mantém o desejo por sua mãe. Durante o complexo de Édipo, o menino passa por sentimentos de ambivalência, ele quer ser seu pai, mas percebe que não pode ser, desejando em fantasia destruí-lo para ficar com sua mãe. Estes sentimentos produzem o que Freud chamou de complexo de castração, um medo de ser repreendido pelo pai, fantasiado com a perda de seu órgão genital. Este complexo geralmente surge após o menino descobrir que as meninas não possuem um órgão genital igual ao dele, acreditando que as meninas já foram punidas por amar a mãe. Após o complexo de Édipo ser resolvido, as pulsões de Eros do menino pela mãe se transformam em amor, dando início ao desenvolvimento de um Superego.

A fase fálica nas meninas, no período inicial, se repete como na dos meninos, com pulsões de Eros pela mãe. Entretanto elas acabam por descobrir que não possuem um órgão genital igual do pai e passam a ter inveja deste genital, transformando as pulsões de Eros por sua mãe em pulsões de Thanatos (hostilidade), voltando as pulsões de Eros para seu pai. O complexo de Édipo feminino é mais complicado que o masculino, e também ocorre mais lentamente. Consequentemente o complexo de Édipo nas meninas desenvolve um Superego mais fraco comparado ao dos meninos. As fixações na fase fálica podem ocorrer no desenvolvimento posterior da personalidade, caracterizado na vida adulta por problemas relacionados à formação do Superego. Isto pode acarretar em problemas individuais relacionados às regras sociais e à identificação da sexualidade. A Tabela 2 descreve as principais diferenças entre a fase fálica e os complexos de Édipo masculinos e femininos.

<b>Fase fálica masculina</b>	<b>Fase fálica feminina</b>
<p>Complexo de Édipo.</p> <p>Pulsões de Eros (amor) pela mãe.</p> <p>Pulsões de Thanatos (hostilidade) pelo pai.</p>	<p>Complexo de Édipo.</p> <p>Pulsões de Eros pela mãe, seguida de hostilidade pela mãe.</p> <p>Em um segundo momento, pulsões de Eros pelo pai.</p>

Complexo de castração.	Inveja dos genitais masculinos.
Identificação com o pai.	Percepção mais gradual que os desejos edípicos são auto-destrutivos.
Superego forte substitui o complexo de Édipo.	Um superego mais fraco substitui o complexo de Édipo.

**Tabela 2.** As Fases fálicas masculina e feminina [Feist & Feist; Roberts, 2015, p. 31].

A partir do complexo de Édipo, a personalidade é classificada em três tipos distintos, de acordo com o mecanismo de defesa usado. O tipo neurótico usa repressão, suprimindo impulsos não adequados; o psicótico faz uso da forclusão, realizando fora os impulsos que devem ser reprimidos (o sujeito perde o contato com a realidade). O perverso se apoia na denegação, ou seja, algo que é inconcebível para o neurótico pode causar satisfação ao perverso. A Tabela 3 mostra as diferenças entre esses tipos de personalidade:

<b>Neurótico</b>	<b>Psicótico</b>	<b>Perverso</b>
Se divide em Neurose Obsessiva e Histeria.	Se divide em Esquizofrenia, Autismo e Paranoia.	Engloba muitas formas de manifestação como o Fetichismo, Maquiavelismo e Sadismo.
O mecanismo de defesa do Ego é a repressão. É tomado por sentimentos de culpa.	O mecanismo de defesa do Ego é a forclusão, através de uma cisão do ego e identificação projetiva.	O mecanismo de defesa do Ego é a denegação.
O Ego utiliza os mecanismos de defesa.	O Ego é dissociado, produzindo delírio.	O Ego ignora as leis da sociedade, o Superego acaba por exercer menos influência.
A neurose é a personalidade mais equilibrada, entretanto na patologia (histeria e obsessão) o indivíduo esconde de si mesmo os problemas.	Caracterizada pela distorção da realidade e falta de harmonia entre os pensamentos e afetos.	Caracterizado pelo Ego que permite que pulsões se satisfaçam, mesmo contrariando as normas impostas pela sociedade.
Recalca os conteúdos considerados ameaçadores pelo Ego.	Encontra fora o que exclui de dentro (Ego), e coloca dentro o que encontra fora criando uma realidade alternativa.	Denegação da angústia, psicopatia.

**Tabela 3.** Os tipos de personalidade da teoria psicanalítica.

Esta seção teve como objetivo fazer um breve e superficial resumo da teoria freudiana, este conhecimento é necessário para entender o funcionamento dos testes projetivos. Freud, através do método da livre associação, passou a estudar as manifestações do inconsciente. Ao formular a teoria psicanalítica, ele verificou que o consciente “escapa” pela linguagem, ou seja, no balbucio da fala, no relato de um sonho, na risada incansável de uma piada (chiste), quando se diz algo sem querer dizer (ato falho), é que são encontrados os pensamentos inconscientes, mas sempre eles são escondidos e disfarçados no discurso do sujeito. Para os psicanalistas o inconsciente é a chave para o entendimento das diferenças individuais da personalidade humana.

A partir da teoria psicanalítica, surgiram todas as outras teorias psicodinâmicas, e também diversas formas de se medir a personalidade através de testes que provocam um ataque à integridade do Ego, avaliando e mensurando a projeção inconsciente. Estes testes podem fazer o *by-pass* do mecanismo de censura, indo de encontro com o núcleo da personalidade do indivíduo.

O legado do inconsciente motivou o surgimento de outras teorias complementares da teoria psicanalítica, entre elas o inconsciente estruturado como uma linguagem, de Jacques Lacan, que vincula a psicanálise à lógica formal [Nasio, 1992].

### **2.1.2 Alfred Adler e a Psicologia Individual**

Alfred W. Adler (1870-1937) foi um médico austríaco, psicoterapeuta e fundador da escola de psicologia individual. Em suas considerações teóricas, postulou que são os sentimentos de inferioridade, os quais se instalam desde a mais tenra idade, que desempenham um papel fundamental no desenvolvimento da personalidade, por estimularem as pessoas a estabelecer objetivos para a superação desses mecanismos de frágil autoestima.

Adler fundou a Sociedade de Psicologia Individual em 1912, após sua ruptura com o movimento psicanalítico de Freud. As principais diferenças entre Adler e Freud centraram-se na alegação de Adler de que o aspecto social (exterioridade) é tão importante para a psicologia quanto o domínio interno (interioridade) e que o comportamento humano é moldado pela percepção subjetiva que as pessoas têm de si mesmas e pela força criativa que move a luta pelo sucesso. Para ele, a dinâmica do poder e da compensação vão além da sexualidade, e as questões de gênero e políticas são tão importantes quanto as da libido.

O interesse social (*Gemeinschaftsgefühl*) constitui um dos princípios básicos da teoria da personalidade de Adler por ser uma necessidade para a perpetuação da espécie humana. Segundo o psicoterapeuta austríaco, a expressão interesse social significa um sentimento de unidade com toda a humanidade que se manifesta como cooperação com os outros para o avanço social, e não apenas para o ganho pessoal [Adler, 1964]. Para Adler:

*“O interesse social é a única escala a ser usada no julgamento do valor de uma pessoa. Como barômetro da normalidade, ele é o padrão a ser usado na determinação da utilidade de uma vida. De acordo com o grau em que as pessoas possuem interesse social, elas são psicologicamente maduras. As pessoas imaturas que carecem de Gemeinschaftsgefühl, não são autocentradas e lutam pelo poder social e pela superioridade sobre os outros. Os indivíduos saudáveis são genuinamente preocupados com as pessoas e possuem um objetivo de sucesso que abrange o bem-estar de todos” [Feist &Feist; Roberts, 2014, p. 54].*

As aplicações da psicologia individual abrangem, principalmente, quatro áreas distintas: constelação familiar, lembranças precoces, sonhos e psicoterapia. Esses recursos são utilizados para estimular a coragem, a autoestima e o interesse social.

### **2.1.3 Jung e a Psicologia Analítica**

Carl Gustav Jung (1878-1961) é um psiquiatra suíço que rompeu com Freud e a psicologia ortodoxa para estabelecer uma teoria da personalidade distinta denominada psicologia analítica ou psicologia junguiana, a qual se baseia no pressuposto de que fenômenos ocultos influenciam a vida de todos. Conceitos importantes no sistema de Jung são a individuação, os símbolos, o inconsciente pessoal, o inconsciente coletivo, os arquétipos, os complexos, a persona, a sombra, a anima e o animus e o self [Jung 1954/1959a], [Jung 1954/1959b].

O conceito de inconsciente postulado por Jung é bem diferente do modelo proposto por Freud, apesar da grande influência que o fundador da psicanálise tinha sobre ele. Jung acreditava que somos motivados não somente por vivências reprimidas, mas também por experiências herdadas de nossos ancestrais. Essas imagens que nos revisitam do passado ancestral, Jung chamou de inconsciente coletivo, cujos conteúdos são herdados e transmitidos de uma geração para a seguinte como potencial psíquico. “As experiências dos ancestrais distantes com conceitos universais como Deus, mãe, água, terra, entre outros, foram transmitidos ao longo das gerações, de modo que as pessoas em todos os climas e tempos foram influenciados por experiências de ancestrais primitivos” [Feist &Feist; Roberts, 2014, p. 73]. A prova da existência do vasto inconsciente coletivo foi o conceito de sincronicidade de Jung, essa conexão inexplicável e misteriosa que todos compartilhamos.

O objetivo primordial da psicologia junguiana é a formação do “eu” através da individuação. Central para esse processo é o encontro do indivíduo com sua psique e a introdução de seus elementos



na consciência. Os seres humanos experimentam o inconsciente através de símbolos encontrados em todos os aspectos da vida: nos sonhos, na arte, na religião e nos dramas simbólicos que encenamos em nossos relacionamentos e atividades de vida. Essencial para este encontro numinoso é a fusão da consciência do indivíduo com a consciência coletiva através desta linguagem simbólica.

Alguns elementos do inconsciente coletivo são chamados de arquétipos [Jung 1954/1959a]. São similares aos complexos mas, enquanto os complexos constituem componentes individualizados do inconsciente pessoal, os arquétipos são imagens arcaicas generalizadas que derivam do inconsciente coletivo. Segundo Jung, os arquétipos também são diferentes dos instintos. Enquanto o instinto é um impulso físico inconsciente direcionado para a ação, o arquétipo é a contrapartida psíquica do instinto. Para diferenciar um fenômeno do outro, Jung esclarece:

*Assim como os animais do mesmo tipo apresentam os mesmos fenômenos instintivos no mundo inteiro, o homem também apresenta as mesmas formas arquetípicas, independentemente de onde vive. Assim como os animais não têm necessidade de aprender suas atividades instintivas, também o homem possui seus padrões físicos primordiais e os repete de modo espontâneo, seja qual for o tipo de instrução. Considerando que o homem consciente e capaz de introspecção, é bem possível que ele possa perceber seus padrões instintivos na forma de representações arquetípicas. [Jung, 1975, p. 152]*

Os sonhos [Jung, 1948/1969b] são a principal fonte de material arquetípico, visto que oferecem provas da existência do arquétipo, pois certos sonhos levantam questões que não são conhecidas pelo sonhador através da experiência pessoal. Ainda que Jung tenha atestado a existência de uma multiplicidade de arquétipos, ele conceitualizou apenas alguns entre eles, a *persona*, a sombra, a *anima*, o *animus*, a grande mãe, o sábio, o herói e o *self*.

Jung coletou dados para o desenvolvimento de suas teorias de extensas leituras em muitas disciplinas, mas também reuniu informações a partir do uso do teste de associação de palavras, da análise dos sonhos, da imaginação ativa e da psicoterapia. Apesar de que ele não foi o primeiro a utilizar o teste de associação de palavras, ele contribuiu para desenvolvê-lo e aprimorá-lo.

#### **2.1.4 Klein e a Teoria das Relações Objetais**

Melanie Klein (1882-1960), psicanalista austríaca, é considerada uma das fundadoras da teoria das relações objetais. Foi pioneira no uso da psicanálise tradicional com crianças pequenas e inovadora em suas teorias sobre o desenvolvimento infantil. Embora tenha iniciado seus estudos em práticas freudianas ortodoxas, introduziu modificações em sua prática terapêutica para adequá-la a sua própria orientação teórica.

Diferentemente de Freud, cujas ideias sobre as crianças provinham, principalmente, do seu trabalho com pacientes adultos, Klein inovou ao trabalhar diretamente com crianças. Ela via as brincadeiras como o principal modo de comunicação emocional das crianças. Depois de observar crianças problemáticas brincando com brinquedos como bonecas, animais, lápis e papel, ela tentou interpretar o significado específico do brincar.

Seguindo Freud, Klein enfatizou o papel significativo que as figuras parentais desempenhavam na vida de fantasia da criança. No entanto, ela estendeu a teoria psicanalítica além das fronteiras estabelecidas por Freud. Sua teoria das relações objetais foi construída a partir de observações de crianças pequenas. Enquanto Freud acreditava na relevância dos primeiros 4 a 6 anos no desenvolvimento infantil, Klein destacava a importância dos primeiros 4 a 6 meses: “para ela os bebês não começam a vida com uma tela em branco, mas com uma predisposição herdada de reduzir a ansiedade que experimentam em consequência do conflito produzido pelas forças do instinto de vida e instinto de morte” [Feist & Feist; Roberts, 2015, p. 96].

O trabalho teórico de Klein incorpora a crença de Freud na existência da "pulsão de morte", refletindo o fato de que todos os organismos vivos são inerentemente atraídos para um estado inorgânico e, portanto, num sentido não especificado, contêm um impulso para a morte. Em termos psicológicos, Eros (pulsão de vida) sustenta o princípio ou instinto da vida, e Thanatos (pulsão de morte) propaga o instinto da morte, ou seja, a força desintegradora da vida. Tanto Freud quanto Klein consideravam essas polaridades como os fundamentos da psique humana.

Klein acreditava que os bebês estão constantemente se engajando em um conflito básico entre o instinto de vida e o instinto de morte, ou seja, entre bom e mau, amor e ódio, criatividade e destruição. Na tentativa de lidar com essa dicotomia de bons e maus sentimentos, os bebês organizam suas experiências em posições (estágios de desenvolvimento) que, segundo Klein, são formas de lidar com os objetos internos e externos. As primeiras relações objetais são com o seio da mãe, mas “logo em seguida se desenvolve o interesse pelo rosto e pelas mãos, os quais atendem suas necessidades e as gratificam” [Klein, 1991, p. 757].

Klein se refere às experiências alternantes de gratificação e frustração da criança como o seio bom e o seio mau. Para controlar o seio bom e combater as frustrações, o bebê adota o que Klein denomina de posição esquizoparanóide [Klein, 1946/ 1975], uma forma de organizar as experiências que inclui os sentimentos paranoides de ser perseguido e uma divisão dos objetos internos e externos em bons ou maus. A posição esquizoparanóide é desenvolvida durante os primeiros 3 ou 4 meses de vida, durante os quais a percepção que o ego tem do mundo externo é subjetiva e fantástica, em vez de objetiva e real.

É em torno dos 5 ou 6 meses que a criança começa a ver os objetos externos como um todo, e a entender que o bom e o mau são passíveis de existir na mesma pessoa. Nessa época, a criança desenvolve uma imagem mais realista da mãe e a reconhecer que ela é uma pessoa independente que pode ser boa ou má. Este estágio foi denominado posição depressiva por Klein – a criança começa a perceber que o objeto amado e o objeto odiado são um único objeto.

A teoria das relações objetais na psicologia analítica diz respeito ao processo de desenvolvimento de uma psique em relação aos outros durante a infância. Com base na teoria psicodinâmica, a teoria das relações objetais sugere que a forma como as pessoas se relacionam com os outros e as situações em suas vidas adultas foram moldadas pelas experiências familiares durante a infância [Klein, 1959/ 1984]. Por exemplo, um adulto que sofreu negligência ou abuso na infância tem medo de se relacionar com pessoas que se assemelham ao pai negligente ou abusivo de seu passado. Essas imagens de pessoas e eventos se transformam em objetos no inconsciente que o "eu" carrega para a vida adulta, e são utilizados pelo inconsciente para prever o comportamento das pessoas em suas relações e interações sociais.

### **2.1.5 Horney e a Teoria Social Psicanalítica**

Karen Horney (1885-1952) foi uma psicanalista alemã que posteriormente trabalhou nos Estados. Suas teorias questionaram algumas visões freudianas tradicionais, principalmente as teorias da sexualidade de Freud. É considerada a fundadora da psicologia feminista em uma espécie de resposta à metáfora da teoria freudiana sobre a inveja das mulheres em relação ao falo (pênis) [Horney, 1917/1968]. Discordou de Freud sobre as diferenças inerentes à psicologia de homens e mulheres e, por conta disso, é frequentemente classificada como neo-freudiana.

Como muitos psicanalistas que nutriam ideias opostas daquelas preconizadas por Freud, Horney achava que o sexo e a agressão não eram os elementos primários para determinar a personalidade. Assim como Adler, acreditava que havia maiores influências na personalidade através

de ocorrências sociais durante a infância, ao invés de apenas pulsões sexuais reprimidas. Os dois se concentraram mais no papel desempenhado pela mente consciente na personalidade humana, ao invés de se limitarem apenas à repressão subconsciente.

A noção freudiana de "inveja do genital masculino" foi criticada por Horney. Ela admitiu que a inveja do genital masculino pode ocorrer ocasionalmente em mulheres neuróticas, mas afirmou que a "inveja do útero", ou seja, a inveja da capacidade da mulher de gerar filhos, também ocorre em homens. O grau em que os homens são levados ao sucesso pode ser meramente um substituto (disfarce pulsional) para o fato de que eles não podem conceber e gerar filhos. Horney reformulou alguns conceitos freudianos, apresentando uma visão holística e humanista da psique individual. Para ela, as diferenças psíquicas entre homens e mulheres não são apenas biológicas, mas são o resultado de construções sociais e culturais. Em uma palestra ministrada em 1935 em um clube para mulheres profissionais e de negócios, Horney resumiu suas ideias sobre a psicologia feminina:

*De uma vez por todas, devemos parar de nos importar com o que é feminino e com o que não é. Tais preocupações apenas minam as nossas energias. Os padrões de masculinidade e feminilidade são artificiais. Tudo o que definitivamente sabemos hoje acerca das diferenças sexuais é que não conhecemos quais são elas. Certamente existem diferenças científicas entre os dois sexos, mas nunca conseguiremos descobrir quais são elas até que desenvolvamos nossas potencialidades como seres humanos. Pode parecer paradoxal, mas descobriremos a respeito dessas diferenças somente se as esquecermos. [Horney, 1994, p. 238]*

Horney também apresentou estudos sobre a neurose sob uma luz diferente dos outros psicanalistas da época. Seu grande interesse pelo assunto resultou em novas proposições teóricas a partir de dados de seus pacientes. Ela postulou que a neurose era um processo contínuo ao longo da vida, e não uma disfunção da mente em resposta a estímulos externos, como luto, divórcio ou experiências negativas durante a infância e a adolescência. Fez questão de ressaltar que esses estímulos eram menos importantes do que as experiências negativas durante a infância que podem ter um efeito prejudicial no estado mental do indivíduo. De suas experiências como psiquiatra, Horney nomeou dez padrões de necessidades neuróticas. Essas dez necessidades são baseadas em coisas que ela achava que todos os humanos necessitam para ter sucesso na vida. O objetivo da psicoterapia horniana é promover o crescimento em direção à realização do *self* real. Essas questões continuam sendo amplamente debatidas por psicólogos contemporâneos.

### 2.1.6 Fromm e a Psicanálise Humanista

Erich Fromm (1900-1980) foi um psicólogo social americano nascido na Alemanha, psicanalista, sociólogo, filósofo humanista e socialista democrata. Foi um dos fundadores do Instituto William Allison White de Psiquiatria, Psicanálise e Psicologia na cidade de Nova York e é um representante de teoria crítica da Escola de Frankfurt.

Os escritos de Fromm eram notáveis tanto por seus comentários sociais e políticos quanto por seus fundamentos filosóficos e psicológicos. Sua obra, *Escape from Freedom (O medo à liberdade)* é considerada como uma das obras fundadoras da psicologia política. Seu segundo trabalho importante, *Man for Himself: An Inquiry into the Psychology of Ethics (Análise do homem: uma investigação sobre a psicologia da ética)*, publicado pela primeira vez em 1947, enriqueceu seu legado. Juntos, esses livros delinearam a teoria da natureza humana sintetizada pelo autor. O livro mais popular de Fromm, intitulado *The Art of Loving (A arte de amar)*, foi um best-seller internacional publicado em 1956, que recapitulou e complementou os princípios teóricos da natureza humana encontrados em suas primeiras obras – princípios esses que foram revisitados em muitas outras obras de Fromm.

A pedra angular da filosofia humanista de Fromm é sua interpretação da história bíblica do exílio de Adão e Eva do Jardim do Éden. Com base em seu conhecimento, Fromm destacou que ser capaz de distinguir entre o bem e o mal é geralmente considerado uma virtude, mas que os estudiosos bíblicos geralmente consideram que Adão e Eva pecaram desobedecendo a Deus e comendo da Árvore do Conhecimento. No entanto, partindo da ortodoxia religiosa tradicional sobre isso, Fromm exaltou as virtudes dos seres humanos tomando ações independentes e usando a razão para estabelecer valores morais em vez de deixar se escravizar por uma moral autoritária.

A tese básica de Fromm diz respeito ao fato de que nos tempos modernos o homem afastou-se de sua união com a natureza e de seus semelhantes. Ele ressalta que a carência de instintos e da intuição e o excesso de pensamento racional tornaram o homem um ente separado da natureza.

Apesar de que Fromm formou-se como um psicanalista freudiano ortodoxo, mais tarde ficou insatisfeito com as técnicas psicanalíticas tradicionais. A partir desse impasse passou a desenvolver seu próprio sistema de terapia, o qual chamou de psicanálise humanista. Sua preocupação era desenvolver aspectos interpessoais no encontro terapêutico, visto que acreditava que a finalidade da

terapia era o autoconhecimento dos pacientes: se não conhecermos a nós mesmos, não será possível conhecer outras pessoas ou coisas.

Para ele, a terapia deveria ser construída sobre uma relação pessoal entre terapeuta e paciente. Como a comunicação interpessoal é essencial para o crescimento terapêutico, o psicoterapeuta deve se relacionar “como um ser humano com outro, com absoluta concentração e sinceridade” [Fromm, 1963, p. 184]. Para atingir a comunicação compartilhada, Fromm trabalhava com a interpretação de sonhos. Ele estava convencido de que os sonhos, assim como os contos de fadas e os mitos, são expressos em linguagem simbólica e, portanto, universal [Fromm, 1951]. Como os significados dos sonhos vão além do sonhador, Fromm solicitava aos seus pacientes para fazerem associações com o material onírico.

Fromm reuniu dados sobre a personalidade humana a partir de muitas fontes, incluindo a psicoterapia, a antropologia cultural e a psico-história. Para ele, os pacientes procuram a terapia buscando a satisfação de suas necessidades básicas, tais como: ligação, transcendência, enraizamento, sentimento de identidade e estrutura de orientação. Essas necessidades exclusivamente humanas movem as pessoas a estabelecer novamente a comunhão com a natureza que constitui o objetivo básico da terapia de Fromm.

### **2.1.7 Eickson e a Teoria Pós-Freudiana**

Erik Erikson (1902-1994) foi um psicólogo germano-americano e psicanalista conhecido por sua teoria sobre o desenvolvimento psicológico de seres humanos. Ele tornou-se famoso por ter cunhado a expressão crise de identidade. Apesar de não ter um diploma de bacharel, Erikson atuou como professor em importantes instituições, incluindo Harvard e Yale. Uma pesquisa da revista *General Psychology*, publicada em 2002, classificou Erikson como o 12º psicólogo mais citado do mundo.

Uma das principais contribuições de Erikson foi estudar o desenvolvimento da personalidade até a idade adulta e apontar os diversos estágios do de crescimento psicossocial. Durante cada estágio, as pessoas experimentam crises psicossociais e a resolução dessas crises produz uma força básica que possibilita que a pessoa avance para o estágio seguinte:

*Ao expandir a noção de Freud do desenvolvimento até a velhice, Erikson desafiou a ideia de que o desenvolvimento psicológico termina coma infância. O legado mais influente de Erikson foi sua teoria do desenvolvimento e, em particular, os estágios desde*

*a adolescência até a velhice. Ele foi um dos primeiros a enfatizar o período crítico da adolescência e os conflitos associados por uma busca da identidade. [Feist & Feist; Roberts, 2015, p. 162]*

Diferentemente de Freud que postulava que a anatomia é destino, Erikson acreditava que “Anatomia, história e personalidade são nosso destino combinado” (Erikson, 1968, p. 285). Em outras palavras, a anatomia por si só não determina o destino, pois ela se combina com a nossa história pregressa, com dimensões sociais e com vários aspectos da personalidade, entre elas o temperamento e a inteligência.

## **2.2 Teorias Humanistas Existenciais**

Estas teorias ganharam muitos adeptos nos anos 50 e 60 e foram uma resposta e crítica as teorias do comportamento (behavioristas) e psicodinâmicas. Os humanistas criticaram a existência do inconsciente e o determinismo postulado nas teorias psicodinâmicas. Também criticaram a ideia de um ser humano se aproximar de um animal de comportamentos condicionados e operantes. Os humanistas tentam conhecer melhor o ser humano, com uma visão mais otimista e existencialista.

As próximas subseções fazem um apanhado geral das teorias humanistas existências.

### **2.2.1 Maslow e a Teoria Holístico-Dinâmica**

Abraham Maslow (1908-1970), psicólogo americano, professor de psicologia em diversas universidades americanas, ficou conhecido por criar uma teoria baseada numa hierarquia de necessidades humanas. Sua teoria da personalidade foi chamada de humanista, no entanto, Maslow preferia referir-se a ela como teoria holístico-dinâmica, porque acreditava no desenvolvimento da pessoa como um todo; o indivíduo está constantemente sendo motivado por uma necessidade ou outra e têm potencial para crescer em direção à saúde psicológica, ou seja, à autorrealização. Para atingir esse objetivo, é preciso, em primeiro lugar, satisfazer as necessidades básicas, como a fome, a sede, a segurança, o amor e o pertencimento. Somente depois de satisfeitas essas necessidades, o indivíduo poderá alcançar a autorrealização. Estas necessidades foram hierarquizadas por Maslow na forma de uma pirâmide, com as mais básicas na base e as mais eruditas no topo.

Para Maslow, a psicoterapia deve ser direcionada para o nível de necessidade frustrado, na maioria dos casos as necessidades de amor e pertencimento. Maslow concordava com Allport que a ciência psicológica deveria colocar mais ênfase no estudo do indivíduo e menos destaque na análise de grupos sociais. “Os relatos subjetivos deveriam ser favorecidos em relação aos rigidamente

objetivos, e deveria ser permitido que as pessoas falassem sobre si mesmas de uma forma holística, em vez da abordagem mais ortodoxa que estuda os indivíduos por partes” (Feist & Feist; Roberts, 2015, p. 183).

### **2.2.2 Rogers e a Teoria Centrada na Pessoa**

Carl Rogers (1902-1987), psicólogo americano, foi um dos fundadores da abordagem humanista. Suas pesquisas sobre a personalidade e as relações humanas encontraram ampla aplicação em vários domínios, como na psicoterapia (terapia centrada na pessoa) e na educação (aprendizagem centrada no aluno). Para ele, a busca de objetivos e o estabelecimento de metas são elementos primordiais no desenvolvimento da personalidade.

Rogers propôs que o pilar da saúde mental era a congruência entre como de fato nos vemos, e como idealmente gostaríamos de ser. Se estas duas autoavaliações forem congruentes, então a pessoa está relativamente adaptada e sadia. Em caso contrário, a pessoa experimenta várias formas de desconforto mental, como ansiedade, depressão e baixa autoestima. *“De acordo com Rogers, uma fonte de sofrimento psicológico é a incongruência, ou quando o self ideal da pessoa não corresponde suficientemente a seu autoconceito, e essa incongruência pode ser representada nos objetivos que a pessoa escolhe perseguir”* (Feist& Feist; Roberts, 2015, p. 208). Assim como muitos outros teóricos da personalidade, Rogers construiu sua teoria sobre as bases proporcionadas pelas suas experiências como terapeuta.

### **2.2.3 May e a Psicologia Existencial**

Rollo May (1909-1994) foi um psicólogo existencial americano e autor do livro influente, publicado em 1969, intitulado *Eros e repressão: amor e vontade (Love and Will)*. Frequentemente associado à psicologia humanista e à filosofia existencialista, ele foi um dos principais proponentes da psicoterapia existencial. Sua ênfase na fenomenologia implica em percepções individuais e, portanto, personalidades únicas.

As teorias de May são embasadas pelos princípios básicos do existencialismo (Sartre, Kierkegaard, Heidegger), entre eles de que *a existência precede a essência*, ou seja, o que as pessoas fazem é mais importante do que o que elas são; que a unidade entre as pessoas e seu mundo



fenomenológico é expressa pelo termo *Dasein*, ou *ser-no-mundo*; e que o *não-ser* ou *o nada* é uma consciência da possibilidade de *não-ser* por meio da morte ou da perda da consciência. A partir desses pressupostos, as pessoas experimentam ansiedade quando tomam consciência da possibilidade de *não-ser*, bem como quando chegam ao entendimento de que são livres para escolher. Sua visão de humanidade é mais ampla e mais profunda do que o modo de ver da maioria dos teóricos que abordam a personalidade humana.

## 2.3 Teorias Disposicionais

As teorias disposicionais são as teorias mais utilizadas nos modelos de TB-APR. Estas teorias partem do princípio que os seres humanos possuem traços de personalidade que são comuns a todos indivíduos e também traços que são únicos a cada indivíduo.

O inventário BigFive, amplamente o mais utilizado para rotular *corpora* utilizados na construção de modelos de TB-APR se baseia nestas teorias. Estes traços são calculados por redução fatorial através do seguinte método [Feist& Feist; Roberts, 2015, p.255]:

- 1) São feitas observações específicas em muitos indivíduos, vamos supor 5.000 indivíduos e 1000 observações.
- 2) É determinado quais observações estão relacionadas e em que medida, calculando a correlação do score de cada variável e os outros 999 scores das outras variáveis, resultando em um total de 499.500 correlações individuais ( $999 * 1000 / 2$ ). Estes cálculos demandam uma matriz com 1000 linhas e 1000 colunas.
- 3) A matriz é muito grande e complicada, é necessário fazer uma redução do espaço.
- 4) Os traços nada mais são do que a redução deste espaço de correlações em uma análise fatorial, em que o traço ou fator explica um grande número de variáveis. As correlações dos scores individuais e fatores são chamadas de cargas fatoriais que apontam a pureza dos fatores.

Separamos, nas próximas sub-seções, um breve resumo das principais teorias disposicionais.

### 2.3.1 Allport e a Psicologia do Indivíduo

Gordon Allport (1897-1967) foi um dos primeiros psicólogos norte-americanos a se concentrar no estudo da personalidade. Para ele, a singularidade de cada indivíduo e o contexto atual eram mais importantes do que a história passada para entender a personalidade. Allport teve uma

influência profunda e duradoura no campo da psicologia, e parte de sua influência resultou de sua habilidade para explorar e conceituar tópicos importantes e interessantes (por exemplo, boatos, preconceitos, religião, traços).

As visões psicanalítica e comportamental de humanidade foram rejeitadas por Allport por serem excessivamente deterministas e mecanicistas. Para ele, as estruturas mais importantes da personalidade são aquelas que permitem a descrição da pessoa em termos das características individuais, as quais denominou de disposições pessoais. “Ele acreditava que o nosso destino e nossos traços não são determinados por motivos inconscientes que se originaram na infância, mas por escolhas conscientes que fazemos no presente” (Feist & Feist; Roberts, 2015, p 249).

### **2.3.2 McRae e Costa e a Teoria dos Cinco Fatores**

Robert McCrae (n. 1949) e Paul Costa (n. 1942) são os criadores da Teoria dos Cinco Fatores da Personalidade (*Big Five*). Os criadores do método defendem que a personalidade de uma pessoa pode ser compreendida a partir de cinco fatores: neuroticismo, extroversão, conscienciosidade, amabilidade e abertura à experiência.

A teoria dos cinco fatores postula que traços de personalidade são construídos como tendências básicas que estão enraizadas na biologia e que interagem com influências externas, incluindo a cultura, na formação de habilidades, hábitos, gostos e valores do indivíduo. McRae e Costa colocaram a mesma ênfase nas influências biológicas e ambientais no que se refere à personalidade. Eles desenvolveram um inventário da personalidade amplamente utilizado, denominado NEO-PI, que mostra “um alto nível de estabilidade nos fatores da personalidade conforme as pessoas avançam dos 30 anos até a velhice” (Feist& Feist; Roberts, 2015, p. 267). A grande maioria dos modelos de TB-APR se baseiam nesta teoria.

## **2.4 Teorias Biológicas Evolucionistas**

Estas teorias possuem forte embasamento genético utilizando constructos teóricos apoiados pela teoria evolucionista, não descartando e admitindo algumas dinâmicas inconscientes no aparelho psíquico. A técnica de redução fatorial também foi bastante utilizada nestas teorias e o modelo dos três fatores de Eysenk (extroversão, neuroticismo e psicotismo) já foi explorado em TB-APR (Seção 6.2).

Reservamos as próximas sub-seções para detalhar algumas destas teorias.

### **2.4.1 Eysenck e a Teoria dos Fatores de Base Biológica**

Hans Eysenck (1916-1997), psicólogo inglês de origem alemã, exerceu sua carreira profissional na Grã-Bretanha. É mais conhecido por seu trabalho a respeito da inteligência e da personalidade, embora tenha atuado em diversos campos da psicologia.

Em 1951, o primeiro estudo empírico de Eysenck sobre a genética da personalidade foi publicado. Foi uma investigação realizada com seu aluno e associado Donald Prell, na qual gêmeos idênticos (monozigóticos) e fraternos (dizigóticos), com idades entre 11 e 12 anos, foram testados quanto ao neuroticismo. Os resultados são descritos em detalhes em um artigo publicado no *Journal of Mental Science*. Eysenck e Prell concluíram que o fator do neuroticismo constitui uma unidade biológica que é herdada como um todo, ou seja, que a predisposição neurótica em grande parte determinada hereditariamente.

A principal força do modelo de Eysenck era fornecer uma teoria detalhada das circunstâncias que influenciam a personalidade: *“Na questão dos determinantes conscientes versus inconscientes do comportamento, a abordagem de Eysenck se inclina para os determinantes inconscientes, uma vez que as pessoas são, sobretudo, incapazes de ter consciência de como a genética e os processos cerebrais afetam seu comportamento e sua personalidade”* (Feist& Feist; Roberts, 2015, p. 283).

As duas dimensões da personalidade, a extroversão e o neuroticismo, foram descritas em seu livro *Dimensões da personalidade (Dimensions of Personality)* de 1967. É prática comum na psicologia da personalidade referir-se a essas dimensões pelas primeiras letras, E e N, as quais forneceram um espaço bidimensional para descrever diferenças individuais de comportamento. Eysenck observou que essas duas dimensões eram semelhantes aos quatro tipos de personalidade propostos pelo médico grego Galeno: alto N e alto E = tipo colérico; alto N e baixo E = tipo melancólico; baixo N e alto E = tipo sanguíneo; baixo N e baixo E = tipo fleumático. Com base em colaborações entre Eysenck e sua esposa, Sybil Eysenck, a terceira dimensão, denominada psicoticismo, foi adicionada ao modelo no final dos anos 1970. Eysenck estimou que três quartos das variações de todas as três dimensões da personalidade podem ser explicadas pela hereditariedade, e aproximadamente um quarto pelos fatores ambientais.

### **2.4.2 Buss e a Teoria Evolucionista de Personalidade**

David Buss (n. 1953) é professor de psicologia na Universidade do Texas em Austin, conhecido por sua pesquisa em psicologia evolutiva sobre as diferenças entre os sexos masculino e feminino. Buss postula que homens e mulheres enfrentaram diferentes desafios adaptativos no

processo evolutivo, os quais são responsáveis e moldam as diferenças comportamentais hoje. Para fundamentar suas teorias sobre o processo evolutivo de homens e mulheres realizou pesquisas focadas em estratégias diferenciadas no processo de acasalamento. Em um estudo transcultural que incluiu 10.047 indivíduos em 37 culturas, Buss procurou primeiro determinar as diferentes características que cada sexo procura em um parceiro. A partir desses dados, foi capaz de levantar a hipótese das causas evolutivas dessas diferenças. Ele verificou que os homens atribuem grande importância à juventude que sinaliza a fertilidade, buscando maximizar o número de parceiras capazes de transmitir seus genes. Por outro lado, as mulheres desejam companheiros mais velhos de status social mais elevado para garantir mais recursos para elas e sua prole.

A psicologia evolucionista, em geral, e a psicologia evolucionista da personalidade, em particular, geraram muitas controvérsias, mas também conduziram a inúmeras pesquisas empíricas. Entre as visões da psicologia evolucionista, prevalece aquela que se apoia no aspecto determinista e explica o comportamento em termos de um passado evolutivo e de influências genéticas. No entanto, a teoria evolutiva criada por Buss preconiza que as explicações biológicas e ambientais não são mutuamente excludentes. Na verdade, ambas são necessárias, visto que o conhecimento e a consciência de nossos mecanismos psicológicos e estratégias evoluídas nos dão mais poder de modificá-las se assim desejarmos (Buss, 1999).

## **2.5 Teorias Cognitivistas e da Aprendizagem**

Estas teorias nasceram em contraposição as teorias psicodinâmicas. Partindo dos estudos de Ian Palov, e do método experimental, Skinner o autor o pioneiro destas teorias verificou que os comportamentos dos animais são análogos a uma função matemática, em que dada uma entrada estímulo, é produzida uma resposta. Estas funções foram detalhadas por estes teóricos.

As próximas subseções fazem um apanhado geral das principais teorias cognitivas e da aprendizagem.

### **2.5.1 Skinner e a Análise do Comportamento**

B. F. Skinner (1904-1990), era um psicólogo americano, behaviorista e filósofo social. Skinner considerou o livre-arbítrio uma ilusão e postulou que as ações humanas são dependentes de consequências geradas por ações anteriores. Se os resultados dessas ações forem ruins, há uma grande chance de não se repetirem; e se os resultados forem bons, a probabilidade de se repetirem torna-se

mais forte. Skinner denominou esse fenômeno de princípio de reforço. Argumentou que as contingências de reforço, principalmente aquelas que moldaram a cultura humana, explicam uma grande parte dos comportamentos humanos:

*Podemos rastrear uma pequena parte do comportamento humano...até na seleção natural e na evolução da espécie, mas a maior parte do comportamento humano deve ser rastreada até as contingências de reforço, em especial as contingências sociais muito complexas que chamamos de culturas. Somente quando levamos essas histórias em consideração, é que podemos explicar por que as pessoas se comportam da forma como se comportam.*  
[Skinner, 1989a, p. 18]

Skinner é considerado um pioneiro do behaviorismo moderno, junto com John Watson e Ivan Pavlov. Suas pesquisas experimentais para a análise do comportamento foram rotuladas de behaviorismo radical. Como behaviorista radical, Skinner rejeitava a noção de um repositório de ideias ou emoções inconscientes. Acreditava que condicionamentos operantes a partir de estímulos positivos ou negativos geram processos de mudança de comportamentos. Assim, “*mesmo acreditando que a genética desempenha um papel importante no desenvolvimento da personalidade, Skinner sustentava que a personalidade humana é moldada, em grande parte, pelo ambiente*” (Feist & Feist; Roberts, 2015, p. 326).

### **2.5.2 Bandura e a Teoria Social Cognitiva**

Albert Bandura (n.1925) é um psicólogo que transita entre o behaviorismo e a psicologia cognitiva. Por quase seis décadas, contribuiu para o campo da educação e outros campos da psicologia da personalidade. Sua teoria social cognitiva defende a premissa de que as pessoas aprendem através da observação de outros:

*Um dos primeiros e mais básicos pressupostos da teoria social cognitiva de Bandura é que os humanos são muito flexíveis e capazes de aprender inúmeras atitudes, habilidades e comportamentos e que boa parte dessas aprendizagens são*

*resultados de experiências vicariantes. Ainda que as pessoas possam aprender e aprendam com a experiência direta, muito do que elas aprendem é adquirido por meio da observação dos outros.* [Feist & Feist; Roberts, 2015, p. 330].

Bandura percebeu a importância de confiar em si mesmo, mecanismo que denominou de autoeficácia. Acreditava que as crenças das pessoas em sua eficácia pessoal influenciam o curso da ação que escolhem seguir, “o quanto de esforço irão investir nas atividades, por quanto tempo irão perseverar em face de obstáculos e experiências de fracasso e sua resiliência após contratempos” (Bandura, 1994, p. 65). Sua terapia enfatiza a mediação cognitiva, em especial a autoeficácia percebida.

### **2.5.3 Rotter e Mischel e a Teoria da Aprendizagem Social Cognitiva**

Julian Rotter (1916-2014), psicólogo americano, ficou conhecido por afastar-se da psicanálise e do behaviorismo e desenvolver a teoria de aprendizagem social cognitiva, e Walter Mischel (n. 1930), psicólogo austríaco de nascimento, especializou-se em teorias da personalidade e em psicologia social nos Estados Unidos. Rotter e Mischel veem as pessoas como seres cognitivos, cujas percepções dos eventos são mais importantes que os próprios eventos. Acreditam que “as pessoas são capazes de interpretar os eventos de várias maneiras, e essas percepções cognitivas tendem a ser geralmente mais influentes do que o ambiente na determinação do valor do reforçador” (Feist & Feist; Roberts, 2015, p. 372). Isso significa que ambos discordam da explicação de Skinner de que o comportamento é moldado pelo reforço imediato e, em vez disso, sugerem que as expectativas que o indivíduo tem em relação aos eventos futuros são os determinantes principais do desempenho comportamental.

A teoria social cognitiva de Mischel tem muito em comum com a teoria social cognitiva de Bandura e a teoria da aprendizagem social de Rotter. Rotter argumenta que o comportamento humano é previsto de forma mais adequada a partir da interação das pessoas com seus ambientes significativos. “Como interacionista, ele acredita que nem o ambiente, nem o indivíduo é completamente responsável pelo comportamento. Em vez disso, ele sustenta que as cognições das pessoas, a história passada e as expectativas do futuro são a chave para a previsão do comportamento” (Feist & Feist; Roberts, 2015, p. 350). O método de Rotter de psicoterapia visa a mudança de objetivos e a eliminação de expectativas baixas.

A teoria de Mischel é baseada no pressuposto de que os pensamentos e outros processos cognitivos interagem com uma situação particular para determinar o comportamento. Mischel destacou que

*[...] toda situação apresenta um grande número de potencial do comportamento, mas a forma como as pessoas se comportam depende de suas expectativas e crenças específicas sobre as consequências de cada uma das diferentes possibilidades de comportamento. O conhecimento de hipóteses ou crenças das pessoas, referentes ao resultado de uma situação, é um preditor mais precioso do comportamento do que o conhecimento de sua capacidade de desempenho. [Mischel et al., 2002].*

As teorias da aprendizagem social cognitivas de Rotter e Mischel procuram sintetizar os pontos fortes da teoria do reforço com os da teoria cognitivista.

#### **2.5.4 Kelly e a Teoria dos Constructos Pessoais**

George Kelly (1905-1967), psicólogo americano, foi terapeuta, educador e teórico da personalidade. Ele é considerado o pai da psicologia do construto pessoal. Kelly iniciou suas pesquisas “com o pressuposto de que o universo realmente existe e funciona como uma unidade integral, com todas as partes interagindo com precisão entre si. Além do mais, o universo está constantemente mudando, portanto, algo está acontecendo o tempo todo. Somada a esses pressupostos básicos está a noção de que os pensamentos das pessoas também existem, de fato, e que elas se esforçam para compreender seu mundo em constante mudança. Pessoas diferentes interpretam a realidade de maneiras distintas, e a mesma pessoa é capaz de mudar sua própria visão de mundo” (Feist & Feist; Roberts, 2015, p. 377).

Nesse sentido, a visão fundamental sobre a personalidade de Kelly era que as pessoas veem o mundo através de uma lente particular. Kelly referiu-se a tais interpretações como construtos pessoais: como as pessoas possuem repertórios de experiências diferentes, elas interpretam o mesmo evento de maneiras diferentes e, devido às diferenças individuais, apesar de que as experiências podem ser compartilhadas, a comunicação nunca é perfeita (Kelly, 1955).

## 2.6 Desordens de Personalidade

Entendemos os transtornos de personalidade como um tipo específico de transtorno mental, caracterizado por "*um padrão persistente de experiência interior e comportamento que se desvia nitidamente das expectativas da cultura do indivíduo; é difuso e inflexível, começa na adolescência ou início da idade adulta, e é estável ao longo do tempo e leva ao sofrimento ou dano*" [DSM-V, p. 645]. De acordo com dados da Pesquisa Nacional Epidemiológica sobre Álcool e Condições Relacionadas de 2000 a 2001, estima-se que 15% da população adulta nos EUA possa apresentar algum distúrbio de personalidade [DSM-V, p. 646].

Sabemos que nas várias teorias psicológicas, classificações taxonômicas e definições de tipos de personalidade variam subjetivamente de acordo com a percepção do seu criador, porém com o apoio de uma equipe multidisciplinar para o diagnóstico correto do indivíduo, é senso comum que os transtornos de personalidade possuem uma classificação única aceita por todos os profissionais. Embora as várias taxonomias de personalidade estudadas nas teorias psicológicas sejam de grande utilidade, muitas delas referem-se aos diferentes tipos de personalidade da população saudável, e mesmo aquelas relativas a populações clínicas não são amplamente aceitas por todos os teóricos e profissionais.

Para que uma classificação única de tipos de personalidade seja possível, existem instituições responsáveis pela formação de comitês multidisciplinares de profissionais responsáveis por criar a taxonomia dos vários transtornos de personalidade, por meio do reconhecimento, aceitação e consenso de todos. Há um grande esforço desses comitês para serem atóricos, tal esforço pode ser exemplificado pela escolha do termo transtorno de personalidade: "Assim, uma abordagem descritiva e atórica foi adotada juntamente com critérios diagnósticos operatórios. Como consequência, é provável que o termo transtorno tenha sido usado em vez de doença ou patologia, porque esses termos corriam o risco de serem considerados excessivamente centrados na área médica, ligados a uma teoria biológica sobre etiologia. Pelo contrário, o termo desordem foi geral o suficiente e atórico para ser amplamente aceito" [Argona, 2017]. Como a classificação deve ser atórica, esses comitês contam com os pilares da experiência clínica, pesquisa acadêmica e métodos estatísticos, estabelecendo critérios para diagnósticos simplificados, úteis e objetivos, com delimitação de limites bem definidos. O produto final, através do consenso do comitê, é a criação de um manual de diagnóstico.

Os manuais utilizados para a classificação dos transtornos de personalidade são a Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde (ICD), que é regulada pela Organização Mundial da Saúde (OMS) e pelo Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM), regulados pela Associação Americana de Psiquiatria (APA). O ICD



classifica os mais diversos tipos de doenças, incluindo transtornos de personalidade, e possui os códigos internacionalmente aceitos para o diagnóstico do paciente. Os códigos IDC são de grande importância, pois são utilizados em atestados médicos e relatórios, preservando a imagem do paciente com a patologia. A versão mais usada atualmente é a IDC-10, aprovada pela OMS em 1990. Os EUA usam uma modificação clínica que compila essa versão chamada IDC-10-CM. Os códigos IDC-10 para transtornos de personalidade variam de F60.0 a F60.9 (CID-10, 2004, p. 111). Esses mesmos códigos e nomenclaturas são utilizados pelo manual do DSM, que estabelece critérios muito mais completos, específicos e seguros para o diagnóstico de transtornos mentais, preenchendo a lacuna da falta de especificidade do IDC nessa questão.

A primeira versão do DSM remonta a mais de 60 anos (1952). Após a versão inicial, o DSM foi remodelado várias vezes, acompanhando sempre o progresso científico da psicologia e da psiquiatria. A quarta versão do manual [DSM-IV, 1994] ainda é amplamente utilizada; esta versão diagnostica a saúde mental em cinco eixos múltiplos. O primeiro eixo diagnostica as síndromes clínicas e, o segundo, os transtornos de personalidade. O terceiro eixo expõe as condições médicas gerais e o quarto engloba problemas psicossociais e ambientais relacionados. Finalmente, o quinto eixo faz uso de uma função global de mecanismo psicológico, que usa uma escala chamada Avaliação Global de Funcionamento (GAF) que vai de 0 a 100. A quinta e atual versão do DSM [DSM-V, 2013] está gradualmente substituindo a DSM-IV, esta versão abandonou o diagnóstico em múltiplos eixos, simplificando o processo de diagnóstico na tentativa de eliminar distinções artificiais entre patologias. O DSM-V combina os três primeiros eixos do DSM-IV em um único, contendo todos os transtornos mentais e fatores biológicos relacionados, enquanto o quarto eixo é representado pelos códigos V do CID-9-CM V ou pelos códigos Z do CID-10-CM. No DSM-IV, a escala GAF (quinto eixo DSM-IV) foi completamente abandonada devido à falta de comprovação científica de sua utilidade pelo comitê responsável.

Abaixo, temos um exemplo de classificação de transtorno mental em múltiplos eixos do DSM-IV utilizando códigos do ICD-9-CM e, em seguida, o mesmo exemplo é replicado utilizando a metodologia do DSM-V com códigos do ICD-10-CM:

#### 1. DSM IV

- a. Eixo I: 300.21 Desordem do pânico.
- b. Eixo II: 301.6 Desordem de personalidade dependente.
- c. Eixo III: 250.0 Diabetes *mellitus*, sem complicações.
- d. Eixo IV: V62.29 Problemas relacionados ao desemprego
- e. Eixo V: GAF = 52

#### 2. DSM V

F40.0 Desordem do pânico com agorafobia; F60.7 Desordem de personalidade dependente; E11.9 Diabetes mellitus, sem dependência de insulina; Z56.0 Desemprego.

Segundo o manual DSM-V, a correta definição geral de transtorno de personalidade é a seguinte:

*[...]um padrão persistente de experiência interna e comportamento que se desvia acentuadamente das expectativas da cultura do indivíduo, é difuso e inflexível, começa na adolescência ou no início da fase adulta, é estável ao longo do tempo e leva ao sofrimento ou prejuízo. [DSM-V, p. 645].*

O DSM-V aceita dois modelos distintos de diagnóstico de transtorno de personalidade. O primeiro modelo, considera cada transtorno de personalidade uma patologia distinta, este modelo preserva práticas de diagnóstico tradicionais [DSM-V pp. 645 - 684]. O segundo modelo possui um sistema dimensional de traços patológicos da personalidade, uma proposta de diagnóstico alternativo mais moderna e flexível [DSM-V pp. 761-781]. Este segundo modelo será explorado no próximo capítulo que diz respeito aos instrumentos psicométricos de avaliação da personalidade.

A seguir, segue o detalhamento dos transtornos de personalidade especificados no modelo de diagnóstico tradicional do DSM-V [DSM-V, p. 646]. Os códigos relativos ao manual IDC-10 de cada patologia estão indicados entre parênteses:

1. O grupo A contém três transtornos de personalidade em que se encaixam os indivíduos que possuem traços estranhos ou bizarros:
  - a. Transtorno de personalidade paranoide (F60.0) é um padrão desconfiança, em que as motivações dos outros são interpretadas como malévolas.
  - b. Transtorno de personalidade esquizoide (F60.1) é um padrão de distanciamento das relações sociais com uma faixa restrita de expressão emocional.
  - c. Transtorno de personalidade esquizotípica (F60.2) é um padrão de desconforto agudo nas relações íntimas, com distorções cognitivas ou perceptivas e excentricidades de comportamentos.
2. O grupo B contém quatro transtornos de personalidade, em que os indivíduos possuem traços dramáticos ou instáveis:
  - a. Transtorno de Personalidade antissocial (F60.2) é um padrão de desrespeito e violação dos direitos dos outros.

- b. Transtorno de personalidade borderline (F60.3) é um padrão de instabilidade nas relações interpessoais, na autoimagem e nos afetos, com impulsividade acentuada.
  - c. Transtorno de personalidade histriônica (F60.4) é um padrão de emocionalidade e busca de atenção em excesso.
  - d. Transtorno de personalidade narcisista (F60.81) é um padrão de grandiosidade, necessidade de admiração e falta de empatia.
3. O grupo C contém três transtornos de personalidade em que os indivíduos possuem traços de personalidade inseguros e ansiosos.
- a. Transtorno de personalidade Evitativa (F60.6) é um padrão de inibição social, sentimentos de inadequação e hipersensibilidade a avaliação negativa.
  - b. Transtorno de personalidade Dependente (F60.7) é um padrão de comportamento submisso e apegado relacionado a uma necessidade excessiva de ser cuidado.
  - c. Transtorno de personalidade Obsessivo-compulsivo (F60.5) é um padrão de preocupação com ordem, perfeccionismo e controle.
4. Fora de qualquer grupo, existem, ainda, duas classificações possíveis para um transtorno de personalidade:
- a. Transtorno da personalidade especificado (F60.89), os critérios gerais para um transtorno de personalidade são atendidos, podem estar presentes traços de vários transtornos de personalidade, mas não se atende a todos os critérios de nenhum transtorno de personalidade específico.
  - b. Transtorno da personalidade não especificado (F60.9), os critérios gerais para um transtorno de personalidade são atendidos, considerando que ele tem um transtorno de personalidade que não faz parte da classificação do DSM-V.

O modelo de diagnóstico de transtornos de personalidade do DSM-V estabelece 6 critérios gerais que avaliam a existência de algum transtorno de personalidade de forma geral, estes critérios são listados a seguir [DSM-V pp. 646-647]:

1. *“Um padrão persistente de experiência interna e comportamento que se desvia acentuadamente das expectativas da cultura do indivíduo. Esse padrão manifesta-se em duas (ou mais) das seguintes áreas: 1. Cognição (i.e., formas de perceber e interpretar a si mesmo, outras pessoas e eventos). 2. Afetividade (i.e., variação, intensidade, labilidade e adequação da resposta emocional). 3. Funcionamento interpessoal. 4. Controle de impulsos”.*
2. *“O padrão persistente é inflexível e abrange uma faixa ampla de situações pessoais e sociais”.*

3. *“O padrão persistente provoca sofrimento clinicamente significativo e prejuízo no funcionamento social, profissional ou em outras áreas importantes da vida do indivíduo”.*
4. *“O padrão é estável e de longa duração, e seu surgimento ocorre pelo menos a partir da adolescência ou do início da fase adulta”.*
5. *“O padrão persistente não é mais bem explicado como uma manifestação ou consequência de outro transtorno mental”.*
6. *“O padrão persistente não é atribuível aos efeitos fisiológicos de uma substância (p. ex., droga de abuso, medicamento) ou a outra condição médica (p. ex., traumatismo cranioencefálico)”.*

Além dos critérios gerais, neste modelo de diagnóstico cada transtorno de personalidade é considerado como uma patologia distinta, por isso cada transtorno de personalidade específico tem dois critérios adicionais que precisam ser satisfeitos, um exemplo pode ser dado pela classificação do transtorno Paranoide [DSM-V, pp. 649-652]:

1. *“Um padrão de desconfiança e suspeita difusa dos outros, de modo que suas motivações são interpretadas como malévolas, que surge no início da vida adulta e está presente em vários contextos, conforme indicado por quatro (ou mais) dos seguintes: 1. Suspeita, sem embasamento suficiente, de estar sendo explorado, maltratado ou enganado por outros. 2. Preocupa-se com dúvidas injustificadas acerca da lealdade ou da confiabilidade de amigos e sócios. 3. Reluta em confiar nos outros devido a medo infundado de que as informações serão usadas maldosamente contra si. 4. Percebe significados ocultos humilhantes ou ameaçadores em comentários ou eventos benignos. 5. Guarda rancores de forma persistente (i.e., não perdoa insultos, injúrias ou desprezo). 6. Percebe ataques a seu caráter ou reputação que não são percebidos pelos outros e reage com raiva ou contra-ataca rapidamente. 7. Tem suspeitas recorrentes e injustificadas acerca da fidelidade do cônjuge ou parceiro sexual”.*
2. *“Não ocorre exclusivamente durante o curso de esquizofrenia, transtorno bipolar ou depressivo com sintomas psicóticos ou outro transtorno psicótico e não é atribuível aos efeitos fisiológicos de outra condição médica”.*

Muitos transtornos mentais podem ter características parecidas. Sendo assim, além dos critérios diagnósticos que precisam ser preenchidos em cada transtorno de personalidade, o DSM-V fornece informações relevantes para cada um deles. Estas informações são relacionadas a dados estatísticos de prevalência da patologia, dados sobre o desenvolvimento e curso do transtorno em questão, fatores de risco, questões relativas a cultura e critérios de exclusão necessários para se

estabelecer um diagnóstico diferencial. O DSM-V também possui um modelo de diagnóstico alternativo [Oldham, 2015] que será explorado no próximo capítulo.

## 2.7 Conclusão

As teorias da personalidade são a chave para o entendimento do funcionamento dos instrumentos psicométricos. Estes instrumentos são utilizados pelos modelos de TB-APR para rotular a personalidade humana. Este capítulo teve como principal objetivo detalhar a teoria psicanalítica que definiu pela primeira vez o conceito de projeção. Além disso o capítulo fez um breve resumo das outras teorias para possibilitar novos *insights*, justificando a escolha das técnicas projetivas utilizadas neste trabalho. Neste sentido, os inventários de personalidade são menos confiáveis para aferir a personalidade, pois eles não possuem mecanismos eficientes para evitar que os indivíduos omitam características indesejadas. Em outras palavras, ao responder uma pergunta do inventário de personalidade, o indivíduo pode fornecer uma pista errada, marcada intencionalmente em uma das alternativas na escala *likert*. Outro enviesamento de inventários de personalidade diz respeito a censura, ou seja, o indivíduo pode não admitir certa suposição que pode fazer com que o indivíduo reprima aspectos de sua personalidade. Neste sentido, a técnica projetiva pode burlar o mecanismo de censura, capturando pistas da personalidade que escaparam do censor via projeção.

Os autores Vinciarelli e Mohhamadi (2014) apontam a tarefa de APR com o reconhecimento da verdadeira personalidade, isto deve ser dito com cautela, pois qualquer instrumento psicométrico possui limitações. Finalmente, esperamos que os modelos de TB-APR concebidos a partir de técnicas projetivas superem as limitações dos modelos que utilizam os inventários de personalidade, sendo possível verificar correlações em dimensões inéditas da personalidade, possivelmente mais fortes que as correlações produzidas pelo estado da arte de TB-APR. O próximo capítulo exemplifica a principal diferença entre as técnicas projetivas e os inventários de personalidade.

### 3 Instrumentos psicométricos de Aferição da Personalidade

Este capítulo é dedicado ao estudo dos instrumentos psicométricos empregados para medir a personalidade. Para permitir a análise computadorizada da personalidade a partir de textos é necessário encontrar padrões textuais que quantifiquem a personalidade de acordo com algum método de cálculo da personalidade que tenha validade científica [Celli et. al, 2013].

Não é o objetivo do capítulo detalhar, de forma profunda, cada instrumento psicométrico, muito menos detalhar todos os instrumentos existentes. Este capítulo procura fazer um apanhado geral dos inventários de personalidade utilizados na tarefa TB-APR, além de descrever superficialmente algumas técnicas projetivas

Existem diferentes métodos usados pelos psicólogos para investigar a personalidade; a entrevista clínica; avaliações de comportamento; amostras de pensamento; inventários de personalidade; e testes projetivos [Schultz & Schultz, 2003]; todos estes métodos possuem subjetividades atreladas às teorias psicológicas discutidas no capítulo 2.

Dividimos este capítulo em duas seções, a primeira descreve os inventários de personalidade e a segunda os testes projetivos.

#### 3.1 Inventários de Personalidade

Os inventários de personalidade são amplamente aceitos pela comunidade da computação da personalidade [Vinciarelli e Mohammadi, 2014]. A aplicação de um inventário de personalidade é relativamente simples, tudo que você precisa é aplicar um questionário que pode ser impresso ou *online*. Para cada pergunta do questionário, há uma resposta de múltipla escolha da escala *likert* [Likert, 1932]. Geralmente é possível quantificar as respostas automaticamente por meio de um *script*, sendo interpretadas diretamente pela máquina, que fornece em poucos segundos os scores dimensionais da personalidade. Este processo automático é uma grande vantagem para a construção de um *corpus* para modelos de TB-APR.

Embora os inventários de personalidade sejam bem aceitos e amplamente utilizados na TB-APR, eles facultam a possibilidade do indivíduo mentir em relação à personalidade, fornecendo falsos indícios sobre suas características. Entendemos que algumas pessoas não serão completamente sinceras ao responder o questionário, ocultando características indesejadas. Outras preencherão o inventário de forma aleatória, para se livrar rapidamente da tarefa. Adicionalmente, pistas alteradas

sobre a personalidade podem ser fornecidas de forma inconsciente, através dos mecanismos de defesa do ego [Freud, 1946]. Os testes projetivos (baseados na projeção da teoria freudiana) como o teste de Rorschach [Rorschach, 1967], o teste Z [Vaz & Alchieri, 2016] e o teste de relações objetais [Ocampo, 1999] são menos suscetíveis a essas interferências.

A estatística Alpha de Cronbach [Hora & Monteiro; Arica, 2010] é utilizada por padrão e nos inventários de personalidade para medir a consistência interna. Geralmente inventários com mais itens (questões) possuem alphas maiores. A estatística Alpha [Hora & Monteiro; Arica, 2010] é calculada através da seguinte Fórmula 1:

$\alpha = \left( \frac{k}{k-1} \right) * \left( 1 - \frac{\sum_{i=1}^k \sigma_{y_i}^2}{\sigma_x^2} \right)$	(1)
---	-----

Onde K refere ao número de itens da categoria,  $\sigma_{y_i}^2$  refere a variância associada com o item i (variância individual) e  $\sigma_x^2$  refere a variância associada dos scores totais observados.

As questões de um inventário sempre são correlacionadas positivamente (+) ou negativamente (-) a um traço ou faceta (sub-traço) da personalidade. Para isso os inventários utilizam três estratégias [Burisch & Matthias, 1984]:

1. Estratégias racionais: utilizam o conhecimento comum.
2. Estratégias teóricas: utilizam conhecimentos sobre as teorias da personalidade.
3. Estratégias externas: selecionam itens que se correlacionam com certas respostas e também com outras informações relevantes além da resposta.
4. Estratégias internas: identificam conjuntos de itens que são respondidos de forma semelhante por um grupo de participantes. A análise fatorial é usada para organizar um grande número de itens em conjuntos que exibem o mesmo padrão.

Posteriormente, uma escala potencial para as respostas pode ser elaborada, identificando os fatores que são interceptados. Tomando essa análise como base, podemos identificar conjuntos com “construto relativamente estreito” e conjuntos com “construto de banda larga”. Para exemplificar, postulamos que a categoria de Extroversão é um conjunto com “construto de banda larga” que engloba subcomponentes [Costa & McCrae, 1992], como simpatia, nível de atividade, alegria que são denominados facetas. Estes últimos são considerados “constructos relativamente estreitos”.

Nas seções a seguir, descreveremos os inventários mais comuns para calcular as dimensões da personalidade. Nestas seções sempre que um valor de porcentagem for encontrado entre parênteses após um traço ou faceta de personalidade (ex: Neuroticismo (0.90) ), este valor é referente à estatística alpha calculada para o traço ou faceta.

### 3.1.1 O modelo Big Five

O modelo Big Five foi proposto por McDougall (1932). O Big Five começou a ganhar importância a partir dos anos 1980, com os estudos de McCrae e John (1992) que descobriram a existência de tais traços em pessoas de diferentes culturas e idades. Os fatores de personalidade do Big Five são:

- 1) Extroversão: diz respeito a pessoas sensíveis, assertivas, ativas, impulsivas e sociáveis que expressam entusiasmo;
- 2) Neuroticismo: descreve pessoas que são inseguras, ansiosas, mal-humoradas, autopuníveis ou exibem outras dimensões do afeto negativo;
- 3) Socialização: define pessoas amáveis, cooperativas, cordiais, prestativas, altruístas e confiantes;
- 4) Realização: caracteriza pessoas autodisciplinadas, organizadas, metódicas e persistentes;
- 5) Abertura à experiência: descreve pessoas que estão abertas ao que é novo, intelectual, perspicaz, liberal e tolerante.

O inventário de personalidade *Neo-International Personality Item Pool* (NEO-IPIP 120), de Johnson (2014), é um exemplo de inventário Big Five moderno que possui 120 itens. Este inventário usa menos da metade dos itens originais do primeiro inventário de personalidade, denominado IPIP, de Goldberg (1999). No estudo promovido por Johnson, há uma demonstração de que o NEO-IPIP 120 mantém a precisão ao inferir a personalidade, além de ser menos exaustivo.

No NEO-IPIP-120, cada uma das características do Big Five é quantificada por questões dirigidas a 6 diferentes facetas correspondentes. Todos traços e facetas [Johnson, 2014] deste inventário possuem itens (questões) com correlação positiva (+) e itens com correlação negativa (-) relativos à alguma dimensão da personalidade. Abaixo todos os traços do NEO-IPIP 120 são descritos com suas respectivas facetas. Os itens estão exemplificados apenas para as facetas do traço Extroversão. A estatística alpha [Hora & Monteiro; Arica, 2010] referente à consistência interna do inventário relativa a cada traço e faceta se encontra entre parênteses.

- 1) Extroversão (0,89)
  - a. Simpatia (0,81).
    - i. (+) fazer amigos facilmente.
    - ii. (+) se sentir confortável no meio das pessoas.
    - iii. (-) evitar o contato com os outros.



- iv. (-) manter os outros à distância.
- b. Gregarismo (0,79).
  - i. (+) amar grandes festas.
  - ii. (+) conversar com várias pessoas diferentes em festas.
  - iii. (-) preferir ficar sozinho.
  - iv. (-) evitar multidões.
- c. Assertividade (0,85).
  - i. (+) assumir o comando.
  - ii. (+) tentar liderar os outros.
  - iii. (+) assumir o controle das coisas.
  - iv. (-) esperar que os outros liderem o caminho.
- d. Nível de atividade (0,69).
  - i. (+) estou sempre ocupado.
  - ii. (+) estou sempre em movimento.
  - iii. (+) faço muito no meu tempo livre.
  - iv. (-) gosto de ter calma.
- e. Procura de excitação (0,73).
  - i. (+) excitação amorosa.
  - ii. (+) procurar aventura.
  - iii. (+) aproveitar sendo imprudente.
  - iv. (+) agir de modo selvagem e maluco.
- f. Alegria (0,79).
  - i. (+) irradiar alegria.
  - ii. (+) divertir-se muito.
  - iii. (+) vida amorosa.
  - iv. (+) olhar para o lado bom da vida.

## 2) Neuroticismo (0,90)

- a. Ansiedade (0,78)
- b. Raiva (0,87)
- c. Depressão (0,85)
- d. Autoconsciência (0,70)
- e. Imoderação (0,69)
- f. Vulnerabilidade (0,76)

## 3) Amabilidade (0,86)

- a. Confiança (0,85)
  - b. Moralidade (0,74)
  - c. Altruísmo (0,73)
  - d. Cooperação (0,71)
  - e. Modéstia (0,73)
  - f. Solidariedade (0,72)
- 3) Consciência (0,90)
- a. Autoeficácia (0,77)
  - b. Ordem (0,83)
  - c. Deveres (.67)
  - d. Esforço de realização (.79)
  - e. Autodisciplina (0,71)
- 4) Cautela (0,88)
- 5) Abertura à experiência (0,81)
- a. Imaginação (0,74)
  - b. Interesses artísticos (0,74)
  - c. Emotividade (0,65)
  - d. Aventura (0,70)
  - e. Intelecto (0,73)
  - f. Liberalismo (0,63)

Além do NEO-IPIP 120, existem vários outros inventários de personalidade, variando o número de itens e a consistência interna de cada dimensão analisada por cada um deles. Os questionários com mais itens possuem consistências internas maiores. A Tabela 4 mostra alguns destes inventários.

Sigla	Nome Inventário	Número de Itens	Autores
TIPI	Ten-item Personality Inventory	10	[Gosling, 2003]
FFPI	Five Factor Personality Inventory	100	[Hendriks, 1997]
NEO-IPIP 120	Neo-International Personality Item Pool	120	[Jhonson, 2014]
BFQ	Big Five Questionary	132	[Caprara et. al., 1993]
NEO-PI-R	Revised NEO Personality Inventory	240	[McCrae & Costa, 1999]
NEO-IPIP 300	Neo-International Personality Item Pool	300	[Johnson, 2000]
GPI	Global Personality Inventory	504	[Schmidt et. al., 2002]

**Tabela 4.** Inventários BigFive, adaptado de [Paim, 2016].

### 3.1.2 Myer Briggs Type indicator

O Myers-Briggs Type indicator [Myers & Myers, 1980] é um inventário de personalidade desenvolvido de acordo com os tipos psicológicos descritos na teoria de Carl Gustav Jung [Jung, 1954/1959a]. Em sua essência, esta teoria afirma que as diferenças individuais são de certa forma ordenadas e consistentes no que diz respeito ao modo de percepção e julgamento. Jung afirmou “*A percepção envolve todas as formas de conhecer as pessoas, as coisas, os acontecimentos e as ideias. O Julgamento envolve todas as formas de chegar a conclusões daquilo que é percebido. Se as pessoas se diferenciam na forma sistemática de como percebem o mundo e chegam a suas conclusões, então é natural que elas se diferenciem quanto aos seus interesses, reações, valores, motivações e habilidades*”.

O inventário de Myer-Briggs foi desenvolvido por Isabel Briggs Myers (1962) e sua mãe Katharine Briggs para produzir *insights* da teoria jungiana em indivíduos e grupos de indivíduos. Neste inventário a personalidade é dividida em 4 dicotomias:

1) Extroversão (E) ou Introversão (I).

Qual o seu mundo favorito? Você prefere focar no mundo externo ou no seu próprio mundo interno?

2) Sensorial (S) ou Intuição (I).

Você prefere focar na informação básica que chega pelos órgãos sensoriais ou prefere interpretar a informação dando novos significados a ela?

3) Razão ('T'hinking) ou Sentimento ('F'eeling).

Quando você toma decisões, você prioriza a lógica e consistência ou leva mais em consideração as pessoas e as circunstâncias especiais?

4) Julgamento (J) ou Percepção ('P'erceiving).

Quando você está interagindo com o mundo externo, você prefere estar aberto a novas informações e opiniões ou ter as coisas rapidamente decididas?

De acordo com cada tendência de dicotomia é possível inferir 16 tipos de personalidade, divididos em 4 grupos de temperamentos: Analistas, Diplomatas, Sentinelas e Exploradores. Os 16 tipos de personalidade são descritos abaixo:

1) Analistas

- a. Arquiteto (INTJ): Pensadores criativos e estratégicos.
- b. Lógico (INTP): Criadores inovadores, sede por conhecimento.
- c. Comandante (ENTJ): Líder ousado, criativo e enérgico.
- d. Inovador (ENTP): Pensador esperto e curioso.

2) Diplomatas

- a. Advogado (INFJ): Idealista, místico, inspirador.
- b. Mediador (INFP): Poético, bondoso, altruísta.
- c. Protagonista (ENFJ): Líder, inspirador, carismático.
- d. Ativista (ENFP): Livre, criativo, sociável, entusiástico, sorridente.

3) Sentinelas

- a. Logístico (ISTJ): Prático, confiável.
- b. Defensor (ISFJ): Protetor dedicado, acolhedor.
- c. Executivo (ESTJ): Administrador, gerenciador de coisas e pessoas.
- d. Cônsul (ESFJ): Atencioso, social, popular, disposto a ajudar.

4) Exploradores

- a. Virtuoso (ISTP): Experimentador, prático, ousado, hábil com ferramentas.
- b. Aventureiro (ISFP): Flexível, charmoso, explorador, aberto a experiências.
- c. Empresário (ESTP): Inteligente, enérgico e perceptivo, gosta de se arriscar.
- d. Animador (ESFP): Entusiasmado, enérgico e espontâneo, a vida nunca é entediante.

### 3.1.3 Egograms

Os inventários baseados nos *egograms* [Dusey, 1972] classificam a personalidade em 5 estados do Ego e possuem uma forte orientação organizacional. Os estados são listados a seguir:

#### 1) Pai Crítico (CP)

Perfeccionista, cumpridor com a palavra, cobra-se demais, sofredor, valoriza tradições, responsável, cumpre o regulamento, organizado, despreza as pessoas, crítico em relação as coisas e fatos, rigoroso com os defeitos alheios, muito preocupado, cargos de gestão e liderança.

#### 2) Pai Protetor (NP)

Está sempre pronto a ajudar, não sabe dizer não, geralmente tem dó das pessoas, age emocionalmente, extremamente atencioso, gosta de lidar com as pessoas, professor, enfermeiro, assistente social.

#### 3) Adulto (A)

Analisa os fatos antes de tomar uma decisão, controla suas emoções em uma conversa, sempre planeja antes de agir, é racional, é lógico, não demonstra emoção facilmente, é frio, profissionais da área técnica, médicos, engenheiros, empresários.

#### 4) Criança livre (FC)

Extremamente curioso, age no calor do entusiasmo, obstinado com relação a seus objetivos, arriscam-se para abrir o próprio negócio, corajoso, desafiador, espontâneo, sem limites, não cumpre as regras, vendedores, microempresários.

#### 5) Criança adaptada (AC)

Sabe lidar bem com as pessoas, esforça-se para contentar os outros, segue as regras, tem projetos mas não os coloca em prática, gosta de regras, obediente, educado, ótimo funcionário, retraído, tem muito medo, adia a tomada de decisões, vive se queixando, profissionais da computação, operadores de máquina.

O inventário *egogram* do instituto Cibele Nardi [Nardi, 2018] possui 50 itens (ex: (+) FC “É espontâneo e livre?”), que espera uma resposta *likert* em uma escala de 0 (não) a 3 (sempre).

### 3.1.4 *Dark Triad*

A *Dark Triad* é um conjunto de três traços relativos a personalidades antissociais [Paulhus & Williams, 2002]. Estes traços são associados a sentimentos de superioridade e privilégios em relação a outros indivíduos, acompanhados de falta de remorso e empatia. Indivíduos com estes traços costumam explorar as pessoas para conseguir ganhos pessoais.

Inventários baseados na *Dark Triad* acessam de forma mais apropriada traços negativos da personalidade que inventários de personalidade mais gerais como o Big Five [Ardic & Ozsoy, 2016]. Os inventários *Dark Triad* são compostos por três traços antissociais e malevolentes:

- 1) Narcisismo (N), traço caracterizado por facetas referentes a grandiosidade, egoísmo e orgulho.
- 2) Maquiavelismo (M), traço que pressupõe a faceta da manipulação e falta de respeito, onde o indivíduo sistematicamente explora os outros para obter ganhos pessoais.
- 3) Psicopatia (P), traço caracterizado por facetas agressivas da personalidade, geralmente indivíduos impulsivos, imprudentes e sem remorso possuem afinidade com este traço. Pínel (1809) descreveu este traço como “mania sem delírio”, diferenciando de forma clara a psicopatia da psicose. Este traço é um fator de risco para crimes violentos [Hare, 1999].

A *Dark Triad* mostra um elo claro com a hipótese léxica [Crowne, 2007], sendo empiricamente possível encontrar manifestações destes traços na linguagem. Quando o copiloto Andreas Lubitz do voo 9535 matou mais de 150 pessoas, causando um acidente fatal de forma intencional em 2005 que também resultou em sua própria morte, dias antes relatou a sua namorada “Um dia, farei algo que mudará o sistema como um todo, e todos saberão meu nome e não de lembrar-se dele” [Guardian, 2018], um discurso claramente narcísico.

É possível também observar as características da *Dark Triad* na fala de líderes de estado tiranos. A personalidade de Adolf Hitler foi analisada a pedido da Agência Americana de Inteligência (CIA) pelo psicólogo de Harvard, Dr. Henry A. Murray (1943), onde em seu relatório [Murray, 1943, p. 185] descreveu a personalidade de Hitler como Narcisista Patológico (Counteractive Narcisist). Neste relatório diversas falas de Hitler estão transcritas, mostrando de forma clara a presença da *Dark Triad* no discurso, algumas delas estão relacionadas ao narcisismo relatório [Murray, 1943, p. 172]:

*“Eu sou um dos homens mais firmes que surgiram na Alemanha há décadas, talvez há séculos, dotado da maior autoridade entre os líderes alemães...Mas, sobretudo, eu acredito no meu sucesso. Nisso eu acredito incondicionalmente”; “Vocês têm consciência que estão na presença do mais ilustre alemão conhecido pela*

*história”; “Quem venceu na campanha da Polônia? Fui eu! Quem deu as ordens? Fui eu! De que foram todas as ideias estratégicas que possibilitaram a vitória? Foram minhas! Quem ordenou o ataque? Eu, eu, eu!”*

No mesmo relatório outras frases de Hitler estão claramente relacionadas a psicopatia [Murray, 1943, p. 175 & 176]:

*“Não haverá paz no país até que um corpo esteja pendurado em cada poste de luz”; “Eu espalharei o terror pelo emprego surpresa de todas as minhas medidas”; “Mas mesmo que não possamos conquistá-los, vamos arrastar meio mundo rumo à destruição conosco, e não deixar ninguém triunfar na Alemanha”.*

Talvez o traço da *Dark Triad* mais latente e desafiador de ser encontrado na linguagem seja o maquiavelismo. O filósofo Niccolò Machiavelli (1469 - 1527), em seu livro “O Príncipe” [Machiavel, 2011], escreveu: “Tenha o povo ao seu lado”, na verdade o que Maquiavel quis dizer, é que os governos devem defender seus interesses custe ao que custar, utilizando a população em seu favor, e se for preciso, o governo deve manipular a população para atender diretamente a seus interesses. Basicamente, para uma personalidade maquiavélica, qualquer virtude é dispensável se a traição e manipulação for mais vantajosa.

O *short D3* [Jones e Paulhus, 2013] é um inventário *dark triad* muito usado. Ele possui 27 itens, os *alphas* para cada traço foram calculados pelos autores N (.77), M (.78) e P (.80). Os itens em forma de perguntas são direcionados diretamente a cada traço (ex. +keyed N) “As pessoas me veem como um líder nato” e as respostas são esperadas em escala *likert* de 1 a 5.

### **3.1.5 Inventários de Transtornos da Personalidade**

Existem diversos instrumentos psicométricos para a avaliação dos transtornos de personalidade [Klein, 1993]. O inventário de personalidade Wisconsin- IV [Klein & Benjamin, 1996] foi elaborado em conformidade com o DSM V. Este inventário está disponível nas línguas inglesas e espanhola. O WISPI-IV contém 214 itens que são avaliados por uma escala de 10 pontos.

Outro inventário é o *Minnesota Multiphasic Personality Inventory 2 RF* [Ben-Porath & Tellgen, 2008], [Tellegen & Ben-Porath, 2008], é um inventário que produz uma escala homogênea aditiva designada a diferenciar diferentes tipos de patologias mentais. Apesar do teste medir diversas desordens mentais, a escala para os transtornos de personalidade é avaliada em 5 traços

(Aggressiveness, Psychoticism, Constraint, Negative Emotionality / Neuroticism, Positive Emotionality / Extraversion).

Além destes inventários, o O DSM-V (seção 3.6) [Oldham, 2015], [DSM-V, 2014] também possui um modelo de traços dimensionais dos transtornos da personalidade. O PID-5 [Markon et. al., 2013] é um inventário de personalidade psicológico desenvolvido especialmente para o DSM-V, com 222 itens que esperam uma resposta em escala *likert* de 4 pontos.

Partindo destes critérios, o PID-5 [Markon et. al., 2013] avalia 25 facetas patológicas da personalidade (anhedonia, anxiousness, attention seeking, callousness, deceitfulness, depressivity, distractibility, emotional lability, gradiosity, hostility, intimacy, avoidance, irresponsibility, manipulateness, perceptual dysregulation, preservation, restricted affectivity, rigid perfectionism, risk taking, separation, insecurity, submissiveness, suspiciousness, usual beliefs & experiences, withdrawal).

A partir do resultado do PID-5 também é possível fazer um diagnóstico de desordem de personalidade, utilizando o manual DSM-V como apoio. Neste modelo dimensional é possível fazer diagnóstico em nível de facetas patológicas da personalidade [DSM-V, 2014, p. 761]. O modelo de diagnóstico da personalidade do DSM-V que utiliza as facetas estabelece 7 critérios [DSM-V, 2014, pp. 761-762]:

- A. *“Prejuízo moderado ou grave no funcionamento da personalidade (self/interpessoal)”*.
- B. *“Um ou mais traços de personalidade patológicos”*.
- C. *“Os prejuízos no funcionamento da personalidade e a expressão dos traços de personalidade do indivíduo são relativamente inflexíveis e difusos dentro de uma ampla faixa de situações pessoais e sociais”*.
- D. *“Os prejuízos no funcionamento da personalidade e a expressão dos traços de personalidade do indivíduo são relativamente estáveis ao longo do tempo, podendo seu início remontar no mínimo à adolescência ou ao começo da idade adulta”*.
- E. *“Os prejuízos no funcionamento da personalidade e a expressão dos traços de personalidade do indivíduo não são mais bem explicados por outro transtorno mental”*.
- F. *“Os prejuízos no funcionamento da personalidade e a expressão dos traços de personalidade do indivíduo não são unicamente atribuíveis aos efeitos fisiológicos de uma substância ou a outra condição médica (p. ex., traumatismo craniano grave)”*.
- G. *“Os prejuízos no funcionamento da personalidade e a expressão dos traços de personalidade do indivíduo não são mais bem entendidos como normais para o estágio do desenvolvimento de um indivíduo ou para seu ambiente sociocultural”*.



Os critérios A e B são os mais relevantes. O critério A investiga o funcionamento da personalidade através de elementos que fazem parte de seu núcleo: o Self e o interpessoal. Para a aplicação do critério A foi estabelecida uma escala para o nível de funcionamento da personalidade, chamada de ENFP (Escala do nível de funcionamento da personalidade), que vai de 0 até 4 [DSM-V, 2014, p.778]:

1. Nível 0: Nenhum prejuízo.
2. Nível 1: Algum prejuízo.
3. Nível 2: Prejuízo moderado.
4. Nível 3: Prejuízo grave.
5. Nível 4: Prejuízo extremo.

O critério A considera um indivíduo portador de um transtorno de personalidade se apresentar prejuízo moderado ou grave nas seguintes dimensões [DSM-V, 2014, p. 762]:

1. Identidade (Self): “Vivência de si como único, com fronteiras claras entre si mesmo e os outros; estabilidade da autoestima e precisão da autoavaliação; capacidade para, e habilidade de regular, várias experiências emocionais”.
2. Auto direcionamento (Self): “Busca de objetivos de curto prazo e de vida coerentes e significativos; utilização de padrões internos de comportamento construtivos e pró-sociais; capacidade de autor refletir produtivamente”.
3. Empatia (interpessoal): “Compreensão e apreciação das experiências e motivações das outras pessoas; tolerância em relação a perspectivas divergentes; entendimento dos efeitos do próprio comportamento sobre os outros.”
4. Intimidade (interpessoal): “Profundidade e duração do vínculo com outras pessoas; desejo e capacidade de proximidade; respeito mútuo refletido no comportamento interpessoal”.

O critério B utiliza um sistema utiliza 5 traços patológicos (Negative affectivity, Detachment, Antagonism, Desinhibition, Psychoticism), onde cada traço patológico é composto por um conjunto de facetas encontradas através do PID-5.

### **3.1.5 *Justice-Vengeance Scale (JVS)***

Este inventário acessa especificamente as facetas da personalidade referentes à Justiça e à Vingança, em 4 dimensões [Ho et. al, 2002]:

- 1) Vengeance-emotion (0.80), relacionado à vingança motivada por emoções.
- 2) Vengeance-sentence (0.79), relacionado à intensidade do sentimento de vingança.
- 3) Justice-fairness (0.73), relacionado ao senso de justiça de forma ampla.

- 4) Justice-legal (0.71), relacionado ao senso de justiça observando a legalidade.

O teste é um questionário que espera respostas em uma escala *likert* de 6 pontos e possui 16 itens, 4 por faceta (ex. +keyed Justice-lagal “Ao decidir um caso criminal – É importante que o acusado seja julgado por princípios legais”).

### **3.1.6 *Trait-Forgiveness Scale (TFS)***

Este inventário explora apenas a faceta da personalidade referente ao perdão/ forgiveness com a consistência interna alfa de 0.80 [Barcaccia & Milioni ; Vecchio, 2015]. Possui 10 itens esperando uma resposta em escala *likert* de 5 pontos (ex. (+) “Eu tento perdoar os outros, mesmo se não se sentirem culpados pelo que fizeram”).

### **3.1.7 *Interpersonal Reactivity Index (IRI)***

O IRI [Davis, 1980] é um inventário que estuda 4 dimensões referentes a faceta empatia; estas dimensões estão agrupadas em 2 grupos diferentes [Spencer, 1970]: o Grupo Cognitivo e o Grupo Emocional. Estudos mostram que a empatia tem correlação com a capacidade de perdoar os outros [Davis & Gold, 2011], e a falta de empatia se correlaciona com traços maquiavélicos e narcísicos [Wai & Tipolus, 2012], sendo esta falta considerada por alguns autores como o pivô desencadeante da *Dark Triad* [Jones et. al, 2013]. Os grupos de dimensões da faceta empatia analisados pelo inventário IRI são descritas abaixo:

- 1) Grupo Cognitivo, identifica dimensões relacionadas à empatia desencadeados por processos cognitivos nas dimensões *Fantasy Scale (FS)* onde é avaliado a capacidade identificação do indivíduo com personagens de ficção, e *Perspective-Taking (PT)*, nesta dimensão é avaliada a capacidade do indivíduo de entender o ponto de vista de outros indivíduos.
- 2) Grupo Emocional/ Afetivo, identifica processos empáticos com caráter de alto impacto emocional, nas dimensões *Empatic Concern (EC)* avaliando a tendência do indivíduo de experimentar compaixão, e *Personal Distress*, avaliando a capacidade de experimentar angústia ao testemunhar experiências negativas de outros indivíduos.

No total, o inventário é composto de 28 itens (ex. (+) PT “Acredito que há dois pontos de vista em relação a cada questão e tento olhar para ambos”); espera-se uma resposta em escala *likert* de 5 pontos.

### **3.1.8. *The hypersensitive Narcissism Scale (HSNS)***

Este curto inventário composto de 10 itens (ex. + keyed “Meus sentimentos são facilmente afetados pelo ridículo ou comentários desdenhosos por parte de outros”) foi desenvolvido especificamente para o traço de personalidade narcisismo [Hendin & Cheek, 2013], onde um questionário espera uma resposta em escala *likert* de 5 pontos.

### **3.1.9. *Grandiose Narcissism***

É um inventário específico para o traço de personalidade narcisismo [Gentile et al., 2013], composto de 13 itens onde espera-se uma resposta binária (sim ou não) para cada item (ex. + keyed “Eu gosto de ser o centro de atenção”).

## **3.2 Técnicas Projetivas**

As tarefas das técnicas projetivas geralmente utilizam estímulos ambíguos e não esperam respostas estruturadas. Estas técnicas podem variar muito dependendo do teste a ser aplicado, entretanto todas elas partem do conceito básico projeção, descrito pela primeira vez na teoria psicanalítica. Na década de 1960, testes projetivos como o Rorschach recebiam duras críticas [Eysenck, 1959]; [Jensen, 1965], devido a problemas de padronização na aplicação. As críticas as principais eram:

- 1) Falta de regras de aplicação e padronização de pontuação.
- 2) Baixa confiabilidade de scores, demonstrada quando diversos avaliadores avaliavam os mesmos indivíduos.
- 3) Validade ecológica e validade de representação não demonstrada.
- 4) Poderiam ser suscetíveis a influências situacionais.

Entretanto as críticas aos testes projetivos de certa forma cessaram após esforços serem realizados visando uma padronização, como é o caso da publicação do “The Rorschach: A Comprehensive System (TRACS)” [Exner, 1974], incorporando técnicas que permitiam avaliar a personalidade de forma um pouco mais metodológica.

No Brasil, existe a Sociedade Brasileira de Rorschach (SBRo) que têm como objetivo difundir o uso dos testes projetivos, promovendo encontros científicos sobre os testes psicológicos. Existem uma ampla gama de testes projetivos [Ocampo, 1999], eles possuem a vantagem de dificilmente serem manipulados, mas também possuem a desvantagem de ter um processo de aplicação e correção

mais complicado, necessitando o aplicador ser um psicólogo com conhecimento sobre as teorias psicológicas.

As próximas subseções detalham duas técnicas projetivas,

### 3.2.1 O Teste Desiderativo

O teste desiderativo foi proposto em 1946 pelos psiquiatras J. M. Pigem e J. Córdoba [Córdoba e Pigem, 1946], [Pigem, 1949]. O principal objetivo deste teste é provocar no indivíduo um ataque à integridade de seu Ego [Ocampo, 1976], definindo uma escala de conceito de força do Ego, esta força é avaliada pelos atributos:

- 1) A capacidade do sujeito de manter a coesão e se sobrepor ao impacto das instruções.
- 2) Nos ataques ao Ego, o sujeito não deve negar de forma maníaca a morte e também não sucumbir a ela.
- 3) O sujeito não se agarra a escolhas consistentes da identidade humana (“mago”, “não ser ladrão”, “batman”, “fada”).
- 4) O sujeito não se limita a respostas evasivas (“não sei”).

O teste desiderativo na sua forma original consistia de apenas duas questões: (i) O que você gostaria de ser se tivesse de voltar ao mundo não sendo uma pessoa? (ii) Porque você fez esta escolha?

O objeto escolhido se traduz pela escolha desiderativa atribuída pelo mecanismo de projeção do Ego. Este modelo de questões foi melhorado e ampliado [Bernstein, 1980], no qual se pede três escolhas com justificativa e três rejeições (o que não gostaria de ser) com justificativa, fornecendo instruções em três etapas, forçando um tópico relacionado a cada escolha: (i) um animal, (ii) um vegetal, (iii) um ser inanimado.

O teste geralmente é aplicado na forma de a cada pergunta feita um tópico é eliminado, cada tópico corresponde a uma catexia (deslocamento de energia) positiva ou negativa do aparelho psíquico. Os três tópicos produzem perguntas no formato de dicotomias polares, permitindo avaliar o Ego do indivíduo de forma mais confiável que o modelo original, produzindo diferentes abstrações, avaliando de forma indireta através da projeção: “O que o indivíduo gostaria que os outros percebessem nele (+) e o que o indivíduo não gostaria que os outros percebessem nele (-). Por que?”. As dicotomias são mostradas a seguir:

(+1) Se você não pudesse ser mais você mesmo e tivesse que escolher um animal para ser, qual você escolheria? Por que?

(-1) Se você não pudesse ser mais você mesmo e tivesse que escolher um animal para ser, qual você não escolheria? Por que?

(+2) Se você não pudesse ser mais você mesmo e tivesse que escolher algo do reino vegetal para ser, qual você escolheria? Por que?

(-2) Se você não pudesse ser mais você mesmo e tivesse que escolher algo do reino vegetal para ser, qual você não escolheria? Por que?

(+3) Se você não pudesse ser mais você mesmo e tivesse que escolher um objeto para ser, qual você escolheria? Por que?

(-3) Se você não pudesse ser mais você mesmo e tivesse que escolher um objeto para ser, qual você não escolheria? Por que?

A interpretação das respostas do teste desiderativo depende do conhecimento do aplicador do teste sobre as teorias de personalidade [Schust & Picolo, 1976]. No que tange às respostas, um Ego muito fraco e deficiente de defesas entra em colapso, não conseguindo responder ao teste, pois não é capaz de discriminar a morte real da fantasia de morte. Um Ego um pouco menos fraco se organiza graças à negação maníaca da angústia de morte, uma escolha típica seria “Uma rocha, porque é eterna, não gasta e não morre”; exemplos de Egos fracos mais racionais podem dar diferentes respostas dependendo do grau de fragilidade “uma rosa delicada”, “uma taça de vidro”, “um ratinho em uma gaiola porque cuidam dele”. Egos com certo grau de força não são ofendidos pelas instruções e não recorrem a respostas maníacas “Um lobo, livre, que caça seu alimento e vive com sua matilha”, “Gostaria de ser um submarino de alta tecnologia, que explora o fundo do mar e descobre novas espécies de peixes”.

O tempo de reação (TR) é um indicador que também deve ser levado em consideração nas respostas, este tempo é considerado a partir do enunciado dado até que o indivíduo encontre uma resposta, ignorando palavras desconexas que contam como um tempo de preparo do indivíduo para encontrar a resposta, esperando-se que as catexias (+1) e (-1) tenham um maior tempo de resposta, pois o indivíduo se depara com uma situação nova, onde o Ego deve se defender da morte e suportar a fantasia de ser transformando em outra coisa. Um TR muito baixo (1s a 5s) indica que o Ego quer se livrar rapidamente da tensão, geralmente caracterizando um Ego fraco e produzindo respostas mal elaboradas do tipo clichê, ao passo que um tempo muito elevado (30s+) é um indicador que o Ego foi atacado de forma muito intensa, fazendo sua reação ser lenta, caracterizando um Ego vulnerável;

esta hipótese é reforçada ao acontecer o processo de lentidão de resposta em todas as catexias (+1), (+2), (+3) e (-1), (-2),(-3). Obviamente, a agilidade na resposta também depende do nível de intelectualidade do sujeito, um indivíduo com alto nível de abstração e inteligência poderá manter respostas concisas com tempos bastante baixos em todas as catexias.

Finalmente, o teste desiderativo abre a possibilidade de identificar outros indicadores [Guimarães e Pasion, 2009] tais como: (i) a avaliação da sequência de escolhas, caracterizando qual a ordem dos tópicos escolhidos para as respostas; um indivíduo com Ego forte irá preferir respostas com maior grau de vitalidade, optando pelo tópico animal seguido do vegetal, deixando os seres inanimados como a última escolha, (ii) a necessidade de indução do aplicador revelando possíveis problemas nas funções psicológicas,(iii) respostas antropomórficas indicando dificuldades da dissociação da figura humana, sugerindo disfunção na adequação ao real. Elementos como a curva de distribuição da ansiedade persecutória (A.P.) e muitos outros passíveis de serem encontrados através do teste desiderativo estão descritos em Ocampo [1976].

### **3.2.2 O Z-Teste**

Hans Zulliger (1893-1965) foi um psicólogo suíço e um dos fundadores da Sociedade de Psicanálise Suíça, juntamente com Hermann Rorschach [Rorschach, 1974] [Beck, 1952]. Podemos considerar Zulliger como um entusiasta dos testes de personalidade projetivos através de imagens elaboradas ao acaso; seu trabalho foi no sentido de aperfeiçoar e simplificar o processo de diagnóstico da personalidade.

Na Segunda Guerra Mundial, Zulliger utilizou a técnica de Rorschach [Rorschach, 1974], um teste projetivo baseado em 10 imagens formadas ao acaso, para selecionar pessoas no exército suíço. Neste processo de aplicação, Zulliger verificou que o teste seria inviável devido ao grande tempo dedicado à aplicação da técnica. No Rorschach, a análise das respostas de cada indivíduo referente aos 10 cartões demandava um árduo trabalho por parte do aplicador do teste, o tempo de aplicação em cada indivíduo pode facilmente passar de 1 hora, sem contar com o tempo elevado de correção.

O Z-Teste ou Técnica de Zulliger [Zulliger, 1948] é um teste de personalidade baseado no Método de Rorschach [Beck, 1952], com vantagem em relação ao tempo de aplicação, pois utiliza um número bastante reduzido de imagens ou cartões, onde apenas 3 figuras são utilizadas (comparativamente Rorschach utiliza 10 figuras). Para tanto, Zulliger fez experimentos com novas manchas de tintas elaboradas ao acaso em diversos grupos de indivíduos, analisando sistematicamente centenas de pessoas e chegando ao número ideal de 3 manchas, publicado em “Der Diapositiv Test”

[Zulliger, 1948]. Adicionalmente, Zulliger elaborou uma forma coletiva de aplicação do teste opcional.

No Brasil, Cícero E. Vaz e João Carlos Alchieri [Vaz & Alchieri, 2016] desenvolveram um trabalho com o Z-teste, respaldados pela comunidade de psicologia. A aplicação do Z-teste na forma coletiva difere em alguns aspectos da aplicação individual. A aplicação coletiva do Z-teste é descrita em detalhes na metodologia desta tese (Capítulo 2.). A aplicação individual é muito parecida com a coletiva. A principal diferença é que na aplicação individual as figuras são mostradas em cartões físicos e o próprio psicólogo anota as respostas do examinando. A aplicação individual permite considerar os fatores adicionais, como o tempo das respostas e marcar como o examinando segurou o cartão (se virou para direita, esquerda, fez rotação, etc). Mais detalhes sobre o Z-teste podem ser encontrados na seção 7.1.

### **3.2.3 O Teste de Apercepção Temática**

O Teste de Apercepção Temática (TAT) é uma técnica projetiva elaborada por Henry Murray (1943) em que se avalia a personalidade do examinando no processo de contar histórias. As histórias contadas são baseadas em estímulos fornecidos por figuras impressas em cartões. O protocolo de aplicação geralmente permite que o aplicador selecione um conjunto de cartões a depender do sexo e da idade do examinando. O processo de quotação do TAT (aferição das dimensões de personalidade) pode ser realizado através de diferentes metodologias. Estas metodologias podem possuir diferentes escalas dimensionais da personalidade [Morval, 1982]; [Winter, 1989]; [Scaduto, 2016]. Mais detalhes sobre o TAT podem ser encontrados na seção 7.2.

## **3.3 Conclusão**

Neste capítulo apresentamos os inventários de personalidade e os testes projetivos, duas formas diferentes de calcular as dimensões da personalidade. Apesar de existirem inventários de personalidade que se baseiam em constructos teóricos das teorias psicodinâmicas, como é o caso do Myers-Briggs Type indicator [Myers & Myers, 1980], o método de aplicação destes inventários é idêntico ao dos inventários baseados em teorias disposicionais (Ex: inventários BigFive), não permitindo capturar elementos inconscientes.

Os testes projetivos possuem uma forma de aplicação e correção bem diferente dos inventários de personalidade. Nestes testes um estímulo ambíguo é fornecido, e através da projeção, é possível capturar pistas adicionais de personalidade, driblando o mecanismo da censura. Geralmente, em uma técnica projetiva não é possível esconder características indesejadas. Neste sentido, mesmo que o

examinando tente deliberadamente esconder pistas indesejáveis de sua personalidade, possivelmente a técnica projetiva revelará pistas, que serão capturadas através das variáveis determinantes do cálculo da personalidade do teste.

## 4 Técnicas de Extração de Características para TB-APR

As técnicas de extração de características são as ferramentas de acesso a contextos morfológicos, sintáticos, semânticos e pragmáticos do emprego da linguagem textual. Este capítulo tem como objetivo fazer um apanhado geral das técnicas de extração de características textuais utilizadas no problema de TB-APR.

Os textos muitas vezes não podem ser submetidos diretamente à etapa de extração de características, sendo necessário, em um primeiro momento, realizar um pré-processamento. A literatura de TB-APR considera as técnicas *top-down* e *bottom up* como o padrão para o problema de TB-APR. Podemos classificar as técnicas de extração de características em três grandes grupos:

- 1) Técnicas baseadas em dicionários, chamadas de *top-down*.
- 2) Técnicas de contagem e estatísticas que não utilizam dicionários, chamadas de *bottom-up*.
- 3) Técnicas híbridas que utilizam conceitos *top-down* e *bottom-up*.

Dividimos este capítulo três seções, a primeira descreve técnicas de pré-processamento. A segunda as técnicas *top-down*. A terceira as técnicas *bottom-up*. A quarta descreve as técnicas híbridas. A última faz uma conclusão do capítulo.

### 4.1 Técnicas de Pré-Processamento

Geralmente em TB-APR, a etapa de pré-processamento é imprescindível, pois os textos podem ser coletados de uma grande variedade de repositórios (transcrições de falas, blogs, redes sociais, ensaios textuais, etc.); estes dados muitas vezes são ruidosos e inconsistentes. O pré-processamento é responsável por [Appel, 2010]:

- 1) Fazer a limpeza de dados: remoção de ruídos e dados incompletos ou inconsistentes.
- 2) Fazer a integração de dados: combinação dos dados provenientes de documentos diversos, no problema de TB-APR geralmente são textos escritos por um mesmo indivíduo.



- 3) Fazer a transformação dos dados: técnicas utilizadas para converter os dados em formatos apropriados.

## 4.2 Técnicas *Top-Down*

As técnicas *top-down* se baseiam em dicionários especiais chamados de léxicos, que possuem a função de agrupar palavras e outros elementos do texto em categorias, na língua inglesa existem ao menos 21 léxicos diferentes [Almeida, 2017]. Muitos destes léxicos possuem traduções em outras línguas que no caso do português-br são de relevância para esta dissertação. A necessidade de recursos léxicos para categorizar palavras emergiu de problemas textuais relacionados à computação afetiva [Picard, 1995] que têm sobre seu domínio técnicas computacionais relacionadas a detecção e inferência de emoções, sentimentos, humor, atitudes e personalidade.

As vantagens da utilização de léxicos são o baixo custo computacional (linear) para a extração de características, bastando realizar a contagem das palavras que pertencem a cada categoria, onde cada categoria será um atributo no espaço de características.

Apesar das vantagens, existem também desvantagens no uso de léxicos, como a limitação do dicionário léxico em comparação ao dicionário presente no *corpus*, podendo existir no texto muitas palavras que não estão categorizadas no léxico. Neste sentido também pode ocorrer o efeito contrário, ou seja, o *corpus* pode não ter a variabilidade de palavras suficientes para popular as dimensões do léxico. Outra desvantagem é inerente ao próprio processo de elaboração de categorias léxicas: categorizar palavras de acordo com um conceito não é um consenso universal, existindo subjetividade.

Antigamente o processo de elaboração de um léxico demandava uma quantidade considerável de recursos humanos em um tedioso trabalho manual, no qual as palavras eram sistematicamente separadas em categorias e rotuladas em categorias por um conjunto de juízes mediante o consenso; este tipo de abordagem produz um número muito limitado de palavras por categoria. Para remediar esta situação alguns léxicos utilizam técnicas de construção semiautomáticas ou automáticas, sendo que a maioria dos léxicos atuais são construídos de forma semiautomática.

Neste capítulo, classificamos os léxicos de acordo com a sua utilidade. Eles podem ser afetivos, semânticos e semântico afetivos, todos eles podem ser marcadores úteis para encontrar pistas sobre a personalidade nos textos.

#### 4.2.1 Léxicos Psicolinguísticos.

Os léxicos psicolinguísticos utilizam uma gama variada de categorias linguísticas e psicológicas, podemos citar dois como os principais léxicos psicolinguísticos utilizados nos modelos TB-APR, o MRC e o LIWC, entretanto o LIWC é muito mais utilizado que o MRC.

O léxico MRC [Coltheart, 1981] possui 150.837 palavras catalogadas em 26 categorias psicolinguísticas. As categorias do MRC são referentes ao número de letras, número de fonemas, familiaridade, part-of-speech, entre outras.

O léxico *Linguistic Inquiry and Word Count* (LIWC) é um léxico mais importante para construir modelos de TB-APR. Este léxico vem sendo constantemente melhorado e já foi traduzido para diversas línguas (espanhol, alemão, holandês, norueguês, italiano, português e diversas outras traduções linguísticas estão em curso), a última versão do LIWC para a língua inglesa foi disponibilizada em 2015.

O LIWC vem sendo aprimorado desde a sua primeira versão, na qual o léxico fazia parte de um estudo exploratório sobre a linguagem realizado em 1993 por Pennebaker e seus colegas; hoje o LIWC encontra-se em sua quarta versão [Pennebaker et al., 2015]. A segunda [Pennebaker et al., 2001] e terceira versão [Pennebaker et al., 2007] melhoraram o léxico, expandindo e modernizando-o, mas apenas na quarta e última versão [Pennebaker et al., 2015] houveram mudanças mais significativas, um exemplo de melhorias desta última versão pode ser dado por entradas léxicas, que antes eram ignoradas tais como “b4”, e que agora é categorizada como uma preposição e caracterizada como uma emoção de polaridade positiva. Adicionalmente, nesta versão uma revisão foi realizada onde algumas categorias foram removidas e outras foram adicionadas.

O processo de construção do LIWC2015 decorreu de um estudo minucioso elaborado por juízes e ferramentas automáticas de contagens de palavras, um breve resumo deste processo será explicado nas 4 etapas a seguir: (i) Em um primeiro momento, utilizou-se o LIWC de 2007 e palavras de outras fontes como ponto de partida, estas palavras foram analisadas individualmente por 2 a 6 julgadores que geraram listas de palavras para cada categoria (ex. identificando polaridades de emoções na escala PANAS [Watson et al., 1988]). Posteriormente 4 a 8 juízes avaliam por votação o “goodness of fit” das palavras em cada categoria, apenas palavras que ganharam o voto majoritário permanecem nas categorias. Após um dicionário utilizável ser construído pelos juízes (ii) verifica-se a porcentagem das palavras categorizadas em relação ao total de palavras, para isso foi utilizada a

ferramenta *Meaning Extraction Helper* (MEH) [Boyd, 2015], determinando qual a frequência das palavras do dicionário nas mais diversas fontes de textos (*corpus*), com isso palavras frequentes, não reparadas pelos juízes, são novas candidatas e são votadas novamente por 4 a 8 juízes para julgar se serão incluídas no léxico e também são votadas para decidir em qual categoria irão se enquadrar. Na etapa seguinte, uma (iii) avaliação psicométrica é realizada, como todas as palavras são representadas por uma porcentagem do número total de palavras (esta porcentagem é referente a aproximadamente 181 mil textos e 231 milhões de palavras), cada palavra é tratada como uma “resposta” e usada para computar a estatística de consistência interna de cada categoria, palavras com baixa consistência interna serão candidatas a exclusão do dicionário final e são submetidas à votação com o julgamento se devem ou não permanecer no léxico (grupo de 2 a 8 juízes); como as categorias linguísticas são parte do mecanismo da linguagem, elas não passam por este processo. Finalmente um (iv) processo de refinamento repete todos os passos anteriores à procura de erros, onde na última fase, dois juízes revisam o léxico procurando erros. Além do dicionário, os autores desenvolveram um software que aceita diversas entradas de dados como PDF, RTF, Microsoft Word and Excell files, entre outros.

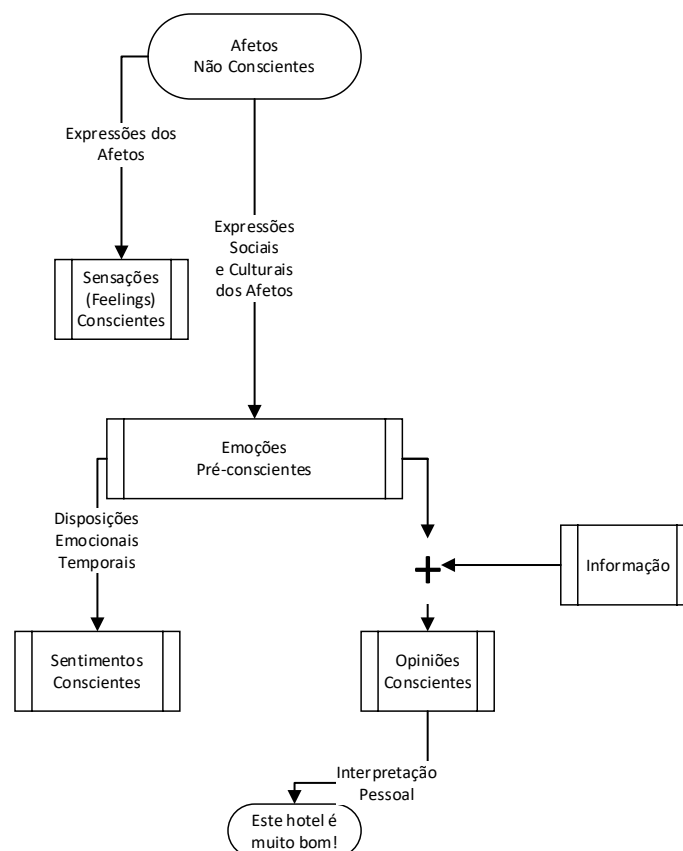
No total o LIWC2015 é composto de 6400 entradas léxicas no formato de *words*, *word stems* e *selected emoticons* onde cada palavra é definida por uma ou mais categorias. Na língua inglesa existem aproximadamente 90 categorias (adaptações em outras línguas podem ter mais ou menos categorias), estas categorias podem ser divididas em 5 dimensões principais. A dimensão (i) *Summary Language Variables* possui as categorias *Analytical Thinking*, *Authentic*, *Emotional Tone* e também *General Descriptor Categories*, tais como *words/ sentence ratio* (WPS), palavras com mais de 6 letras, *dictionary words*. A dimensão (ii) *Linguistic Dimensions* possui categorias relativas a palavras funcionais (*it, to, no, very*), pronomes (*me, mine, you, she, he*), artigos (*a, an, the*), prepositions (*to, with, above*), negations (*no, not, never*), conjunctions (*and, but, whereas*), auxiliary verbs (*am, will, have*), adverbs (*very, really*). A dimensão (III) *Other Grammar* possui categorias referentes à gramática tais como *common verbs* (*eat, come, carry*), *common adjectives* (*free, happy, long*), *comparisons* (*greater, best, after*), *interrogatives* (*how, when, what*), *numbers* (*second, thousand*), *quantifiers* (*few, many, much*). A dimensão (iv) *Psychological Processes* possui categorias caracterizando processos afetivos (*happy, cried, love, nice*), sociais (*son, dad, mate, talk, buddy*), cognitivos (*think, know, maybe, always, but*), perceptuais (*look, heard, feeling, view, touch*), biológicos (*eat, blood, cheek, pill, horny, pizza*), drives (*ally, firend, win, sucess, superior, danger*), time orientations (*ago, today, will, soon*), relativity (*arrive, car, go, down, in, thin, season*), personal concerns (*job, majors, xerox, cook, audit, kitchen, church, kill*) and informal language (*dam, agree, we, mean*). A última dimensão diz respeito a (v) pontuação de textos, onde podemos encontrar as categorias representativas do uso da pontuação em geral, como pontos, vírgulas, dois pontos, ponto e

vírgula, pontos de interrogação, pontos de exclamação, travessões, aspas, apóstrofes, parênteses e outros sinais de pontuação.

As categorias associadas com dinâmicas psicológicas são direcionadas a palavras que se correlacionam com processos emocionais, cognitivos, sensoriais e sociais e categorias linguísticas são associadas a POS tags. Podemos notar também uma hierarquia interna entre algumas categorias, um exemplo pode ser dado pela categoria de emoções positivas, englobando categorias de palavras positivas (*happy, love*), palavras com valência positiva (*beautiful, nice*), palavras otimistas (*exciting, win*), ao passo que categorias de outras dimensões como a *relativity*, que possui referências temporais (*hour, month*), não são hierárquicas [Pennebaker et. al., 1999].

#### 4.2.2 Léxicos Afetivos

Os léxicos afetivos são aqueles que capturam elementos da linguagem referentes a afetos. Neste contexto, podemos entender a palavra afeto como um conceito mais abrangente, que engloba um conjunto de conceitos psicológicos utilizados na computação afetiva: *afetos, sensações, emoções, sentimentos e opiniões* [Munezero et. al, 2014]



**Figura 10.** Diferenças entre *afetos, sensações, emotions, sentimentos e opiniões*, adaptado de [Manuzero et.al., 2014].

O processo de categorizar palavras com referências a processos psicológicos é uma tarefa difícil, muitas palavras são ambíguas e suscetíveis a interpretações subjetivas devido a diversas variáveis (teóricas, culturais, estatísticas, entre outras). O próprio conceito de afeto, discutido aqui, não é universal, pois existem aqueles que acreditam que o inconsciente não existe. Uma tentativa de desambiguação de significado de algumas palavras referentes a alguns processos psicológicos bastante estudados pela computação afetiva foi proposta pelo trabalho de Munezero et. Al. [2014], no qual os autores debatem sobre a subjetividade de algumas destas palavras, propondo um critério de desambiguação. Notamos que o critério estabelecido pelos autores (Figura 10) foi influenciado pela primeira tópica da teoria psicanalítica (sub-seção 2.1.1), que dividiu o aparelho psíquico em três instâncias distintas, o inconsciente, o consciente e o pré-consciente, admitindo a origem do processo cognitivo está enraizado em mecanismos não conscientes. Neste sentido, podemos entender os afetos como manifestações psíquicas inconscientes, sendo as sensações uma forma de expressão destas manifestações. Por outro lado, as emoções são manifestações psíquicas pré-conscientes e os sentimentos e opiniões são manifestações psíquicas conscientes.

Os léxicos afetivos são ferramentas de acesso a emoções, sentimentos e opiniões, fornecendo informações sobre a polaridade afetiva de suas palavras ou categorias de palavras.

- 1) *General Inquirer* [Stone et. al., 1996] é um dos léxicos mais antigos, criado de forma totalmente manual. Apesar ser um léxico de uso mais geral, é classificado como afetivo por possuir em suas referências duas valências de polaridade (positiva e negativa). A categorias deste léxico englobam os mais diversos domínios (acadêmico, militar, bem estar, entre outros).
- 2) *SentiStrenght* [Theleall et. al., 2010] classifica as palavras em uma escala de 1 a 5 para palavras com polaridade positiva e uma escala de -5 a -1 para palavras com polaridade negativa. Este léxico possui uma ferramenta *online* para aplicação (<http://sentistrength.wlv.ac.uk>) que permite fazer a análise de sentimentos em textos curtos. Este léxico possui uma versão em português-br.
- 3) *Affective Norms for English Words* (ANEW) [Bradley & Lang, 1999] caracteriza as emoções como um afeto efêmero, composto por duas dimensões, a de alerta em uma escala que varia do relaxado ao estimulado e a de valência em uma escala que varia do agradável ao desagradável. Existe uma versão deste léxico para o português do Brasil [Kristensen et.al., 2011], utilizando a escala de *Self-Assesment Manikin* (SAM) [Bradley & Lang, 1994] que possui nove pontos para cada uma das 2 dimensões.

- 4) *SentiLex-PT* [Silva & Carvalho; Sarmiento, 2012] [Carvalho & Silva, 2015] léxico disponível para o português-br possui informações referentes ao tema, categoria gramatical, atributos de polaridade de sentimentos (1 positivo, 0 neutro, -1 negativo) e outras observações específicas
- 5) *OpLexico* [Souza, 2011] léxico em português com palavras categorizadas de acordo com sua morfologia e com anotações referentes a polaridade (1 positivo, 0 neutro, -1 negativo).
- 6) O NRC [Mohammad, Kriitchenko; Zhu, 2013] é um léxico que contém mais de 14000 palavras em inglês, anotadas em associação com 8 emoções – raiva, medo, antecipação, confiança, tristeza, alegria, desgosto (*anger, fear, anticipation, trust, surprise, sadness, joy, disgust*) –, além da anotação dessas emoções, a polaridade das palavras também é anotada (positiva ou negativa).

### 4.2.3 Léxicos Semânticos

Os léxicos semânticos são dicionários que organizam palavras de acordo com os seus significados, possuindo recursos para organizar palavras de acordo com suas relações semânticas. Estes léxicos se organizam no que chamamos de *bags-of-concepts*, onde estes conceitos podem inclusive ser representados por ontologias e grafos.

O *WordNet* é um exemplo deste tipo de léxico, desenvolvido e disponível para uso na língua inglesa, e existe uma versão que está sendo desenvolvida para a língua portuguesa, neste sentido o autor Hugo Gonçalo Oliveira fez uma pesquisa comparando os léxicos semânticos disponíveis para a língua portuguesa e portuguesa do Brasil, comparando os léxicos disponíveis. O autor verificou os seguintes léxicos semânticos disponíveis para o português [Gonçalo, 2018] :

- 1) Léxicos completos inspirados no *WordNet*: WordnetBR (WN.BR) [Dias-da-Silva, 2006], OpenWordNet.PT (WN.PT) [Paiva et. al., 2012], PULO [Simões et. al., 2014].
- 2) Léxicos de *Synets TeP* [Maziero et. al., 2008] e *OpenThesaurus.PT* (OT.PT) [OT.PT, 2018]
- 3) Redes Semânticas Extraídas de dicionários: PAPEL [Gonçalo et. al., 2008] extraída do Dicionário Aberto [Simões et. al., 2012] e relações extraídas do Wikitionary.PT.
- 4) Relações Semânticas Port4Nooj [Barreiro, 2010]
- 5) Relações Semânticas entre palavras do português na ConceptNet [Speer, 2017]

A diferença entre estes léxicos semânticos está na cobertura de cada um, por exemplo, no que diz respeito a relações, todos léxicos cobrem sinônimos, mas o WN.BR OT.PT não cobre antônimos. O número de itens lexicais também varia em cada um deles, por exemplo o TeP possui 1138 advérbios e o OT.PT, apenas 143. O número de relações e o número de itens cobertos por cada léxico estão especificados no trabalho de Gonçalo (2018).

#### 4.2.4 Léxicos Semânticos Afetivos

Estes léxicos são combinações de léxicos que possuem mecanismos de inferência semântica com léxicos afetivos, nesta categoria podemos citar os seguintes léxicos [Paim 2016]:

- 1) SentiWordNet [Esuli & Sebastiani, 2006]: É uma extensão do WordNet, associando cada *synset* com as polaridades positivas negativas ou neutras em uma escala que varia de 0 a 1.
- 2) WordNetAffect: Outra extensão do WordNet. que utiliza uma base de dados afetiva, fazendo uso do modelo de emoções OCC [Clore & Ortony, 2013] [Ortony & Clore; Foss, 1987] e da teoria de emoções básicas, este modelo introduziu uma nova relação na base WordNet chamada de “a-label”, possuindo o conteúdo referente ao modelo emocional. Existe uma adaptação do WordNetAffect para a língua portuguesa, chamada de WordAffectBr [Pasqualotti & Vieira, 2008].
- 3) SentiNet [Cambria & Olsher; Rajagopal, 2014]: Este léxico atribui a polaridade de textos a nível semântico, utilizando informações de senso comum, web semântica e técnicas de computação afetiva [Paim, 2016].
- 4) EmoSenticNet [Poria et. al., 2013] Atribui 6 emoções do WordNetAffect (raiva, alegria, repugnância, tristeza, surpresa e medo) por representação binária aos conceitos do SenticNet com a informação de polaridade referente a estas emoções.
- 5) EmoSenticSpace [Poria et. al., 2014] é a combinação do ConceptNet que consiste em um grafo que descreve o conhecimento humano em geral [Speer & Havasi, 2013] e o léxico semântico afetivo EmoSenticNet descrito acima.

### 4.3 Técnicas bottom-down

Neste tipo de abordagem não existe dicionário com as palavras pré-categorizadas. Existem diversas técnicas utilizadas na abordagem *top-down*, podemos dividir estas técnicas em nível de caracteres, palavras, sentenças e estilo. Dividimos esta seção em quatro subseções explicando em detalhe cada uma delas.

As ferramentas computacionais utilizadas para extração de características *bottom-down* são desenvolvidas pela especialidade da inteligência artificial chamada de NLP (*natural language processing*).

#### 4.3.1 Técnicas a nível de caracteres.

Neste tipo de técnica, o texto é abstraído como uma mera sequência de caracteres, podendo ser contabilizadas letras, dígitos, caracteres especiais, etc. Os caracteres podem ainda ser agrupados utilizando o conceito de n-grams, ou seja, é possível extrair sequências de 2, 3, ou mais caracteres, e podem ainda ser processados por métodos de compressão.

Utilizando esta técnica é possível realizar a contagem de letras (caixa baixa, caixa alta), dígitos, pontuações, *emoticons*, caracteres especiais. Todas estas técnicas de contagem podem utilizar o conceito de n-grams, expandindo o espaço de características, onde sequências de caracteres são contadas produzindo novas características textuais, por exemplo “sou extrovertido” em uma contagem 2-grams poderia produzir as features (so), (u ), (ex), (tr), (ov), (er), (ti),(do). No que diz respeito aos caracteres n-grams, o valor de n pode capturar diferentes contextos. Um n pequeno (2,3) é uma representação de parte de palavras (sílabas) e n grandes (5,6) capturam mais elementos léxicos e temáticos, sendo assim o valor para n é dependente da linguagem natural e do tipo de representação desejada. O problema da escolha de valores fixos para n pode ser remediado com técnicas que utilizam valores de n variáveis [Forsyth & Holmes, 1996], sendo assim poderíamos extrair caracteres de n-grams de 1 a 4, por exemplo ( $n = 1, 2, 3... k$ ). Existem técnicas mais refinadas que podem ser aplicadas neste sentido, construindo uma representação em árvores [Zhang & Lee, 2006] representando todos os n-grams variáveis possíveis e os contabilizando como *features* de grupos e técnicas que utilizam outras representações como redes de *markov* [Marton et. al., 2005].

Finalmente, existem ainda técnicas de compressão que podem ser aplicadas a nível de caracteres [Benedetto et al., 2002] [Marton et, al., 2005], esta técnica consiste em utilizar um modelo de compressão de um texto para comprimir outro texto, se os textos tiverem muitas similaridades a nível de caracteres n-grams (ex: escritos pelo mesmo autor), o tamanho relativo aos bits gerados pela compressão será menor. Estes modelos são baseados em repetições de sequências de caracteres.



### 4.3.2 Técnicas a nível de palavras.

As técnicas a nível de palavras são uma abstração um nível acima das técnicas a nível de caracteres sendo estas as técnicas mais comumente utilizadas nos modelos de TB-APR, estas técnicas são referenciadas na literatura como *bag-of-words* (BOW).

O modelo mais simples de extração de características que utiliza BOW é chamado de *term-frequency* (TF), neste modelo um atributo por palavra encontrada no texto, em todos os textos dos documentos de *corpus*, e depois é contado quantas vezes estes atributos apareceram em cada documento. Um modelo de contagem de palavras um pouco mais elaborado é o *term frequency – inverse term frequency* TF-IDF, onde um algoritmo seleciona as k-melhores palavras de um *corpus*, se baseando na frequência das palavras, mas se estas palavras forem comuns a outros documentos um contra-peso será utilizado (frequência inversa). Os algoritmos de extração de características TF e TF-IDF possuem referência na literatura como *StringToWordsVector* [Witten & Frank, 2005]. Abaixo, segue a fórmula 2 utilizada para calcular o TF-IDF.

$tf - idf(t_i, d_j) = tf(t_i, d_j) * \log \frac{n}{df_i}$	(2)
---	-----

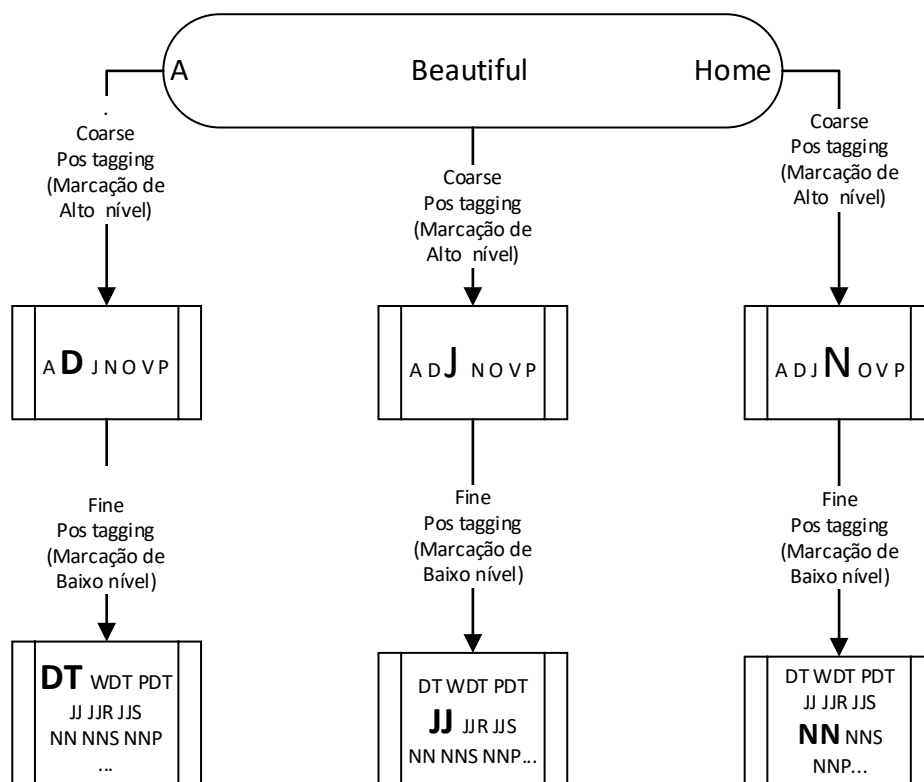
Onde *tf* é o *term frequency* que representa o número de vezes que a termo  $t_i$  ocorre no documento  $d_j$ ,  $n$  é o número total de documentos e  $df_i$  é o total de documentos que possui o termo  $i$ .

Tanto o TF quanto o TF-IDF podem utilizar representações em n-grams ou n-grams variáveis ( $n = 1, 2, 3 \dots k$ ), a utilização de n-grams expande bastante o espaço de características. Além do TF-IDF, é possível no modelo BOW utilizar técnicas a nível de tópicos.

A inferência automática de tópicos é uma área bastante ativa da computação [Jelodar et. al., 2017]. Os tópicos são conjuntos de palavras que possuem um sentido, mas são calculados de forma estatística pura, sem usar parsers semânticos. Um exemplo pode ser dado pelo tópico “família”. Este tópico contém as seguintes palavras: pai, mãe, filho, casa, parque, passeio, praia, viajar. Para inferir o tópico, uma estatística é calculada para cada palavra, indicando qual a probabilidade desta palavra aparecer em um documento junto com as outras palavras. Depois de inferir possíveis tópicos, calcula-se a probabilidade de cada documento pertencer ao tópico. Finalmente, cada documento possuirá um atributo por tópico detectado no *corpus*, na forma de uma porcentagem indicando a probabilidade daquele tópico estar presente no documento.

### 4.3.3 Técnicas a nível sintático.

Estas técnicas fazem o uso de *parsers* sintáticos para separar os textos em *tags parts-of-speech* (POS-tags), ou seja, a marcação da classe gramatical relacionada ao discurso. Os *parsers* sintáticos são as ferramentas do estado da arte da NPL, com estas ferramentas é possível extrair dois tipos principais de características de acordo com a granularidade de POS-tags desejada, estas tags podem ser do tipo *Coarse Grain* (alto nível) ou *Fine Grain* (baixo nível). O *parser* sintático é sempre dependente da linguagem natural. Um exemplo de extração destas tags é apresentado pela Figura 11, em que se trata de um *parser* sintático desenvolvido para a língua inglesa [Horsmann & Torsen, 2016].



**Figura 11.** Pos-tags (marcação de classe gramatical): Coarse Grain (alto nível) & Fine Grain (baixo nível). Adaptado de [Horsmann & Torsen, 2016].

Cada sigla na Figura 11 se refere a uma POS-Tag, DT (determiner), JJ (adjective) e NN(Noun). Estes tipos de características podem ser utilizados em conjunto com a abordagem n-grams, produzindo n-grams de POS-Tags, ou seja, sequencias de partes do discurso encontradas nos textos.

### 4.3.4 Técnicas de estilometria.

A área da computação chamada de *authorship attribution*, que se dedica a diferenciar textos de diferentes autores. Para isso, são utilizadas certas técnicas de extração de características textuais que procuram extrair um conhecimento denominado pela literatura como *style markers* (marcadores de estilos) [Stamatatos et. al., 2001] [Stamatatos et. al., 2009]. Podemos citar os seguintes marcadores de estilo:

- 1) Type-token ratio [Stamatatos et. al., 2009]: Relação do número de palavras do vocabulário com o número de palavras do documento.

$f(ttr) = \left( \frac{\text{count}(D_v)}{\text{count}(D_w)} \right) * 100$	(3)
---	-----

Onde  $\text{count}(D_v)$  é o número total de palavras do vocabulário presente no documento e  $\text{count}(D_{st})$  é o número total de palavras do documento.

- 2) A Métrica *readability of a text* (RT) proposta por Flesch-Kincaid [McClure, 1987] serve para medir a complexidade de leitura um texto.

$f(rt) = (206.835 - 1.015) * \left( \frac{\text{count}(D_w)}{\text{count}(D_{st})} \right) - 84.6 * \left( \frac{\text{count}(D_{sy})}{\text{count}(D_w)} \right)$	(4)
--	-----

Onde  $\text{count}(D_w)$  é o número total de palavras do documento e  $\text{count}(D_{st})$  é o número total de sentenças do documento e  $\text{count}(D_{sy})$  é o número total de sílabas do documento.

- 3) *Textual errors* (erros textuais): Podendo serem contabilizados através de ferramentas de correções ortográficas.
- 4) *HapaxLegomas*: Palavras que aparecem apenas uma vez nos documentos.

## 4.4 Técnicas Híbridas

É possível combinar abordagens *top-down* e *bottom up*, em um exemplo prático na aplicação da maioria léxicos afetivos é possível em um primeiro momento encontrar as palavras relevantes ao documento através de uma técnica *bottom-up* como o TF, TF-IDF ou tags POS ajustando parâmetros em cada uma delas e depois utilizar o conhecimento de um léxico sobre estas palavras, realizando a contagem de categorias [Paim, 2016].

Os experimentos preliminares relatados nesta dissertação utilizam este tipo de técnica e detalham com bastante riqueza como é possível combinar uma abordagem *bottom-down* com uma *bottom-up*.

## 4.5 Conclusão

Não existe consenso na literatura referente a modelos de TB-APR sobre a melhor técnica a ser utilizada. Alguns autores preferem técnicas *top-down* [Mairesse, 2007], outros trabalhos utilizam apenas técnicas *bottom-up* [Park et. al, 2015] ou ainda usam técnicas híbridas combinando abordagens *top-down* com abordagens *bottom-up* [Paim, 2016].

Apesar da grande variedade de técnicas de extração de características, não foi encontrado na literatura nada que justifique utilizar apenas um tipo específico de técnica. Sendo assim, o ideal é testar diversas técnicas e descobrir empiricamente qual técnica ou conjunto de técnicas é a mais adequada ao modelo gerado, sendo interessante utilizar algoritmos de ranqueamento das melhores características. O próximo capítulo especifica os paradigmas de aprendizagem de máquina para modelos de TB-APR.

## 5 Aprendizagem de Máquina Supervisionada para TB-APR

Este capítulo tem como objetivo expor os principais paradigmas de aprendizagem de máquina utilizados no problema de TB-APR. Não é objetivo deste capítulo mostrar detalhadamente o funcionamento de cada indutor, mas sim detalhar em alto nível as etapas e paradigmas utilizados na aprendizagem de máquina supervisionada (ML). Dividimos este capítulo em duas seções, a primeira seção explica os processos de amostragem dos dados, que é a etapa de pré-requisito para a aplicação dos paradigmas de algoritmos indutores, discutidos na segunda seção.

### 5.1 Amostragem de dados

Amostragem de dados são métodos para a seleção de amostras necessárias para o processo de aprendizagem de máquina supervisionada. Entendemos que as técnicas de amostragem de dados possuem a mesma importância para a aprendizagem de máquina supervisionada que as técnicas de pré-processamento para a extração de características.

Os algoritmos indutores requerem pelo menos duas amostras de um *corpus*, uma de treinamento, usada para a construção do modelo e uma de testes, estas amostras devem ser representativas. Para a seleção destas amostras *algoritmos de estratificação* são empregados, utilizando o atributo meta como referência para produzir boas amostras, chamadas de *stratos*. Quando utilizamos uma amostra de treinamento e uma de testes, chamamos o método de amostragem de *hold out*, geralmente é usada a porção de dois terços da amostra para treinamento e um terço para testes. O método de *hold out* pode eventualmente produzir *overfitting* do modelo de TB-APR, sendo assim geralmente é utilizado o método de *validação cruzada* [Kohavi, 1995]. Nesta técnica, a amostra é dividida em  $k$  amostras de treinamento e teste chamadas de *folds* que são mutuamente exclusivas e

do mesmo tamanho. O processo é repetido  $k$  vezes de modo que todo subconjunto de treinamento e testes seja utilizado, no fim do processo uma média da medida de desempenho dos modelos de cada *fold* é calculada. Existe também uma variante da técnica de *validação cruzada* que usualmente é utilizada com indutores do tipo *lazy* (não constroem modelo), onde o  $k$  é igual ao número total de instâncias.

No que diz respeito a amostragem de dados em TB-APR, existe ainda o problema do desbalanceamento de dados, sendo assim, em um problema de classificação, as instâncias de dados da amostra podem estar concentradas em determinadas classes, com outras classes possuindo uma pequena quantidade de instâncias. Similarmente, no problema de regressão, ao tentarmos aproximar a distribuição da amostra a uma curva normal, podemos verificar que às vezes este processo não é possível, com os *scores* de personalidade concentrados em *ranges* de valores específicos da escala (ex: distribuições desviadas à direita).

Para o problema relatado no parágrafo acima, existem técnicas de amostragem que são divididas em dois grupos [Appel, 2010]:

- 1) *Oversample*: Algoritmos que introduzem novas instâncias sintéticas (artificiais) quando estas possuem menos representação, procurando na medida do possível homogeneizar a representação de todas as instâncias da amostra.
- 2) *Undersample*: Podemos entender estes algoritmos como o processo inverso do *oversample*, mas com a mesma finalidade. Sendo assim, instâncias que possuem uma maior representação são apagadas da amostra, procurando na medida do possível homogeneizar a representação de todas as instâncias da amostra.

Existem diversos algoritmos de *oversampling* e *undersampling* e esta é uma área de pesquisa muito ativa. Apesar de em teoria estes algoritmos possuírem utilidade para o problema de TB-APR, não encontramos trabalhos na literatura que fazem uso deles. Este assunto merece investigação, mas exige cautela, pois as dimensões da personalidade são bastante sensíveis a variáveis estatísticas, culturais, subjetivas, entre outras. Geralmente, para evitar problemas de *overfitting*, quando se trabalha com estes algoritmos, a base é dividida em testes e validação a priori. Em seguida, o modelo é construído e testado na base de testes onde as técnicas de amostragem *undersampling* e *oversampling* são aplicadas. Depois o modelo é retestado na base de validação, que possui uma amostra original da base de dados desbalanceada.

A próxima seção descreve os paradigmas de aprendizagem de máquina supervisionada que são utilizados nos modelos de TB-APR, descritos pela literatura.

## 5.2 Paradigmas de aprendizagem de máquina supervisionada para TB-APR

A escolha do paradigma de AM é de vital importância para os modelos de TB-APR. Esta escolha interfere diretamente nas escalas de personalidade descritas pelos inventários, sendo assim certos paradigmas alteram as escalas de personalidade simplificando-as, decompondo ou alterando sua forma original [Oberlander & Nowson, 2006].

Cada paradigma possui sua própria gama de algoritmos indutores, estes indutores se dividem em dois grandes grupos: aqueles que tentam prever uma ou mais *variáveis categóricas*, chamados de *classificadores* e aqueles em que tentam prever uma ou mais *variáveis numéricas contínuas*, chamados de regressores. De um modo geral, a tarefa de regressão geralmente *abstrai problemas mais complexos* que a tarefa de classificação; assim, nesta dissertação, utilizamos a palavra *simplificação* para descrever o *processo de transformação* de um problema de regressão em um problema de classificação.

Como a personalidade geralmente é calculada pelos instrumentos psicométricos em scores n-dimensionais referentes a traços, facetas e outros mecanismos psicológicos relacionados, no ponto de vista computacional, a personalidade é tipicamente um problema de previsão de diversas variáveis, sendo natural que um modelo de TB-APR considere e tente prever todas as variáveis. Entretanto, muitas vezes podemos querer transformar o modelo de previsão de n-variáveis em n-modelos que tentem prever uma variável por vez, ajustando cada modelo e especializando-o em traços, facetas e outros mecanismos psicológicos relacionados específicos. Nesta tese, utilizamos a palavra *decomposição* para fazer referência ao processo de transformação destes últimos modelos.

Todo paradigma de ML possui vantagens e desvantagens, sendo necessário analisar a viabilidade de cada um deles para a construção do modelo de TB-APR. Para explicar cada paradigma, propomos a seguinte formalização:

Sejam  $X_k = \{x_1, x_2, x_3, \dots, x_n\}$  o espaço de n características textuais referente ao indivíduo ou instância  $k$  e  $Y_k = \{y_1, y_2, y_3, \dots, y_n\}$  seus respectivos *atributos meta*, referentes as pontuações de personalidade n-dimensionais de cada indivíduo ou instância  $k$  consideramos o *corpus*:

$C = \{(X_1, Y_1), (X_2, Y_2), (X_3, Y_3), \dots, (X_k, Y_k)\}$ , que são os dados necessários para os algoritmos *indutores* construir modelos TB-APR, que compreendam os paradigmas de ML detalhados nas subseções abaixo.

### 5.2.1 Paradigma de classificação binária

Cada variável  $y_n$  pertencente a  $Y_k$  é simplificada no que diz respeito a seus valores numéricos, transformando o problema original de regressão multi-target em um problema de classificação binária do tipo multi-label. Em seguida, o problema de classificação multi-label é decomposto em  $n$  problemas de classificação binária, totalizando  $n$  classificadores binários independentes que irão produzir um modelo de TB-APR por traço de personalidade. Apesar deste paradigma ser amplamente utilizado no problema de TB-APR [Argamon, 2005] [Oberlander & Nowson, 2006], ele introduz dois graves *bias* já descritos na motivação desta tese:

- 1) O processo de simplificação utiliza a técnica de aproximação da distribuição dos traços de personalidade a uma curva normal, e nem sempre isto é possível, pois alguns traços psicológicos possuem desvios na distribuição da escala de scores (ex: *right skewed distributions*). A literatura se refere à técnica de simplificação como conversão da personalidade em Z-scores [Celli, 2013].
- 2) No paradigma binário de classificação, os desvios padrões são utilizados para definir os extremos de cada traço da personalidade, isto é uma simplificação muito grosseira do que é uma escala de traço de personalidade, pois estas escalas não foram concebidas para trabalhar com valores extremos [Johnson, 2014].
- 3) O paradigma de classificação binário tem uma probabilidade alta de introduzir o problema de *overfitting*, principalmente em bases de dados pequenas.

Uma forma de remediar estes efeitos colaterais é conceber modelos de TB-APR utilizando o paradigma de classificação multi-classe que será explicado na próxima subseção. As métricas mais comuns utilizadas em TB-APR para avaliar o desempenho de paradigmas de classificação binária são a acurácia e a medida *f1 score*.

### 5.2.2 Paradigma de classificação multi-classe

O paradigma de classificação multi-classe, onde para uma variável  $y_n$  pertencente a  $Y_k$  é simplificada no que diz respeito a seus valores numéricos, transformando o problema original de regressão multi-target em um problema de classificação do tipo multi-label. Em seguida, o problema de classificação multi-label é decomposto em  $n$  problemas de classificação de  $m$  labels ( $m = 3, 4, 5, \dots$ ), totalizando  $n$  classificadores multi-classe independentes, produzindo um modelo de TB-APR por traço de personalidade.



Este é um paradigma de classificação mais realista, onde pelo menos 3 classes são deduzidas do processo de simplificação por Z-scores, neste exemplo, cada dimensão da personalidade teria a classes *low*, *medium* e *high*.

Oberlander e Nowson (2006) mostraram que quanto mais classes são introduzidas (ex: *very low*, *low*, *medium*, *high*, *very high*) pior é a performance dos indutores, mas ao mesmo tempo aproxima o modelo computacional do problema real de reconhecimento da personalidade. Embora seja uma opção mais realista, este paradigma também é suscetível ao *bias* no que se refere à distribuições de traços de personalidade desbalanceados.

Existem 2 grupos diferentes de indutores utilizados para este paradigma:

- 1) Classificação multi-classe por classificação binária: estes indutores utilizam técnicas de transformação do problema multi-classe em classificação binária, utilizando as abordagens um contra todos, todos contra todos, entre outras.
- 2) Classificação multi-classe utilizando algoritmos diretos: usam indutores baseados nos vizinhos mais próximos, *k-class polychotomous logistic regression*, *k-class svm*, *multiclass perceptron*, entre outros.

### 5.2.3 Paradigma de classificação multi-label

O paradigma de classificação multi-label pode ser do subtipo binário ou multi-classe, englobando os paradigmas de classificação explicados anteriormente. Este paradigma não utiliza o processo de decomposição, ou seja, é construído apenas um modelo de TB-APR que tem como objetivo prever todas dimensões da personalidade. Existem dois conjuntos de algoritmos usualmente empregados na classificação multi-label [Madjarov, 2012]:

- 1) Os métodos de transformação do problema utilizam as técnicas *binary relevance*, *classifier chains*, *calibrated label ranking* e *random k labelsets* [Tsoumakas, 2007].
- 2) Os métodos de adaptação de algoritmos utilizam os indutores ML-KNN, ML-DT, Rank-SVM, CML, AdaBoost.MH, BP-MLL.

As medidas de avaliação de desempenho utilizadas neste paradigma geralmente levam em consideração todas as classes de forma simultânea, como é o caso da medida *Hamming Loss* que especifica a fração de labels previstos de maneira errada em relação ao número total de labels.

#### 5.2.4 Paradigma de regressão

Neste paradigma não existe a simplificação, os scores de personalidade continuam sendo representados por suas escalas contínuas originais no modelo de TB-APR, entretanto, o modelo é decomposto em n-regressores para cada  $y_n$ .

Este paradigma é bastante apropriado para tratar o problema de previsão da personalidade, possuindo a vantagem de poder usar medidas bastante eficazes e muito simples para medir a performance do modelo, como a correlação de *Pearson*. Existem trabalhos expondo modelos de TB-APR que trabalham com este paradigma [Mairesse, 2007], [Park et. al., 2015], entretanto as correlações encontradas nos experimentos destes trabalhos geralmente são fracas.

#### 5.2.5 Paradigma de regressão multi-target

Este paradigma utiliza indutores do tipo regressores multi-target. Eles também são referenciados na literatura como *multi-variant*, *multi-response*. Este paradigma se aproxima bastante do problema da personalidade: não faz simplificação das escalas, nem decompõe o modelo.

Assim como o paradigma de classificação multi-label existem dois grupos de indutores que podem ser utilizados: os de transformação do problema e os de adaptação de algoritmos. O trabalho de Borchani (2015) e seus colegas classifica os indutores que são utilizados neste paradigma e também explicam algumas medidas de avaliação de desempenho empregadas. Os tipos de algoritmos utilizados podem ser verificados na Tabela 5.

<b>Problem trasformation methods</b>	<b>Algorithm adaptation methods</b>
Random Linear Target combinations	Statistical methods
Separate Ridge regression	Multi-output SVR
Multi-target regressor stacking	Kernel methods
Regressor chains	Multi-target regression trees
Multi-output SVR	Rule methods

**Tabela 5.** Classificação de indutores multi-target, adaptado de [Bocharni et. al., 2015].

Este paradigma é detalhado no anexo 1, com acréscimos que resultaram dos experimentos preliminares realizados desta tese; conceitualmente, este é o paradigma que mais se aproxima do problema real da personalidade.

### 5.2.6 Paradigma de ranqueamento

O paradigma de ranqueamento trata a personalidade como um problema de ranqueamento. Neste paradigma o espaço de características é representado por um conjunto de funções binárias indicadoras, conforme a Fórmula 5 [Mairesse, 2007].

$h_{100}(x) = 1 \text{ (if } functionWords > 0.7 \text{) or } 0 \text{ otherwise}$	(5)
--	-----


Sendo assim  $x$  será 1 se o número de palavras funcionais for maior que 70%. Podemos então abstrair que um parâmetro único  $\alpha$  (neste caso  $\alpha = functionWords > 0.7$ ) é associado como indicador da função, sendo possível calcular o ranqueamento através da fórmula abaixo [Mairesse, 2007]:

$F(x) = \sum_s \alpha_s * h_s(x)$	(6)
-----------------------------------	-----

Utilizando a Fórmula 6 é possível ranquear a amostra, utilizando  $s$  diferentes funções binárias. Uma medida de avaliação de desempenho muito utilizada neste paradigma é o *ranking loss* [Mairesse, 2007] e a correlação de *Spearman* [Hollander & Wolfe; Chiken, 2013].

### 5.2.7 Paradigma estruturado

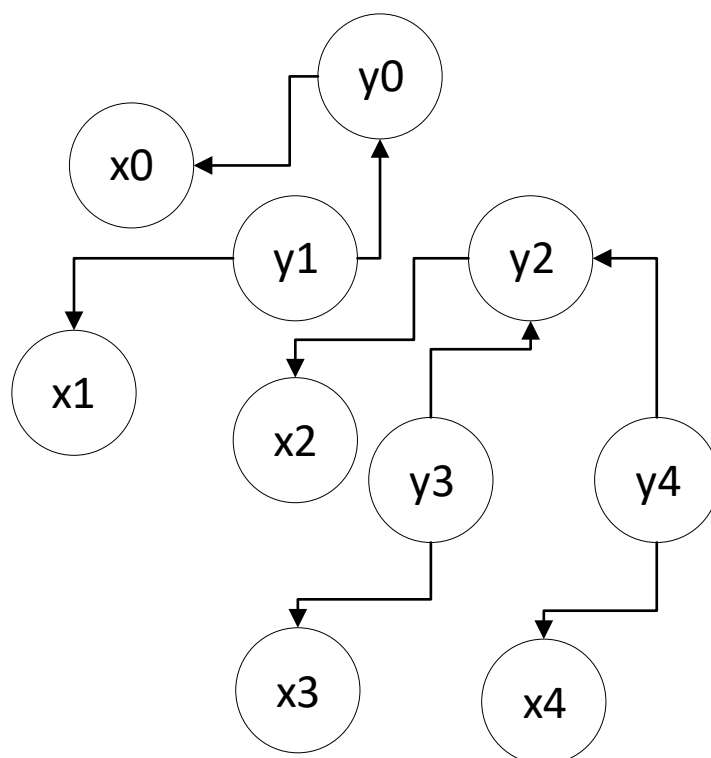
O paradigma estruturado utiliza indutores para prever objetos estruturados. Neste paradigma a personalidade é prevista como uma estrutura sequencial de labels. Os outros paradigmas de forma geral ignoram as correlações entre o espaço de características e as sequências de labels de diversas classes, isto não acontece no paradigma estruturado, que explora estas correlações. Um indutor estruturado basicamente define funções que decompõe o problema como um modelo *Hidden Markov Model* (HMM), representado pela Figura 12.



**Figura 12.** Modelo *Hidden Markov Model* (HMM) adaptado de [Lacoste - Julien, 2007].

O paradigma estruturado possui dois grupos de indutores [Lacoste-Julien, 2007]:

- 1) Modelo Gerativo: *Markov Random Fields* (MRF), estes indutores moldam todo espaço de probabilidades de  $X$  e  $Y$  de forma simultânea  $P(X, Y)$ . Como estes indutores moldam todo espaço de probabilidades conjunto (*joint probabilities*), é possível em um exemplo contornar valores faltantes em  $X$ . O modelo MRF pode prever  $P(X|Y)$ , assim como  $P(Y|X)$ , sendo assim estes indutores são mais flexíveis.
- 2) Modelo não Gerativo: Estes modelos não moldam todo espaço conjunto de probabilidades de  $X$  e  $Y$ , então estes modelos podem apenas executar a tarefa de previsão clássica  $P(Y|X)$ . Sendo assim estes indutores são mais específicos e úteis ao problema de TB-APR, como é o caso do *Conditional Random Fields* (CRF) [Lafferty et al, 2001].



**Figura 13.** Indutores estruturados adaptado de [Lacoste-Julien, 2007].

A Figura 13 mostra um exemplo de indutor estruturado, onde o modelo está sendo representado por um grafo acíclico. Os indutores estruturados CRF foram investigados em sua capacidade de prever a personalidade em um trabalho que está detalhado no capítulo 6 [Iacobelli and Cullota, 2013].

### 5.2.8 Paradigma de distribuição de labels

Este paradigma presume que os espaço  $n$ -dimensionais de  $Y$  referentes aos scores de personalidade de um *corpus* são na verdade uma distribuição de probabilidades. Sendo assim, o problema original, que tipicamente é de regressão multi-target, é transformado em um problema de distribuição de labels. Desta maneira é possível representar cada  $n$ -traço da personalidade pela Fórmula 7 [Xu et. al., 2017]. Esta fórmula transforma as escalas de personalidade em uma distribuição de labels.

$d_{y_n} = \frac{y_n}{\sum y_n}$	(7)
----------------------------------	-----

Onde  $d_{y_n}$  representa os score dos traços de personalidade  $y_i \in Y$ , referentes a uma instância  $k$  e  $D = \{d_{y_1}, d_{y_2}, d_{y_3} \dots d_{y_n}\}$  representa os novos scores de personalidade que irão substitui  $Y$ .

Este paradigma permite utilizar os seguintes grupos de indutores [Geng, 2016]:

1. Métodos que transformam o problema (PT-Bayes, PT-SVM).
2. Métodos que adaptam algoritmos (AA-kNN, AA-SVR).
3. Métodos específicos (SA-BFGS, CPNN) [Geng & Hou, 2015] [Geng, 2016] [Xu et. al., 2017].

### 5.3 Conclusão

É necessária cautela ao escolher o paradigma de aprendizagem de máquina para a construção de modelos de TB-APR. Nem todos os paradigmas tratam de forma adequada as escalas de personalidade, sendo assim o paradigma de classificação binária geralmente é o primeiro que deve ser descartado, mas isto não é verificado na literatura [Vinciarelli & Mohammadi, 2014]; [Ong et al, 2017]; [Bhamare & Kumar, 2019]; [Stajner & Yenikent, 2020]. Dependendo das escalas originais de personalidade, este paradigma introduz diversos *bias* que foram detalhados ao longo desta tese (Capítulos 1, 7, 8). Para aproximar o modelo de TB-APR do paradigma correto de ML é necessário analisar cuidadosamente o instrumento psicométrico e a escala dimensional de personalidade que este instrumento produz.

Os inventários de personalidade que produzem uma escala numérica, possuem o paradigma de regressão indicado. Estas escalas quase sempre são n-dimensionais, neste sentido é interessante utilizar um paradigma que aproveite a informação de previsão das dimensões a priori, antes de elaborar um modelo final. Neste aspecto o paradigma de regressão *multi-target* é adequado. Utilizamos este paradigma em nossos experimentos preliminares (Anexo 1). Uma continuidade possível a esses experimentos, seria um modelo que transformasse o problema de regressão *multi-target* em n-regressores mais especializados. Este processo de decomposição possibilitaria o *tuning* do indutor para cada dimensão da personalidade. Posteriormente uma análise de desempenho poderia comparar os dois modelos e verificar qual paradigma de regressão é o mais adequado.

Alguns instrumentos de aferição da personalidade fazem uma análise quantitativa e/ou qualitativa e depois produzem uma escala categórica multi-dimensional da personalidade. Neste sentido, é possível deduzir as escalas categóricas, fazendo uma regressão da análise quantitativa e depois consultar tabelas de normalização (ex. [Vaz & Alchieri, 2016, pp. 118 - 126]). Por outro lado, a tarefa de regressão em TB-APR tem mostrado correlações fracas (capítulo 6), podendo ocorrer uma variância exagerada nas escalas categóricas após consultar as tabelas de normalização. Sendo assim, o paradigma mais adequado para instrumentos psicométricos que possuem escalas categóricas é o da classificação multi-classe, possibilitando o *tuning* de cada classificador para cada dimensão da personalidade. Este paradigma irá funcionar melhor em escalas inferidas por Z-scores (3 classes) e tenderá a degradar a performance à medida que existirem classes adicionais. Finalmente seria possível comparar a performance de classificadores multi-classe com classificadores multi-label, podendo estes últimos serem utilizados para prever as categorias utilizando a informação de previsão de todo o modelo dimensional. Neste caso, o indutor utilizado no paradigma multi-label deve ser preferencialmente do tipo multi-classe, suportando prever n-categorias em cada dimensão, considerando todas as dimensões cobertas pelo instrumento de aferição da personalidade.

Finalmente, podemos considerar que é o instrumento psicométrico, o qual baseado em sua escala de personalidade, deve selecionar o paradigma de *machine learning* mais adequado. Neste sentido, um modelo de TB-APR não deve fazer nenhuma simplificação grosseira das escalas dimensionais da personalidade, sob a pena de construir um modelo enviesado. O próximo capítulo faz um apanhado geral dos trabalhos que propuseram modelos de TB-APR.

## **6 Fundações de TB-APR**

Este capítulo faz um apanhado geral dos trabalhos relacionados a TB-APR. Procuramos organizar o capítulo com os artigos em uma ordem cronológica.

Para selecionar os trabalhos deste capítulo, as palavras-chave relacionadas a tarefa de TB-APR foram procuradas nos buscadores e mecanismos de acesso às bases científicas. Não houve exclusão por janela de tempo. Os primeiros trabalhos foram localizados no início dos anos 2000. Foram excluídos os trabalhos que não tratavam exclusivamente do reconhecimento automático de personalidade em textos, como por exemplo, trabalhos que focavam em características multimodais, desvirtuando o foco dos textos. Também excluímos trabalhos que tratavam da percepção ou síntese automática da personalidade. Procuramos fazer a revisão da literatura em ordem cronológica.

Este capítulo possui três seções: a primeira comenta de forma geral os trabalhos utilizados em TB-APR, e a segunda possui uma tabela comparando os trabalhos e a última conclui o capítulo.

## 6.1 Discussão geral sobre os trabalhos.

Existem evidências de que a computação da personalidade nasceu dos esforços de James W. Pennebaker e Laura A. King, em 1999, após a publicação do trabalho “*Linguistic Styles: Language use as an individual difference*”. O objetivo deste trabalho não foi criar um modelo de TB-APR, e sim testar a confiabilidade das categorias do léxico LIWC [Pennebaker & Francis, 1999] para avaliar as diferenças individuais em diferentes *corpus*. Este trabalho se dividiu em três etapas (i) *establishing reliability of language use*, (ii) *exploring the factor of language use*, (iii) *validity studies*. Os *corpus* foram submetidos a contagens de palavras por *top-down*, gerando um percentual por documento em cada categoria LIWC. Nestes experimentos foram utilizados vários conjuntos de diferentes amostras textuais na forma de *corpus*, onde a estatística *alpha* e a correlação de *Pearson* foram sistematicamente utilizadas para verificar a confiabilidade do LIWC em cada uma das três etapas:

- 1) A estatística de consistência interna *alpha de cronback* (Fórmula 1, seção 3.1.1) das categorias do LIWC foi calculada, em relação a cada *corpus* textual.
- 2) A confiabilidade do LIWC foi calculada *em cada corpus*, correlacionando a contagem de categorias do LIWC em documentos textuais com o mesmo tópico, mas escritos em datas diferentes pelos indivíduos.
- 3) A confiabilidade do LIWC *entre tópicos*, correlacionando a contagem de categorias do LIWC em *corpus textuais separados*, utilizando tópicos textuais diferentes, mas escritos pelos mesmos indivíduos.
- 4) Um estudo de correlação de fatores do LIWC com dois instrumentos psicométricos (um teste projetivo e um inventário de personalidade).

A etapa (i) focou na consistência interna das categorias LIWC; para isso utilizou três *corpus* distintos escritos na língua inglesa. O primeiro (C1) era composto de 18 ensaios textuais por indivíduo, controlados pelo tópico “*significant event sheet*” que foram escritos por 15 indivíduos de uma clínica de recuperação de dependentes químicos. O segundo (C2) *corpus* era uma base de dados conhecida pelo nome *essays*. Este *corpus* futuramente foi bastante ampliado, se tornando referência em diversos estudos de TB-APR. Os ensaios são um conjunto de 10 textos diários por indivíduo,



escritos por 34 estudantes. Todos os textos foram controlados pelo tópico “*a stream of consciousness*”. O terceiro *corpus* (C3) era uma lista de 40 autores de artigos da *Membership Roster of the Elite Social Psychology*, onde 15 *abstracts* de publicações de cada autor foram selecionados do *PsycINFO database*.

A estatística de consistência interna alpha (Fórmula 1, seção 3.1.1) foi computada nas 72 categorias disponíveis no LIWC, medindo a consistência dos itens das categorias referentes às dimensões do LIWC em relação a cada *corpus*. A medida avaliação de desempenho da etapa (i) considerou a *porcentagem dos alphas maiores que 0.60* calculados nas n-categorias das 4 dimensões principais do LIWC (*Language composition, Psychological process, Relativity e Current concerns*). Entre as dimensões principais, a dimensão “*Language composition*” se mostrou a mais consistente, com uma porcentagem de alphas acima de 0.60 encontrados em cada *corpus* representada pelas tuplas (0.83, C1), (0.88, C2), (0.39, C3). Adicionalmente quando se excluía categorias não usadas ou usadas raramente (< 0.1%) obteve-se a porcentagem melhor de alphas acima de 0.60 para esta dimensão (*Language Composition*), representados pelas tuplas (0.83, C1), (0.83, C2), (0.69, C3).

Na etapa (ii) os autores propuseram-se a fazer um novo estudo de confiabilidade, utilizando um *corpus* mais significativo e em seguida fazer a análise fatorial das categorias mais consistentes,. Participaram do experimento (ii) 800 estudantes de psicologia, que foram orientados a escrever 4 ensaios textuais, com 2 ensaios sobre o tópico “*stream of consciousness*” (SOC) e mais 2 ensaios sobre o tópico “*coming at college*” (CTC), estes ensaios foram coletados entre 1992 a 1997. Nesta etapa, estabeleceram-se quatro critérios de exclusão:

- 1) As categorias deveriam ter uma consistência interna mínima de  $\alpha > 0.60$ , baseado nos resultados da etapa anterior (i).
- 2) Se alguma das categorias tivesse palavras sobrepostas, elas deveriam ser ignoradas em prol de categorias mais específicas.
- 3) As categorias sem relação de significados de palavras foram excluídas.
- 4) As categorias escolhidas deveriam estar presentes em pelo menos 1% dos ensaios textuais.

Obedecendo os critérios de exclusão estabelecidos, na fase (ii) foram selecionadas um total de 15 categorias do LIWC (*Words > 6 letters, First-person singular, Negations, Articles, Postive, Negative emotions, Causation, Insight, Discrepancy, Tentative, Social processes, Past tense, Present tense, Inclusive, Exclusive*). Esta etapa (ii) obteve os seguintes resultados preliminares:

1. A consistência interna para os indivíduos que completaram as 4 tarefas textuais referentes a este *corpus* (SOC + CTC, n= 610) variou entre (0.74, *Words > 6 letters*) e (0.44, *Past tense*).
2. Os coeficientes de confiabilidade (correlação entre contagens de palavras) obtidos entre os textos escritos e datas diferentes para o para o tópico SOC (n= 677) ficaram entre (0.46, *Words > 6 letters*) e (0.16, *Causation*), para o tópico CTC (n = 626) os mesmos coeficientes variaram entre (0.40, *Words > 6 letters*) e (0.12, *Insight*).
3. Os coeficientes de confiabilidade entre os tópicos SOC e CTC (n=743) ficaram entre (0.41, *Words > 6 letters*) e (0.14, *positive emotions*).

Ainda na etapa (ii) foi realizada a análise fatorial das categorias. Para verificar se a análise fatorial era recomendável foi utilizada a estatística de Kaiser-Meyer-Olkin (KMO) (Fórmula 8) [Cerny and Kaiser, 1977] a qual produziu um coeficiente de 0.633, indicando que a amostra era apropriada.

$KMO = \frac{\sum \sum_{j \neq k} r_{jk}^2}{\sum \sum_{j \neq k} r_{jk}^2 + \sum \sum_{j \neq k} p_{jk}^2}$	(8)
---	-----

Onde  $r_{jk}^2$  é o quadro do coeficiente de correlação entre  $x_j$  e  $x_k$  ou o quadrado dos elementos da matriz correlacional que não pertencem a diagonal e  $p_{jk}$  é o coeficiente de correlação parcial entre  $x_j$  e  $x_k$ .

Ainda na etapa (ii), foi realizada a análise fatorial das 15 categorias do LIWC. Na análise fatorial utilizou-se a técnica *principal component analysis* (PCA) com o algoritmo de rotação de eixos varimax. Uma solução ideal de 4 fatores foi encontrada, os fatores estão listados abaixo com a variância de cada um deles entre parênteses:

- 1) *Immediacy* (0.224): palavras da primeira pessoa singular (*I, me, my*), artigos (*a, an, the*), algumas palavras com mais de 6 letras, verbos no presente e discrepâncias (*would, should, could*).
- 2) *Making Distinctions* (0.103): palavras exclusivas (*but, without, except*), palavras com referências a tentativas (*perhaps, maybe*), negações (*no, not, never*), palavras de inclusão (*and, with*).
- 3) *The social past* (.098): verbos no passado, alguns verbos no presente, emoções positivas, preferências sociais.

- 4) *Rationalization* (.086): palavras causais (*because, reason*), palavras de *insight* (*understand, realize*), emoções negativas.

Na última fase (iii) dos experimentos foram traçadas correlações entre a aplicação do teste projetivo TAT (teste de apercepção temática) e os fatores do LIWC encontrados no experimento anterior (fase ii). Um corpus com 79 participantes foi rotulado com o teste TAT [Morgan & Murray, 1935] utilizando os slides usados nos estudos de McClelland (1985). As figuras utilizadas incluíram um homem e uma mulher sentados perto de um rio, um homem sentado em uma mesa de escritório, duas mulheres trabalhando em um laboratório, um homem mais velho e uma mulher mais nova andando a cavalo, e um homem e uma mulher em um trapézio. As sessões de aplicação do teste ocorreram em uma sala pequena com 1 a 7 participantes, onde os slides eram mostrados cada um por 10 segundos e depois eram dados 10 minutos para que histórias sobre o slide fossem escritas. O TAT produz escalas relativas aos traços de personalidade *need for achievement, need for affiliation* e *need for power*. Adicionalmente os participantes responderam um inventário chamado *Personality Research Form* (PRF) com 16 itens [Jackson, 1974]. O inventário PRF espera resposta em uma escala verdadeiro- falso para os itens, e no final produz uma escala sobre os traços de personalidade *achievement, affiliation* e *dominance*.

O TAT foi corrigido por dois especialistas que por concordância produziram os scores para as dimensões da personalidade avaliadas pelo teste. Depois os scores de cada dimensão foram dividido pelo número total de palavras do protocolo e, em seguida, esta proporção foi multiplicada por 1000. Sendo assim, os scores TAT se referem a 1000 palavras imaginárias do texto [Winter, 1989]. Depois os textos das histórias foram submetidos a contagem de palavras referentes aos fatores LIWC encontrados na fase (ii). Correlações baixas foram encontradas entre os fatores do LIWC e o traço *need for achievement* do TAT. Além do TAT e PRF, correlações baixas entre os fatores do LIWC e um inventário BigFive foram encontradas. A Tabela 6 mostra estas correlações.

Fatores LIWC	TAT - Need Need for achievement	TAT - Need for affiliation	TAT- Need for power	PRF achievement	PRF affiliation	PRF dominance
Immediacy	<b>-.33</b>	-.04	.04	.10	-.03	-.13
Making distinctions	-.18	.12	.12	.13	-.30	-.20
The Social Past	.23	.15	.15	.10	-.21	-.10
Rationalization	.20	-.03	-.03	-.16	-.12	-.14

**Tabela 6.** Correlações entre os fatores LIWC e os testes TAT e PRF [Pennebaker & King, 1999].

Observando a Tabela 6, notamos correlações mais fortes (em negrito) entre os fatores e o traço *need for achievement* no caso do teste TAT.

Os experimentos de Pennebaker e King não elaboram um modelo de TB-APR. Neste trabalho os autores não fazem a previsão da personalidade, mas verificam através da correlação a confiabilidade do LIWC em relação a diversos corpus textuais, e também em relação as dimensões de personalidade (ex: aumentando a contagem de palavras em um fator LIWC também aumenta o score de personalidade?). Sendo assim os valores da Tabela 6 não são referentes a uma previsão e sim são uma medida de confiabilidade em relação a um processo de contagem de categorias léxicas em um processo de pontuação dimensional da personalidade.

Os trabalhos de Pennebaker e King motivaram os trabalhos que fizeram a construção de modelos estatísticos para prever a personalidade. As pesquisas de Gill e seus colegas [Gill et. al., 2002] utilizaram um *corpus* de textos coletados de 105 estudantes universitários. A descrição deste *corpus* em detalhes pode ser encontrada em Oberlander et. al. [2006b]. No processo de construção do *corpus*, estudantes foram atraídos para uma página na web, na qual eles preencheram o inventário de personalidade e depois foram instigados a escrever dois e-mails controlados pelo tópico “*to a good friend whom they hadn’t seen for quite some time*” em que foram aconselhados a gastar em média 10 minutos escrevendo. Este *corpus* foi utilizado por vários trabalhos publicados por Gill e Oberlander. Neste trabalho [Gill et. al., 2002], todos indivíduos participantes foram submetidos a um inventário de personalidade baseado na teoria dos três fatores de Eysenck [Eysenck et. al., 1991] que produz escalas para os traços de personalidade extroversão, neuroticismo e psicotismo.

Todos os textos foram submetidos à contagens *top-down* utilizando o léxico LIWC. Adicionalmente a contagem de categorias do LIWC, o léxico MRC [Coltheart, 1981] também foi aplicado; sendo assim, os textos precisam passar por um pré-processamento onde um POS-tagger

identificou as frases e outras estruturas textuais (artigos, verbos, etc). Apenas o traço extroversão foi investigado. A técnica de ML utilizada foi de regressões múltiplas e a métrica de avaliação escolhida foi o coeficiente de determinação ( $R^2$ ). Este trabalho investigou apenas o traço extroversão (embora o *corpus* possuísse informação referente aos 3 traços dos fatores de Eysenck). Depois de realizar múltiplas regressões utilizando categorias do léxico LIWC, foi descoberto que as variáveis independentes *Word Count* (correlação negativa) e *Numbers* (correlação positiva) foram as mais promissoras para prever extroversão, produzindo um coeficiente de determinação de 0.08. Em outras palavras, quanto maior for a contagem de palavras de um texto e menor for a ocorrência de números deste texto, obtém-se um indicador de extroversão, explicando 8% da variância.

Quanto ao léxico MCR, a variável independente *Mean Concreteness* (correlação negativa) foi a mais promissora para prever extroversão, com um coeficiente de determinação de 0.05. Adicionalmente, os autores procuraram encontrar variáveis independentes que poderiam estar escondidas nos léxicos, sendo assim, utilizaram uma abordagem *bottom-up*, calculando a frequência de pares de termos adjacentes (bigramas). Nesta abordagem os scores de personalidade foram simplificados, utilizando Z-scores (high e low) e a significância dos bigramas foi calculada com a estatística *Log Likelihood*, onde os 50 melhores bigramas foram rankeados utilizando a correlação de *Spearman*, listando os bigramas comuns a introversão (low) e extroversão (high) e também os bigramas exclusivos de extroversão ou introversão.

Em 2004, os autores publicaram uma continuação deste trabalho [Oberlander & Gill, 2004] utilizando a mesma metodologia e *corpus* do primeiro trabalho [Gill et. al., 2002], mas desta vez trabalharam com o traço neuroticismo, encontrando os coeficientes de determinação 0.11 (correlação positiva com palavras inclusivas) quando o léxico LIWC foi utilizado e 0.14 (correlação positiva com a categoria frequência verbal) quando o léxico MRC foi utilizado. Depois, a amostra de neuroticismo foi dividida utilizando z-scores (desta vez utilizando as porções *high*, *mid* e *low*), e novamente utilizaram a correlação de *Spearman* para rankear os 50 bigramas mais significativos (de acordo com a estatística *log-likelihood*). Outra continuação deste trabalho pode ser encontrada no trabalho acadêmico de descrição do *corpus* [Oberlander et. al., 2006b], no qual o traço psicotismo também foi analisado. Adicionalmente, utilizando esta mesma metodologia, os autores analisaram o ranqueamento de features do tipo *part-of-speech* para os três traços de personalidade correspondentes aos fatores de Eysenck.

No que diz respeito a modelos utilizando o paradigma de classificação binária e classificação multi-classe, o trabalho de Oberlander e Nowson (2006), utiliza um corpus baseado no BigFive. O Capítulo 1 descreve alguns detalhes este trabalho como parte da motivação desta tese. Este trabalho

não investigou o traço *openness to experience* por ter uma distribuição desviada à direita, não permitindo a simplificação do *dataset* pela técnica dos Z-scores [Nowson & Oberlander, 2006c]. No ano seguinte Nowson e Oberlander (2007) construíram modelos de classificação muito parecidos com o trabalho anterior [Oberlander & Nowson, 2006], mas utilizaram um *corpus* maior. Este *corpus* possuía 1672 indivíduos, todos eles foram rotulados por um inventário de personalidade BigFive baseado em memes, não validado cientificamente. Os paradigmas de ML foram exatamente iguais aos do primeiro trabalho [Oberlander & Nowson, 2006], utilizando os métodos do *Z-score* para simplificar o problema. Este último trabalho [Nowson & Oberlander, 2007] produziu acurácias ruins, entre .32 e .59 ao ser comparado ao primeiro trabalho [Oberlander & Nowson, 2006] que produziu acurácias de até 100%, mas sabemos que este último tinha um grave problema de *overfitting* devido a vários fatores (simplificação dos scores de personalidade, amostra muito pequena, etc).

Em 2009, Gill e seus colegas expandiram o *corpus* de Nowson e Oberlander (2007) e publicaram um trabalho investigando blogs [Gill et. al., 2009]. Este *corpus* passou a ser referenciado como “*big and dirty*”, em contraposição com o *corpus* “*small and clean*” que foi utilizado no trabalho de Oberlander e Nowson em 2006. Na época deste trabalho, o *dataset big and dirty* já possuía 5042 bloggers rotulados por um inventário de personalidade baseado em memes. Os traços do BigFive foram simplificados de acordo com os *z-scores* em *low*, *mid*, *high*. Depois dos dados serem pré-processados, a ferramenta de análise do LIWC TAWC [Kramer et. al., 2006] foi utilizada. As categorias LIWC escolhidas foram baseadas em hipóteses relativas a resultados encontrados nas pesquisas anteriores, em que os autores utilizaram o *corpus* “*small and clean*” [Oberlander et. al., 2006]. Para cada traço de personalidade foi construído um modelo regressão ordinal, a métrica de avaliação de desempenho utilizada foi o coeficiente de determinação. Os melhores resultados obtidos estão representados nas tuplas (O, 0.0163), (C, 0.0106), (E, 0.0133), (A, 0.0155) (N, 0.0133).

Argamon et.al [2005] elaboraram um trabalho de TB-APR sob a motivação de testar e compreender novos métodos para a tarefa de “author profiling”, para isso utilizaram o *corpus* da base *essays* [Pennebaker & King, 1999] rotulado por um inventário Big Five, utilizando uma técnica de extração de características única, baseada em um *parser* sistêmico funcional. Neste trabalho, os autores optaram pelo estudo das dimensões, a N e a E e o problema original de regressão foi decomposto e simplificado em um problema de classificação (*high* e *low*) utilizando a técnica dos *z-scores*, e considerando apenas os terços superiores e inferiores de cada dimensão.

Na época deste trabalho a base *essays* [Pennebaker & king, 1999] possuía 1157 documentos controlados pelo tópico SOC e mais 1106 documentos controlados pelo tópico “*an essay of deep self analysis*” (DSA) com um total de 2.263 documentos. Para extrair características textuais os autores

consideraram 4 diferentes *feature spaces*: uma *standard function word list*, *conjunctive phrases*, *modality indicators* e *appraisal adjectives and modifiers*.

A extração de palavras funcionais foi justificada para testar indícios de estudos em que as palavras funcionais são processadas de forma diferente pelo cérebro humano [Gothner and Pennebaker, 2003] e [Cohn et al, 2004], em certas situações, como é o caso de pessoas abaladas psicologicamente devido a um trauma coletivo onde existe uma tendência em pronunciar mais a terceira pessoa do plural em detrimento à primeira do singular. Foram separadas 675 palavras funcionais que foram contadas utilizando a Fórmula 9 [Argamon et. al., 2005]:

$f(w) = \frac{\text{count}(w)}{\sum_{w' \in FW} \text{count}(w')}$	(9)
--	-----

Onde  $w$  é uma palavra funcional,  $\text{count}(w)$  é o total de palavras no documento e  $\sum_{w' \in FW} \text{count}(w')$  é a soma de contagens de palavras funcionais que estão presentes em um documento.

As outras características extraídas se basearam na *Theory of Systemic Functional Grammar* (SFG), um paradigma linguístico que enxerga a linguagem em termos funcionais, modelando a linguagem textual como um sistema de escolhas semânticas [Matthiessen and Bateman, 1991]. A chave para compreensão SFG são as metafunções textuais (*resources for presenting information to a context*), interpessoais (*resources for social roles and relations*) e ideacionais (*resources for constructing experience in terms of objects and events*) [Whitelaw and Argamon, 2004]. Esta abordagem permite visualizar a linguagem como um sistema de escolhas de mutualidade exclusiva, caracterizando a variação no estilo do uso da linguagem.

O processo de extração de features da SFG se baseou no trabalho de Whitelaw e Argamon [2004] que propõe uma arquitetura de software para o paradigma SFG. Como elaborar um software que faça o parser completo de SFG é um problema muito complexo, parte desta complexidade foi evitada através de um parser parcial encarregado de identificar unidades semânticas nos textos. O parser representa o sistema funcional semântico em um grafo direcionado e acíclico, onde o node raiz representa uma categoria semântica e os arcos são interações OR / AND entre subelementos semânticos desta categoria, chamados de unidades, que por sua vez podem se relacionar com outras unidades mais específicas permitindo interações disjuntivas (OR) ou conjuntivas (AND). No processo da extração de características as unidades podem formar sets de duas ou mais unidades, se ambas estiverem presentes no texto e também podem existir sets ordenados, modelando, por exemplo,

conjunções entre condições ou descrevendo unidades léxicas avaliadas de forma individuais (ex: a unidade “*Dear*” no início do documento seguida de uma unidade referente a um high-level constructo como “*well-wishing*” algum momento depois). Para extrair as features SFG, a Fórmula 10 [Argamon et.al., 2005] foi utilizada para computar a frequência relativa das unidades, sendo assim é possível identificar frequências relativas a diferentes sets, sequências, categorias e sistemas.

$RF_d(O_1 O_2) = \frac{N_d(O_1, O_2)}{N_d(O_2)}$	(10)
--	------

Onde  $RF_d(O_1, O_2)$  é a frequência relativa da opção  $O_1$  em relação a opção  $O_2$ ,  $N_d(O_1, O_2)$  é o número de unidades com a opção  $O_1$  e  $O_2$  e  $N_d(O_2)$  é o número de unidades com opção  $O_2$ .

No total, foram extraídos 3 sistemas semânticos na forma de vetor numérico de frequências relativas: *cohesion*, *assessment* e *appraisal*, caracterizando no total 4 espaços de características, somadas com o das contagens de palavras funcionais. O processo de *machine learning* utilizou a validação cruzada e o indutor SMO.

Para a avaliação dos resultados, os autores optaram pela acurácia. Na base SOC a acurácia média foi de .58 (N, .58), (E, .58), sendo que o traço neuroticismo se beneficiou mais das *features* do sistema semântico. O traço extroversão se beneficiou mais com todas as *features* combinadas. A base DAS teve resultados mais modestos com uma acurácia média de .56 (N, .57), (E, .55). As características do sistema appraisal foram as mais significativas para o traço neuroticismo, em contrapartida o traço extroversão se beneficiou mais das características relacionadas a *function words*.

No que diz respeito à língua alemã, existe um *corpus* que está disponível para download na internet chamado CLiPS (2018). Os textos do *corpus* possuem aproximadamente 200.000 palavras em alemão escritos por 145 estudantes (*Bachelor of Arts degree in Linguistics and Literature at University of Antwerp, Belgium*). Cada estudante escreveu um ensaio sobre o documentário que assistiu (chamado de *artificial life*), registrando suas opiniões pessoais. Os ensaios tiveram uma média aproximada de 1400 palavras cada um. O tópico escolhido para os ensaios não foi relacionado diretamente com a personalidade, minimizando o *bias* do efeito psicológico do indivíduo saber que a personalidade está sobre investigação no momento de escrever o texto. Todos os participantes responderam um questionário do inventário Myers-Briggs Type indicator [Myers and Myers, 1980], baseado na topologia proposta da teoria psicodinâmica de Carl Jung [Jung, 2002]. O inventário de



personalidade aplicado produziu 8 pontuações de traços de personalidade, 2 por dicotomia. Posteriormente, os scores foram normalizados para a tarefa de 8 classificações binárias. Esta base possui problemas de balanceamento de classes, este é um problema muito difícil de ser tratado em amostras de dados pequenas.

Mairesse em 2007 utilizou a base *essays* [Pennebaker & King, 1999] para prever a personalidade a partir de textos e também uma base de dados chamada EAR [Mehl et. al., 2001] para prever a personalidade a partir de características prosódicas. Para a base textual *essays* este trabalho realizou diversos experimentos de rankeamento (explicado na seção 5.2.6), regressão e classificação utilizando diversos indutores. Os paradigmas de classificação utilizaram os extremos da personalidade. Como técnicas de extração de características foram utilizados os léxicos LIWC [Pennebaker et. al., 2015] e MRC [Coltheart, 1981] (Seção 4.2.1). Este trabalho ficou famoso por utilizar diversos paradigmas de ML e também por propor uma fórmula de aplicação para o léxico LIWC (explicada na seção 8.2.3).

Os autores [Luyckx and Daelemans, 2008] pré-processaram os textos do *corpus* CLiPS utilizando o *Memory-Based Shallow Parser* [Daelemans et al.,1999], que tokenizou a entrada e marcou o texto com as *pos-tags*. Para formar o espaço de características foram utilizadas as técnicas *top-down* e *bottom-up* citadas abaixo:

- 1) Contagem de tokens a nível de palavras e n-grams.
- 2) Contagens de pos ngrams *coarse-grained*.
- 3) Contagens de pos n-grams *fine-grained*.
- 4) Contagens de *function words*.
- 5) Contagens ou representações binárias de léxicos, não foi especificado quais léxicos foram utilizados.
- 6) Aplicação da métrica *readability of a text* (RT) (Fórmula 4) proposta por Flesch-Kincaid [Stamatatos et. al, 2001].
- 7) Aplicação da métrica *type-token ratio* (TTR), quantificando a riqueza do vocabulário (Fórmula 3).

A métrica  $\chi^2$  (Fórmula 11) [Luyckx and Daelemans, 2008] foi utilizada para seleção de features, calculando a frequência esperada e observada para cada item em cada categoria, caracterizadas pelos n maiores valores de  $\chi^2$ . A seleção de características foi feita apenas para os espaços de 1 a 5 enumerados acima. As melhores features selecionadas foram provenientes dos espaços 5,3, 2.

$\chi^2 = \sum_{i=1}^k \frac{\chi_i - \mu_i}{\sigma_i}$	(11)
---	------

O processo de *machine learning* foi submetido a validação cruzada com 10 folds, sendo selecionado o indutor supervisionado, o TiMBL [Daelemans et al., 1999], que é uma heurística *lazy* baseada no KNN com extensões adicionais para lidar com features nominais e peso de relevância para features. Não foi realizado *fine tuning* dos parâmetros do indutor. O problema multi-label foi decomposto em n-classificadores binários onde foram executados 2 experimentos. O primeiro deles se propôs a prever os 8 traços de personalidade do MBTI, utilizando 8 classificadores binários e o segundo se propôs a prever os 4 polos das dicotomias do MBTI, utilizando 4 classificadores binários. As métricas escolhidas para a avaliação dos resultados foram o F-score e a acurácia. A acurácia foi fornecida a fins de comparação com outros trabalhos, mas não é uma medida de avaliação adequada para estes classificadores, pois os autores informam que o *corpus* possui classes desbalanceadas. Os resultados de classificação são exibidos abaixo (os significados das siglas referentes aos 8 traços de personalidade e as 4 dicotomias MBTI podem ser encontrados na seção 3.1.2):

- i. A média de acurácia nos 8 traços foi 0.64 (J, 0.82), (F, 0.73), (T, 0.65), (I, 0.64), (E, 0.60), (N, 0.58), (P, 0.57), (S, 0.55).
- ii. A média do F1-score nos 8 traços foi 0.669 (J, 0.90), (F, 0.84), (E, 0.73), (N, 0.71), (I, 0.67), (S, 0.65), (T, 0.44), (P, 0.38).
- iii. A média de acurácia nas 4 dicotomias foi de 0.70 (J/P, 0.82), (F/T, 0.73), (I/E, 0.65), (N/S, 0.62).
- iv. A média do F-Score médio de cada dicotomia foi de 56.98% (I/E, 0.65), (N/S, 0.61), (J/P, 0.51), (F/T, 0.49).

Para fins de comparação com outros trabalhos, o experimento (ii) possui mais relevância que o experimento (i), pois os autores afirmam que existem estudos provando que algumas dicotomias se correlacionam com o Big Five. Os autores conseguiram resultados significativos apenas para as dicotomias Introversed – Extroversed e Intuitive-Sensing. Podemos considerar que o diferencial deste trabalho foi utilizar um *corpus* em alemão, utilizar o MBTI, baseado na teoria jungiana para rotular os textos e acrescentar técnicas de extração de características textuais a nível de POS *coarse grained* e *fine grained*. Outro diferencial foi também por a prova técnicas de extração de características utilizadas na estilometria.

O potencial do inventário EgoGram (muito usado em dinâmicas organizacionais) ainda não tinha sido utilizado em nenhum trabalho de TB-APR até Minamikawa e Yokoyama publicarem um trabalho em 2011. O *corpus* utilizado compreendeu os textos de weblogs de 551 indivíduos japoneses que se submeteram a um inventário de personalidade baseado no EgoGrams (Seção 3.1.3) chamado *Todai-shiki Egogram Version 2* que possui 50 itens. A seleção de características foi feita utilizando uma ferramenta para japonês (chamada de SEN) que faz contagens de palavras (*bag-of-words*). As top k-features foram selecionadas usando o critério do ganho de informação. O problema foi simplificado e decomposto em classificação binária e também em classificação multi-classe, utilizando respectivamente 2, 3 e 5 classes. O classificador utilizado foi o *multinomial naïve bayes*. A acurácia dos experimentos variou dependendo do número de k-melhores features utilizadas variando de .55 a .62 no experimento com 5 classes e .69 a .85 no experimento com 2 classes, indicando os problemas já relatados no capítulo 1 sobre simplificar a personalidade utilizando z-scores.

Utilizando a base de dados MyPersonality [Kosinski & Stillwell, 2011], Quercia e seus colegas (2011) analisaram traços do BigFive de 335 tweets de usuários com profiles variados [Quercia et. al., 2011]. O algoritmo M5 foi utilizado para construir um modelo de regressão, utilizando features estruturais da rede apenas; este trabalho desencadeou uma série de outros trabalhos utilizando o tweeter, onde modelos foram construídos utilizando dados estruturais da rede social, combinados com features textuais. Em um desses trabalhos [Goldbeck et. al., 2011] utilizou um *corpus* de 2000 tweets rotulados pelo BigFive com um inventário de 45 itens. Os léxicos LIWC e MRC (Seção 5.2.1.) foram utilizados para extração de características textuais. O léxico afetivo *general inquirer* (Seção 5.2.2) também foi usado para fazer análise de sentimentos, adicionalmente foram incorporados outros dados da rede social no espaço de características (características estruturais). O modelo de ML foi construído com o regressor *GaussianProcess* e foi comparado com baseline ZeroR. A medida de desempenho utilizada foi o mean absolute error (MAE), a performance de regressão teve um resultado 0.11 e 0.13, obtendo uma performance praticamente idêntica ao classificador *baseline ZeroR*.

Em 2012, um novo trabalho utilizou um *corpus* do tweeter para prever a *dark triad* da personalidade (maquiavelismo, psicopatia e narcisismo) [Summer et. al., 2012]. Adicionalmente, para fins de comparação, todos participantes também responderam um inventário Big Five. Neste trabalho foram analisados 2927 profiles do twitter, onde todos responderam um inventário de personalidade baseado na *dark triad* (*short dark triad SD3*, seção 4.1.4). As características textuais foram extraídas por contagens utilizando o léxico LIWC, juntamente com features referentes às redes sociais (número

de amigos, seguidores, número de tweets, etc). Os indutores NB, SVM, J48 (*trees*) e *random forests* foram utilizados no processo de ML. Foram usados o paradigma de classificação binária (high – low) e também o de regressão. No paradigma de classificação binária foram utilizadas 2 técnicas diferentes de divisão, a primeira delas dividiu a amostra pela mediana e a segunda utilizou uma técnica para dividir a amostra chamada de 90<sup>th</sup> *percentile*. As medidas de avaliação de desempenho utilizadas foram AUC (*area under the curve*) e acurácia. Os resultados de previsão dos classificadores foram publicados prevendo os traços do BigFive e também os traços da DarkTriad. Todos os modelos de classificação foram ruins de forma geral.

Outro trabalho [Wald et. al., 2012], utilizando um *corpus* do facebook com 537 indivíduos, rotulado por inventário BigFive de 45 itens, utilizou 31 atributos estruturais da rede (autores se referem como demográficos) e mais 80 atributos textuais baseados nas categorias do léxico LIWC. Foram utilizados os indutores regressores lineares, REPTree e Dtable para prever a personalidade. No que diz respeito aos resultados, os autores mostraram gráficos dos indutores para os 5 traços de personalidade, determinando os indivíduos que aparecem nos extremos de cada traço de personalidade em representações de porcentagens. Como os autores utilizaram regressão, para analisar os extremos da personalidade, foi utilizada a medida de desempenho acurácia. Para isso uma técnica parecida com o sistema *Module Order Modeling* [Khoshgoftaar, 2003], que avalia a qualidade da previsão numérica baseado em como ela ordena as instâncias foi utilizada. Entretanto, o método se diferencia no que diz respeito à maneira como esta qualidade é mensurada numericamente. Neste estudo, verificou-se por regressão um potencial de prever com 0.75 de acurácia indivíduos que possuem os 0.10 maiores scores de abertura a experiência.

Lima e Castro em 2013 propuseram o primeiro modelo de TB-APR semi-supervisionado que temos conhecimento. Para isso os autores utilizaram um *corpus* baseado no *Twitter*, capturando 4621 *tweets*. Para extrair as características textuais, os *tweets* foram processados de acordo com contagens referentes as seguintes meta-informações: (i) *followers*, (ii) *followings*, (iii) palavras, (iv) questões, (v) exclamações, (vi) palavras com mais de 6 letras, (vii) palavras positivas, (viii) palavras negativas, (ix) artigos, (x) links e (xi) vírgulas. Na etapa de ML, os autores utilizaram paradigma de classificação binária semi-supervisionada, com o classificador Naive Bayes, obtendo uma acurácia de até 84%. Este trabalho foge um pouco do escopo desta tese, pois utiliza além dos textos, meta-informações do twitter, mas decidimos fazer um comentário em relação a ele devido a inovação de utilizar um paradigma semi-supervisionado de machine learning.

No ano de 2013 houve o primeiro evento dedicado a comunidade de TB-APR, no qual aconteceu o primeiro *workshop de personality computing-shared task* [Celli et. al., 2013]. Neste

evento 8 diferentes times de participantes tentaram construir modelos de TB-APR utilizando a base de dados *essays* [Pennebaker & King, 1999]. A base de dados *essays*, controlada pelo tópico “*a stream of consciousness*” (SOC) na época deste workshop possuía aproximadamente 2400 indivíduos rotulados pelos extremos de cada dimensão do *BigFive* (*low* e *high*). O processo de simplificação das dimensões foi baseado nos *z-scores* [Mairesse, 2007]. Todos os trabalhos utilizaram o paradigma de classificação binária. Além da base de dados *Essays* (ES), o *workshop* forneceu uma base de dados extraída do projeto do facebook *MyPersonality* (MP) [Kosinski & Stillwell, 2011]. Esta base é composta de 250 indivíduos que tiveram suas mensagens de *status* do facebook coletadas. No total a base possui aproximadamente 9900 mensagens de *status*. Todos os indivíduos foram rotulados por um inventário *BigFive* de 100 itens. Adicionalmente a base possui diversos dados extratidos diretamente da rede social facebook, tais como o tamanho da rede, densidade, cardinalidade, entre outros. Foram incluídos para esta base os scores numéricos derivados diretamente dos inventários e também um rótulo adicional com o extremo de cada traço de personalidade (*high* e *low*), possibilitando as tarefas de regressão e classificação. Os trabalhos do *workshop* utilizaram as mesmas técnicas já relatadas nos anos anteriores [Celli et. al., 2013]. Uma exceção é o trabalho de Iacobelli e Cullota (2013) que será detalhado em sequência. Celli e seus colegas (2013) obtiveram os seguintes *insights* no *workshop* [Celli et, al., 2013]:

- 1) A seleção de características com algoritmos de ranqueamento é bastante efetiva em espaços de características grandes.
- 2) No que diz respeito à extração de características, os trabalhos que utilizaram abordagens *top-down* foram mais efetivos que os trabalhos que utilizaram abordagens *bottom-up*.
- 3) As abordagens que utilizaram *n-grams* não foram efetivas nestes trabalhos. Indutores probabilísticos como o *Naïve Bayes*, parecem ter mais performance que os demais utilizando estas abordagens.
- 4) Métodos baseados em *ensembles* podem ser efetivos.

Os autores Iacobelli e Cullota (2013) se destacaram no *workshop* [Celli et, al., 2013] por escolher o paradigma estruturado de ML (Seção 5.2.7). Estes autores propuseram um modelo utilizando técnicas *bottom-up* com classificadores estruturados e classificadores não estruturados. O corpus utilizado foi a base de dados *essays*. O baseline estabelecido foi o classificador ZeroR. Todos experimentos foram submetidos à validação cruzada em 10 folds. Na etapa de pré-processamento foi realizada a conversão da base para *lower case* e depois a tokenização do texto. A pontuação, os símbolos e os emoticons foram mantidos e tratados como tokens simples. A extração de características não utilizou técnicas mais refinadas, fizeram um token count de unigrams, bigrams

and trigrams. Não utilizaram nenhuma técnica específica de seleção de características, apenas eliminaram tokens que ocorreram menos de 5 vezes e também os 20 mais frequentes. A etapa de Machine learning foi a que chamou atenção. Para verificar hipóteses de estudos que mostram traços de personalidade que se correlacionam, os autores optaram por um classificador estruturado que utiliza a informação dos outros labels em tempo de construção do modelo, com o objetivo de prever uma sequência de labels. O Indutor estruturado utilizado foi baseado na heurística *Conditional Random Fields* (CRF) [Lafferty et al, 2001]. Este indutor funciona de maneira análoga a regressão logística, mas com extensões adicionais que aproveitam a informação disponível nos labels da base de treinamento. O CRF faz a representação computacional do problema em uma rede de markov, onde um grafo não direcionado abstrai em aresta (ou clique) uma “*potential pairwise function*”. Esta função é utilizada para decompor a “*joint probability distribution*”, permitindo inferir algumas relações condicionais independentes.

Duas variações heurísticas do CRF foram utilizadas, a Parwise Label Factors (CRF-P), onde o modelo inclui fatores de interação entre cada par de labels. Como no total são 5 labels, existe a inclusão de 10 fatores. O custo computacional de representação é combinado com os da regressão logística; e como cada label é uma variável binária, o modelo produzirá no total 40 parâmetros adicionais. A outra heurística utiliza ainda mais fatores, a Parwise Label-Features Factors (CRF-PF) que fatoriza condições entre os labels e as features produzindo um número muito maior de parâmetros, portanto, se a regressão logística utilizar  $n$  parâmetros, o modelo terá  $40 * n$  parâmetros. Para fins de comparação os indutores não estruturados também foram utilizados (SMO, NB e LOGREG). O indutor ZEROR foi usado como baseline, este indutor classifica as instâncias se baseando apenas na informação sobre a distribuição da classe de treinamento, desconsiderando o espaço de características.

Para a avaliação dos (5) resultados, foi utilizada a acurácia. A média de acurácia dos melhores resultados foi de 57,69%, com os melhores resultados ordenados pelas tuplas: (O, LOGREG, 66.00%), (E, NB, 61.20%), (C, NB, 56.00%), (A, SMO, 52.80%), (N, LOGREG, 52.49%). De forma geral, os indutores propostos não foram melhores que o baseline, não havendo diferença estatística entre nenhum dos classificadores testados ( $p < 0.05$ ). Entretanto, os autores afirmaram que seus baselines ZEROR são significativamente melhores que os baselines relatados em [Mariesse et. al, 2007]. Eles atribuíram isso a alguma particularidade na hora dividir os *folds*. Neste experimento, o classificador NB foi o único a superar em acurácia o ZEROR apenas para o traço “C”, com uma margem muito pequena de vantagem (+0.04% acc). A única diferença estatística detectável neste

experimento foi entre os classificadores SMO e LOGREG para o traço “O” com (LOGREG, +0.11% acc).

Um ano após o primeiro *workshop* de computação da personalidade, Celli e seus colegas propuseram novos estudos, mas desta vez utilizando um corpus multi-modal construído a partir de *vlogs* [Celli et. al., 2014]. O corpus foi obtido a partir de um conjunto de 404 *vloggers* rotulados pelo BigFive. Todos *vloggers* tiveram suas falas transcritas em textos. Os scores rotulados pelo BigFive foram simplificados em suas porções extremas (*high, low*). Neste segundo workshop 6 trabalhos foram aceitos, entre eles 2 chamaram a atenção.

Um dos trabalhos que chamou a atenção realizou uma tentativa de utilizar o paradigma de regressão multi-target (Seção 5.2.5) para prever a personalidade. O trabalho de Fernandi e seus colegas [Fernandi et. al., 2014] utilizou sete espaços de características diferentes (multi-modal (Gender, Audio Video features), *top-down* (LIWC, NCR, MCR, SentiStrenght, Splice)). Foram utilizados diversos regressores multi-target para prever os traços de personalidade, utilizando o coeficiente de determinação e a medida de erro RMSE para avaliar o desempenho. Apesar da inovação em relação ao paradigma de ML, as correlações foram baixas.

O segundo trabalho que chamou a atenção foi o de Nowson e Gill [Nowson & Gill, 2014]. Os autores tentaram provar que seria possível aprendizagem de máquina entre domínios. Para isso eles treinaram classificadores no *corpus* dos *vloggers* [Celli et. al., 2014] e testaram a performance desses classificadores no EAR *corpus* [Mairesse, 2007]. Os scores numéricos foram submetidos a simplificação por Z-scores. Foram utilizados os paradigmas de classificação binária (*high e low*) e também o paradigma de classificação multi-classe (*high, medium, low*). Para extração de características usaram o LIWC. Todos os experimentos de classificação utilizaram indutores probabilísticos baseados no algoritmo do *naive bayes*. Neste experimento apenas o traço extroversão foi analisado. Foram reportadas acurácias de 0.62 para a tarefa de classificação binária e 0.41 para a tarefa de classificação multi-classe, indicando novamente como é problemática a técnica de simplificação das escalas de personalidade por *z-scores*.

Mounica Arroju, Aftab Hassan e Golnoosh Fernandi (2015) realizaram um trabalho com objetivo de reconhecer a idade, o sexo e a personalidade através de textos escritos em quatro línguas naturais diferentes (inglês, espanhol, alemão e italiano). Em relação aos experimentos para reconhecer a personalidade, os autores utilizaram um corpus com dados textuais de 79 indivíduos do *Twitter*, sendo que os indivíduos foram submetidos a um inventário Big Five. Os textos deste *corpus* poderiam conter qualquer uma das línguas mencionadas, mas eram em sua maioria escritos em inglês ou espanhol. Para extração de características os autores utilizaram o léxico LIWC. Em relação ao

paradigma de machine learning, foi utilizada a regressão multi-target (o inventário de personalidade utilizava uma escala de *scores* entre -0.5 e 0.5), com o classificador ERCC. Para avaliar o desempenho, os autores utilizaram a métrica MAE, obtendo resultados entre 0.10 e .0.28 a depender da dimensão de personalidade e da língua natural avaliada (as 5 dimensões do Big Five foram avaliadas individualmente para cada língua). É possível notar enviesamentos na amostra, por exemplo, apenas 7 indivíduos falavam alemão, então possivelmente o modelo que prevê dimensões de personalidade para esta língua pode estar com *overfitting*.

Um dos trabalhos de TB-APR mais detalhados em termos de produção de resultados é a publicação “*Automatic Personality Assessment Through Social Media Language*” [Park et. al, 2015]. Este foi o primeiro estudo sistemático da personalidade que utilizou um maior número de participantes, e também foi o primeiro a utilizar a informação sobre as facetas dos traços de personalidade BigFive. Neste trabalho, os autores privilegiaram abordagens *bottom-up* em *corpus* baseado no facebook, compreendendo um sub-set de 71.566 usuários que fizeram parte do projeto *MyPersonality* [kosinski & Stillwell, 2011]. Todos os usuários postaram pelo menos 1000 palavras em suas mensagens de status, capturadas entre janeiro de 2009 e novembro de 2011, totalizando 15 milhões de mensagens, com cada usuário escrevendo em média 4.107 palavras. A média de idade dos usuários foi de 23.4, e a maioria dos participantes eram mulheres (0.626). Todos os participantes responderam um inventário de personalidade BigFive NEO-PI-R [Costa & McCrae, 1992], entretanto, versões diferentes do inventário foram utilizadas, uma com 20 itens e outra com 100 itens, sendo que estas versões fazem parte do *International Personality Item Pool* (IPIP) [Goldberg et. al., 2006]. Destes participantes, uma pequena amostra (n=336) completou um proxy do IPIP, promovendo o acesso a 30 facetas, 6 por traço do BigFive.

Para evitar o *overfitting*, os autores dividiram a base em treinamento (66.000 participantes) e validação (5.000 participantes), utilizando critérios externos adicionais para selecionar os participantes da base de validação. Os critérios externos utilizados para a escolha da base de validação baseou-se no preenchimento de inventários de personalidade adicionais disponíveis no projeto *MyPersonality*, tais como os inventários *Self-Monitoring Scale*, *Orpheus Personality Questionnaire*, *Pennebaker Inventory of Limbic Languidness* (PILL), *Barrat Impulsiveness Scale* (BIS-11) e *Informant Reports of Personality*. Estes usuários tiveram prioridade na seleção da base de validação. Além dos textos, foram também capturadas informações sobre o *profile* (perfil) dos usuários como o número de amigos (disponível apenas em 1906 usuários) e informações sobre a visão política (disponível para 756 usuários) que foram classificadas em uma escala estilo *likert* de muito conservador (-2) a muito liberal (+2).



A ferramenta *emoticon-aware tokenizer* [Potts, 2011] foi utilizada no pré-processamento textual. O processo de extração de características textuais utilizou tipos distintos de técnicas *bottom-up* em conjunto com um processo implícito de seleção de características. Após a tokenização centenas de milhares de características textuais foram vetorizadas em três espaços de características distintos.

O primeiro espaço de características foi obtido através da contagem de palavras e de n-grams, neste trabalho os autores se referem aos n-grams como “frases”. Na extração das frases, apenas frases que não ocorriam ao acaso no texto foram selecionadas, para isso foi utilizado a estatística *pointwise mutual information* (PMI) [Church & Hanks, 1990], permitindo identificar frases como co-ocorrência de n-grams que ocorreram mais frequentemente que a probabilidade individual de suas palavras constituintes; a estatística PMI é exemplificada na Fórmula 12 [Park et al., 2015].

$pmi(phrase) = \frac{\log(p(phrase))}{\prod p(word)}$	(12)
---	------

Onde  $p(phrase)$  é a probabilidade da frase baseada em sua frequência relativa e  $\prod p(word)$  é o produto da probabilidade de cada palavra em uma frase.

Após a aplicação da estatística PMI foram mantidas frases compostas por 2 ou 3 n-grams que possuíam o valor PMI três vezes maior que  $n$  ( $n=2$  ou  $n=3$ ), adicionalmente para reduzir o espaço dimensional, apenas palavras e frases utilizadas em pelo menos de 1 % da amostra foram consideradas. Após a identificação das palavras e das frases consideradas válidas, um processo de contagem de frequências relativas a estas features foi realizado, gerando milhares de valores normalizados no espaço de características de cada participante.

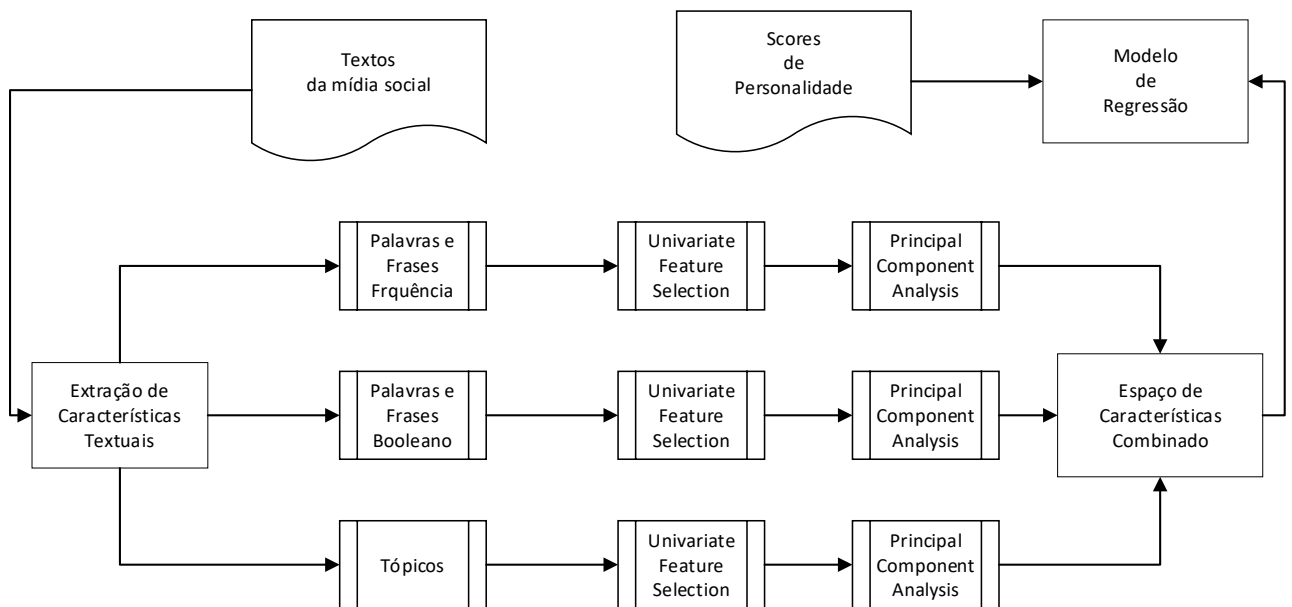
O segundo espaço de características utilizou as mesmas palavras e frases encontradas no primeiro espaço, mas ao invés de realizar a contagem de frequências relativas, foi contabilizada uma representação binária (0 ou 1) das palavras e frases.

O terceiro e último espaço de características compreendeu a extração de features a nível de tópicos, onde foi utilizada a abordagem *Latent Dirichlet Allocation* (LDA) [Blei et al., 2003]. O LDA considera os documentos como tópicos latentes de palavras, onde cada tópico é um conjunto de palavras relacionadas. Na implementação do LDA o número de tópicos a serem gerados escolhido foi 2000. A probabilidade de presença de cada um dos 2000 tópicos para cada participante foi calculada utilizando a Fórmula 13 [Park et al., 2015].

$$p(\text{topic}, \text{user}) = \sum p(\text{topic}|\text{word}) \times p(\text{word}|\text{user}) \quad (13)$$

Onde  $p(\text{word}|\text{user})$  é a probabilidade de uso da palavra pelo usuário e  $p(\text{topic}|\text{word})$  é a probabilidade de um tópico, dada uma palavra.

Resultante do processo de extração de características o espaço combinado de características textuais resultantes obteve um total de 51060 características. Para aumentar a eficiência dos regressores, foram utilizadas duas técnicas diferentes para a redução da dimensionalidade: (i) a *univariate feature selection* (UFS) [Guyon & Elisseeff, 2003], eliminando features com associação linear fraca e a técnica (ii) *randomized principal components analysis* (RPCA) [Martinsson et. al., 2011], utilizando  $k = 0.10$ . As técnicas de redução de dimensionalidade foram utilizadas de forma independente para cada um dos três sets de características, evitando interferências dos sets adjacentes no processo de seleção. A Figura 14 exemplifica o processo de redução da dimensionalidade.



**Figura 14.** Redução da dimensionalidade adaptado de [Park et al., 2015].

Após a redução de dimensionalidade, o espaço de características foi combinado (Figura 14) e ao ser terminada a etapa de redução da dimensionalidade, sobraram como componentes principais (i) 2453 atributos de frequências relativas de palavras e frases, (ii) 2453 atributos de representação binária de palavras e frases e finalmente (iii) 200 atributos de tópicos.

No que tange ao processo de aprendizagem de máquina, os indutores de regressão baseados no algoritmo *Ridge Regression* [Hoerl & Kennard, 1970] foram escolhidos. Estes regressores

funcionam de forma similar à regressão linear, mas com uma penalidade imposta à magnitude quadrática dos coeficientes, reduzindo a variação dos coeficientes estimados. Após obter as correlações de regressão, os autores fizeram uma série de análises qualitativas e quantitativas verificando a validade e a confiabilidade do método proposto.

A validade convergente foi calculada examinando correlações entre os LBAs e os auto-reports de cada traço de personalidade (processo de TB-APR), e a validade discriminante foi calculada comparando a correlação entre os traços dos auto-reports (ex. extroversão e socialização), repetindo o processo também para a correlação encontrada entre os LBAs e auto-reports. Adicionalmente, também foi calculada a validade convergente e discriminante para cada uma das 30 facetas de um pequeno sub-set de usuários, que também responderam o questionário proxy do inventário BigFive. Finalmente, foi realizado um estudo de confiabilidade do processo de TB-APR, utilizando a técnica de test-retest com LBAs extraídos em diferentes períodos de tempo.

Como tipos de inventários diferentes foram utilizados, e também amostras diferentes (nos testes de confiabilidade), para o cálculo da validade convergente e para o cálculo de confiabilidade, os autores se basearam nas médias da correlação de Pearson, sendo imprescindível ao cálculo destas médias a transformação de Fisher (Fórmula 14), possibilitando o valor médio ser encontrado em uma distribuição normal (z-score) para, em seguida, ser realizada a transformação reversa (Fórmula 15, onde *tanh* é a tangente hiperbólica) encontrando o coeficiente de correlação médio [Park et. al., 2015].

$f(r \text{ to } z) = 0.5 \log_e \left( \frac{1+r}{1-r} \right)$	(14)
--	------

$f(z \text{ to } r) = \frac{e^{2z} - 1}{e^{2z} + 1} \text{ ou } f(z \text{ to } r) = \tanh(z)$	(15)
--	------

Podemos entender a transformação de Fisher, analisando a distribuição de uma amostra de correlações hipotéticas, em que as correlações positivas se encontram distribuídas em 4 diferentes regiões. Podemos agora supor que estas regiões estão espalhadas proporcionalmente em diferentes ranges de correlação, sendo que a primeira região compreende valores de correlação entre 0 e 0.50 (range de 0.50), a segunda entre 0.50 e 0.71 (range de 0.21), a terceira entre 0.71 e 0.87 (range de 0.16) e a quarta entre 0.87 e 1 (range de 0.13). Com este exemplo, podemos entender que a

distribuição de correlações, na medida em que a correlação se aproxima de 1, os valores pertencentes a distribuição são “comprimidos” em um range menor de valores. Como efeito desta compressão, a densidade das correlações do intervalo de 0.90 e 1 é muito maior do que a densidade das correlações entre o intervalo 0.00 e 0.10, se isso não for levado em conta, ao tentarmos utilizar uma estatística que considere esta distribuição de correlações com outras distribuições de correlação (ex: diferentes amostras) isso pode nos remeter ao erro. Para mediar este problema, a transformação de Fisher (Fórmula 15) é aplicada à distribuição de correlações antes de realizar a estatística (ex. média) e depois da estatística ser aplicada, a transformação de Fisher inversa é realizada (Fórmula 16).

A Tabela 9 mostra os resultados de validade convergente, ou seja, as correlações obtidas no processo de TB-APR (LBAs x self-reports BigFive). Como foram utilizadas diferentes versões do inventário BigFive (uma de 20 e outra de 100 itens), os autores obtiveram a média de correlações dos self-reports, calculadas utilizando a transformação de Fisher, o processo de regressão também utilizou a mesma metodologia.

<b>LBA x Self reports</b>	All versions (n= 4824)	20 – item (n = 2324)	100 – item (n=1943)
O	0.43	0.38	0.46
C	0.37	0.34	0.38
E	0.42	0.39	0.41
A	0.35	0.31	0.40
N	0.35	0.30	0.39
Mean	0.38	0.34	0.41

**Tabela 7.** LBA x *Self reports* BigFive (correlação) adaptado de [Park et. al., 2015].

Observando a Tabela 7, notamos que o inventário de 100 itens produziu correlações melhores que o inventário de 20 itens. Podemos considerar isto um efeito colateral esperado, pois inventários com mais itens possuem um coeficiente de consistência interna (alpha) maior. A validade discriminante para as correlações médias referentes aos *self-assessments* é mostrada na Tabela 8. Adicionalmente, a Tabela 8 também mostra a média das correlações médias resultantes do processo de TB-APR (LBA). Todas estas médias (referentes aos inventários aplicados de 20 e 100 itens) também foram calculadas utilizando a transformação de Fisher, estes valores se encontram negrito.

Disc. val.	Self	Self	Self	Self	Self	LBA	LBA	LBA	LBA	LBA
Self	O	C	E	A	N	O	C	E	A	N
O										
C	0.0									
E	0.13	0.19								
A	0.7	0.17	0.19							
N	-0.8	-0.31	-0.34	-0.36						
LBA										
O	<b>0.43</b>	-0.12	-0.08	-0.05	0.0					
C	-0.13	<b>0.37</b>	0.16	0.17	-0.17	-0.25				
E	-0.7	-0.12	<b>0.42</b>	0.10	-0.15	-0.17	0.33			
A	-0.7	0.17	0.13	<b>0.35</b>	-0.14	-0.12	0.44	0.27		
N	0.05	-0.17	-0.18	-0.13	<b>0.35</b>	-0.6	-0.41	-0.43	-0.34	

**Tabela 8.** Validade discriminante (correlação) dos traços de personalidade do BigFive e também dos scores obtidos pelo modelo utilizando os LBAs. [ Park et, al., 2015].

O estudo da validade convergente e discriminante dos participantes que preencheram o proxy do IPIP para o acesso das 30 facetas (5 por traço) também foi realizado e a tabela original mostrando este estudo pode ser encontrada no artigo original de Park e seus colegas [Park et.al., 2015].

A confiabilidade dos experimentos de regressão foi calculada por test-retest através da correlação dos resultados encontrados em processos distintos de TB-APR, obtendo-se amostras diferentes em cada intervalo de tempo. Sendo assim, os LBAs pertencentes a 4 intervalos de tempo proporcionais distintos, extraídos durante um período total de 6 meses (julho 2009 até dezembro 2009) foram submetidos ao processo de regressão separadamente, produzindo 4 distribuições de correlações diferentes para cada um dos 5 traços do BigFive. A média de correlação destes intervalos foi calculada utilizando a estatística de transformação de Fisher obtendo as seguintes correlações: (C, 0.76), (O, 0.74), (E, 0.72), (A, 0.65) e (N, 0.62). Finalmente, os autores também forneceram uma forma de visualização dos LBAs nos 5 traços do BigFive em forma de nuvem [Park et. al., 2015], mostrando as palavras e tópicos com maior correlação.

Outro trabalho que utilizou regressão foi o do Celli e seus colegas [Celli et. al., 2016]. O *corpus* utilizado foi baseado em 210 usuários do twitter, que foram submetidos a um inventário Big

Five de forma online. Este inventário possui apenas 10 questões (BFI-10). Para extração de características foi utilizada a técnica bag-of-words a nível de frases (n-grams). Também foram extraídas características utilizando o léxico LIWC. A técnica de amostragem utilizada foi um *split*, que dividiu a base em 180 instâncias para treino e 30 para testes. O Regressor Utilizado foi o Random Forest. O modelo gerou medidas de erro RMSE entre 0.15 e 0.18, dependendo da dimensão de personalidade investigada. Apesar da medida de erro ser baixa ela foi equivalente ao baseline. No artigo os autores comentaram que chegaram em medidas de erro equivalentes a da literatura [Goldbeck et. al, 2011], entretanto neste artigo citado, apesar da medida de erro também ser baixa, os modelos deste trabalho tiveram uma performance equivalente ao baseline ZeroR. Adicionalmente a medida de erro utilizada no trabalho comparado é a MAE e não a RMSE.

Santos e seus colegas [Santos et, al., 2017] investigaram como os tópicos textuais poderiam afetar o reconhecimento da personalidade e para isso construíram um *corpus* em que participaram 110 indivíduos do facebook. Todos participantes desta pesquisa falam português do Brasil. Todos os indivíduos foram rotulados por um inventário BigFive de 44 itens.

Neste trabalho, os seguintes dados textuais foram coletados:

- 1) Mensagens de status de update do facebook.
- 2) Tarefa descritiva: os participantes foram instigados a descrever 10 imagens (fotos) com cargas emocionais produzindo:
  - a. Um texto descrevendo a imagem em múltiplos detalhes (texto longo).
  - b. Uma frase descrevendo a imagem de forma sucinta (texto curto).
- 3) Tarefa referencial: Identificar descritivamente de forma textual um único objeto em um contexto contendo diversos objetos.
  - a. Para esta tarefa foram utilizadas fotos do rosto de seres humanos obtidos do *Face Place image database* [Lucena et. al., 2010]. As faces humanas são facilmente associadas a emoções positivas ou negativas.
  - b. A escolha e descrição de uma entidade do *Greeble*, estas entidades são difíceis de descrever e requerem um pensamento mais introspectivo.

Após a coleta dos dados pelos autores, o *corpus* possui 5 tópicos de controle diferentes: os textos do facebook, os textos descritivos multisentenciais, os textos descritivos monosentenciais, os textos de referência às faces humanas e os textos referenciais aos *Greebles*. Um conjunto de 155 características foram extraídas utilizando uma abordagem *top-down* (liwc e outros léxicos) e os scores de personalidade BigFive foram decompostos e simplificados em problemas de classificação. No total foram construídos 30 modelos de classificadores (5 por corpus + 5 para todos os textos juntos) para

fins de comparação e a métrica de avaliação de desempenho escolhida foi o F1 score. Os autores não especificaram o indutor utilizado, mas isso não tem relevância, pois o foco deste trabalho foi investigar a influência dos tópicos textuais. A Tabela 9 mostra uma comparação dos resultados obtidos.

Corpus/BigFive	O	C	E	A	N
Facebook	.54	.45	.64	.50	.45
Monosentencial	.48	.43	.59	.45	.45
Multisentencial	.43	.49	.54	.47	.42
Ref. Faces	.54	.63	.55	.50	.47
Ref. Grebbles	.53	.46	.53	.59	.51
Todos	.46	.40	.56	.44	.45

**Tabela 9.** F1 score para os traços do BigFive utilizando diferentes corpus [Santos et al., 2017].

O trabalho de Santos e seus colegas [Santos et. al, 2017] tem um grande potencial latente, pois a grande maioria dos modelos TB-APR desconsidera a influência que os diferentes tópicos textuais podem ter na previsão da personalidade, entretanto, estes experimentos estão nitidamente em uma fase inicial, requerendo uma análise mais minuciosa no que diz respeito aos paradigmas de AM.

O primeiro trabalho a explorar técnicas de deeplearning foi o de Majumder e seus colegas (2017). O dataset utilizado foi a base de dados *essays* com os scores simplificados em *high* e *low* [Mairesse, 2007] [Celli et. al, 2013]. Os autores utilizaram o conjunto de características de Mairesse (2007) junto com uma abordagem *words2vec* para treinar uma rede do tipo convolutional neural network (CNN). A acurácia deste experimento é reportada na Tabela 10.

Explorando técnicas *top-down*, um grupo de pesquisadores da *Amazon Research Germany* [Vu et. al., 2017] desenvolveram um trabalho utilizando abordagens *top-down*. Uma proposta foi feita utilizando um conjunto de 4 *corpus* diferentes, a saber: (i) Twitter contendo os twitters de 153 indivíduos, (ii) Facebook [Celli et. al., 2013] contendo 250 status updates de 250 indivíduos, (iii) Youtube [Fernandi et. al., 2011] contendo a transcrição de 404 Vlogers e (iv) *Essays* [Pennebaker & King 1999] contendo 2479 ensaios textuais. Todos os *corpus* foram simplificados para ser possível a classificação binária.

Com a justificativa de que recursos léxicos poderiam ainda ser fortes preditores da personalidade no ano de 2017, os autores se propuseram a explorar 4 tipos diferentes de espaços de características representadas pela tupla (*Word*, *Sense*, *S\_Sense* e *Senti*). O primeiro elemento da tupla

se refere a características a nível de palavras, o segundo a nível de senso, o segundo e terceiro elemento se referem a features a nível do léxico *WordNet* e a última a nível de léxicos afetivos. Neste trabalho, os autores desenvolvem um próprio algoritmo de desambiguação de palavras.

No processo de extração de características a nível de palavras o processo foi sub-dividido em (i) palavras e (ii) palavras que também estão presentes no léxico *Word-Net*. No que diz respeito às características *Sense*, dois algoritmos de desambiguação foram utilizados (*Word Sense Desambiguation* WDS), (i) o *SimLesk* e o (ii) *MostFreq* [Gurevynch, 2012] subdividindo esta característica em mais 2 espaços diferentes, a tupla ((*Word*, *Word\_WN*), (*Wn\_S\_Lesk*, *Wn\_Mfs*), *S\_Sense* e *Senti*) representa todos os espaços de características.

Para ser possível a extração das features semânticas, em um primeiro momento, o conhecimento léxico foi extraído utilizando os labels semânticos do *Word-Net*, sendo assim, depois de extrair os n-grams, a informação é organizada na forma de pos.suffix (pos = *part of speech*, suffix = grupo de *synets*), organizando os n-grams de acordo com as categorias de *synets* (ex: “a dog” = noun.animal), para esta extração foi utilizada a ferramenta DKPro Uby [Miller et. al., 2013].

As features que utilizaram informações sobre sentimentos (*Senti*) utilizaram o conhecimento de léxicos afetivos, para isso a desambiguação desses afetos foi realizada por um algoritmo utilizando o *SentiWordNet*, produzindo uma escala discreta de polaridade em três atributos (positivo, negativo ou neutro). As demais características ((*Word*, *Word\_WN*), (*Wn\_S\_Lesk*, *Wn\_Mfs*), *S\_Sense*), foram submetidas a um processo de redução da dimensionalidade utilizando o  $X^2$  onde as k-melhores foram selecionadas. Para analisar os resultados foi utilizada a acurácia. Como *baseline* foi estabelecida a previsão baseada na classe majoritária. Foram utilizados classificadores SVM para resolver o problema de classificação binária. A artigo provou que os recursos léxicos afetivos não podem ser ignorados. Os léxicos superaram o *baseline* em todos os quatro datasets e em quase todas dimensões do *BigFive*. O *dataset* do facebook (ii) foi o mais promissor neste trabalho. A Tabela 10 mostra os resultados destes experimentos, comparando aos resultados de Majumder (2017).



Traço Big Five	[Majumder et. al, 2017] CNN Essays (2400)	[Vu et. al, 2017] SVM MyPersonality (250)	[Vu et. al, 2017] ZeroR
O	.62	.72	.70
C	.57	.56	.52
E	.58	.62	.38
A	.56	.55	.53
N	.59	.61	.39

**Tabela 10.** Estado da arte de acurácia [Vu et al., 2017]. Acurácia para dataset essays – 2400 users [Majumder et al, 2017]. Acurácia para o *dataset* MyPersonality – 250 users [Vu et al., 2017].

Sweeandi e seus colegas (2017) propuseram um modelo a partir de um corpus textual do *Facebook*, rotulado por um inventário de personalidade baseado nos três fatores de Eysenk (extroversão, neuroticismo e psicotismo), com os indivíduos foram rotulados em *high* e *low*, ou seja, utilizaram o paradigma de classificação binária (com o classificador Naive Bayes). Para realizar o processo de extração de características, os autores utilizaram uma combinação de ontologias com o léxico LIWC. Os autores relataram uma acurácia de até 91% nos experimentos.

Para comparar a performance de TB-APR em relação a diferentes inventários de personalidade, Fabio Celli e Bruno Lepri (2018) utilizaram um corpus textual do *Twitter*, no qual 900 indivíduos foram rotulados pelo Big Five e outros 900 foram rotulados pelo MBTI. Este *corpus* possui textos em quatro línguas naturais diferentes, sendo que a grande maioria dos textos são em inglês. Cada indivíduo do *corpus* teve 40 *tweets* coletados. Para extrair as características textuais, foram utilizadas técnicas *bottom-up* (bi-grams e tri-grams com 1000 atributos e frequência mínima igual a 3) e *top-down* (LIWC). Também foram extraídas características de meta-dados do *Twitter*. O paradigma de *machine learning* utilizado foi o da classificação binária. Os experimentos utilizaram a acurácia para avaliar o desempenho do modelo. Foram testados diversos classificadores, utilizando SVM e o meta-classificador auto do *Weka*. As acurácias com os *corpora* de ambos inventários de personalidade foram equivalentes. Nestes experimentos foram reportadas acurácias ente 0.53 e 0.73 dependendo do classificador e da dimensão de personalidade avaliada.

O trabalho de Santos e Paraboni (2019) explorou o reconhecimento automático de facetas da personalidade. Os autores utilizaram um corpus de 1019 indivíduos rotulados por um inventário Big

Five de 44 itens que possui a informação de duas facetas por dimensão de personalidade. Os textos foram extraídos das mensagens de *status* do *facebook* dos participantes. No processo de extração de características três técnicas foram utilizadas: (i) bag of words, (ii) skip-gram e (iii) cbow. Como muitas facetas estavam com desbalanceadas, foi utilizada uma técnica de sampling. Entre as técnicas de da sampling os autores optaram pela SMOTE, que é uma técnica de oversampling, criando instâncias sintéticas a partir de uma estratégia dos vizinhos mais próximos. Foram construídos modelos utilizando os classificadores binários Naïve Bayes e Logistic Regression. Todos os experimentos utilizaram como métrica de avaliação F1score, obtendo resultados entre 0.33 e 0.62 dependendo da faceta investigada.

Recentemente, mais um trabalho se propôs a prever facetas em conjunto com as dimensões de Personalidade do Big Five [Karanatsiou et al, 2020]. Neste trabalho os autores utilizaram um corpus de 243 indivíduos, que foram recrutados pelo *Amazon's Mechanical Turk*. Todos os participantes foram submetidos a um inventário de personalidade do tipo Big Five com 20 itens. Adicionalmente, os participantes tiveram dados textuais coletados do *Twitter*, totalizando 350 000 *tweets*. No processo de extração de características, foi utilizada uma combinação de *emoticons*, *bag-of-words* (*tf-idf n-grams*) e *features* comportamentais próprias do *Twitter*. Adicionalmente foi utilizada uma técnica de *POS tag* (parser sintático). Para seleção de características foi utilizada uma técnica univariada que calculou as correlações entre os atributos e classes do *set* de treinamento, rankeando os 100 melhores atributos. A métrica de erro selecionada foi RMSE. Os atributos meta foram as 5 dimensões do Big Five, mais as facetas *Anxiety* e *Avoidance*. O processo de ML ocorreu em duas etapas: (i) utilizar regressores base para prever uma faceta ou traço de personalidade por vez, onde o Random Forest obteve os melhores resultados, (ii) utilizar o paradigma de regressão multi-target, com o algoritmo *Esemble of Regression Chains* (10 *chains* de regressores Random Forest). Nestes experimentos, o paradigma multi-target superou o paradigma single-target, obtendo uma media de RMSE de 0.192.

Este capítulo faz um apanhado geral dos trabalhos relacionados a TB-APR. Procuramos organizar o capítulo com os artigos em uma ordem cronológica. Este capítulo possui duas seções, na primeira comenta de forma geral os trabalhos utilizados em TB-APR e a segunda possui uma tabela comparando os trabalhos, fazendo a conclusão do capítulo.

## **6.2 Tabela cronológica de artigos.**

A Tabela 11 compara os artigos descritos na seção anterior. Todos os artigos estão ordenados cronologicamente. Para não poluir a tabela, selecionamos os dados mais relevantes, a saber:

1. A forma como personalidade foi calculada (rotulamento dos *scores* dimensionais do *corpus*).
2. Quais as principais técnicas de extração de características textuais que foram utilizadas.
3. Qual foi o paradigma de ML escolhido.
4. Qual foi a medida de avaliação de desempenho foi utilizada.

Verificando a Tabela 11, notamos que desde 1999 até 2020, praticamente o estado da arte de *natural language processing* e ML já foi utilizado para construir modelos de TB-APR. Adicionalmente, verificamos que todos os trabalhos rotulam o *corpus* através de inventários de personalidade. O único trabalho que utilizou uma técnica projetiva foi o de Pennebaker e King em 1999, mas este trabalho não tinha como objetivo construir modelos de TB-APR, mas sim verificar a confiabilidade do léxico LIWC.

Autores	Psicometria (corpus)	Características / ML	Medida Desempenho
[Pennebaker & King, 1999]	TAT, PRF e Big Five (diversos corpus, ensaios textuais, artigos científicos)	LIWC / Análise de confiabilidade e de redução fatorial	Correlação Pearson, Alfa de Cronback
[Gill et. al., 2002]	3 Fatores de Eyesenck (emails)	LIWC, MCR / Regressões lineares múltiplas, Rankeamento com amostra binarizada	Coeficiente de determinação,  Correlação de Spearman
[Oberlander & Gill, 2004]	Fatores de Eyesenck (emails)	LIWC, MCR / Regressões lineares múltiplas, Rankeamento com amostras multi-classe	Coeficiente de determinação  Correlação de Spearman
[Oberlander & Nowson, 2006]	Big Five (bloggers)	n-grams / Classificação binária, Classificação multi-classe	Acurácia

[Oberlander et. al., 2006b]	3 Fatores de Eysenk (emails)	n-gram, POS tags / Regressões lineares múltiplas,  Rankeamento em amostra multi-classe	Coefficiente de determinação  Correlação de Spearman
[Oberlander & Nowson, 2007]	Big Five (bloggers)	n-grams / Classificação binária, Classificação multi- classe	Acurácia
[Argamon et. al., 2005]	BigFive (ensaios textuais)	Parser de Gramática Sistêmico Funcional/ Classificação binária	Acurácia F1-Score
[Mairesse et. al., 2007]	Big Five (ensaios textuais)	LIWC, MRC / Rankeamento Classificação Binária Regressão	Correlação Pearson Acurácia
[Luyckx & Daelemans, 2008]	MBTI 8 fatores (ensaios textuais)	n-grams, function words, Stilometria / Classificação binária	Acurácia
[Gill et. al., 2009]	BigFive (blogs)	LIWC / Regressão Ordinal com 3 classes.	Coefficiente de Determinação
[Minamikawa & Yokoyama, 2011]	EgoGrams (blogs)	Bag-of-words / Classificação binária Classificação multi- classe	Acurácia
[Goldbeck, 2011]	BigFive (twitter)	LIWC, MRC, General Inquirer, estrutura rede social / Regressão	MAE
[Sumner et. al., 2012]	Dark Triad e BigFive	LIWC, Estrutura rede social / Classificação binária	Acurácia TPR TNR AUC

	(twitter)		
[Wald, 2012]	BigFive (facebook)	LIWC, Estrutura da rede social / Regressão	Acurácia, apesar de utilizar regressão para medir os top 10% em relação ao rakeamento.
[Iacobelli & Cullota, 2013]	BigFive (Essays ensaios textuais)	n-grams / Classificação estruturada	Acurácia
[Lima & Castro, 2013]	Big Five Twitter, Programas da TV Brasileira	Twitter meta-atributos a nível textual / Classificação Semi-supervisionada Naïve Bayes	Acurácia Precision
[Farnandi et. al., 2014]	BigFive (Vlog404 Transcrição Vlogs)	Features Vlogs , LIWC, NCR, MRC, SentiStrenght, Splice /  Regressão Multi- Target	Coefficiente de Determinação  RMSE
[Nowson & Gill, 2014]	BigFive (Vlog404 Transcrição Vlogs – Train set)  (EAR Transcrição Conversas – Test set).	Features Vlogs, LIWC / Classificação Cross- domain com paradigma binário e multi-classe.	Acurácia.
[Park et. al, 2015]	BigFive + 30 facetas (facebook)	Ngrams e tópicos / Classificação binária	Correlação Pearson
[Arroju, Hassan & Fernandi, 2015]	Big Five Twitter	LIWC	MAE
[Celli, 2016]	Big Five BFI (10 items) Twitter	Bag of Words n- grams, LIWC Regressão	RMSE

[Santos et. al., 2017]	BigFive (diversos corpus tópicos textuais, textos obtidos por imagens emocionais, etc).	LIWC / Classificação binária	F1 score
[Majumder et al, 2017]	BigFive (Essays Ensaaios textuais)	LIWC, MRC, Word2vec / Classificação binária utilizando CNN	Acurácia
[Vu et. al., 2017]	BigFive (diversos corpus, ensaaios textuais, facebook, etc).	Word-net, SentiWordNet / Classificação binária	Acurácia
[Sewwandi et al., 2017]	Eyesenk three fator model Facebook	Ontologia LIWC Naïve Bayes Classificação Binária	Acurácia
[Celli & Lepri, 2018]	Twitter MBTI Types BIG FIVE	N-grams LIWC Twitter Metadata Classificação Binária	Acurácia
[Santos & Paraboni, 2019]	Facetas, Big Five (Status Facebook, PT-BR)	Bag of Words, SkipGram, cbow / Classificação Binária	F1Scores
[Karanatsiou et al, 2020]	Facetas, Big Five (Twitter)	Emoticons, Bag of Words, POS tag / Regressão single- target, Regressão multi-target.	RMSE MAE

**Tabela 11.** Tabela cronológica de trabalhos em TB-APR.

A próxima seção irá fazer a conclusão do capítulo.

## 6.3 Conclusão

Ao revisar a literatura notamos que o estado da arte de *natural language processing* e *machine learning* já foi explorado pelos modelos de TB-APR. Dezenas de técnicas diferentes de extração de características foram utilizadas pelos trabalhos. O mesmo pode ser dito para o processo de aprendizagem de máquina, diversos paradigmas foram utilizados. Notamos que, em muitos destes trabalhos, a simplificação das escalas de personalidade é usual, gerando modelos de TB-APR ingênuos e não confiáveis.

Em todos os trabalhos notamos um baixo desempenho dos modelos de TB-APR. Quase todos possuem correlações, acurácia, medidas de erro e outras métricas aquém do esperado, superando marginalmente baselines e os trabalhos de outros colegas. Neste sentido, um trabalho de 2017 [Majumder et. al, 2017] [Vu et. al., 2017] tem praticamente a mesma performance de um trabalho de uma década anterior [Mairesse, 2017] [Argamon et al., 2005] ao utilizar um mesmo *corpus* (base de dados essays [Pennebaker & King, 1999]). Podemos dizer que de maneira geral que por mais que a comunidade de computação da personalidade se esforce, os indutores não estão conseguindo generalizar adequadamente os modelos TB-APR. Todos os trabalhos que tentam prever a personalidade utilizam inventários de personalidade, nos levando a crer que o problema dos modelos ocorre *a priori*, no processo de construção do *corpus* a partir de um inventário de personalidade. A próxima seção apresenta um novo método para a construção de um modelo de TB-APR.

## 7. Metodologia

Este capítulo é dedicado ao método que utilizaremos para resolver os problemas gerais e específicos enumerados na seção 1.4. A metodologia relatada neste capítulo foi submetida ao comitê de ética e pesquisa (CEP) da PUCPR. A coleta de dados envolvendo seres humanos, relativa ao *corpus* do Z-teste ocorreu no ano de 2019, no primeiro semestre, após a aprovação pelo CEP da metodologia descrita na seção 7.1, que especifica a construção do *corpus* do Z-teste. A coleta de dados relativa ao TAT tem sua metodologia descrita na seção 7.2 e na tese de doutorado de Alessandro Scaduto (2016), cuja metodologia de pesquisa já tinha sido aprovada pelo comitê de ética e pesquisa da USP. Como teríamos que manipular dados que Alessandro Scaduto havia coletado anteriormente, submetemos mais um projeto com a metodologia descrita na seção 7.2 ao CEP da PUCPR, recebendo a aprovação no primeiro semestre do ano de 2020.

A metodologia, descrita neste capítulo, utiliza, até onde temos conhecimento, uma abordagem única em TB-PR, visto que constrói modelos partindo de técnicas projetivas de aferição da personalidade [Ocampo et. al, 1999]. Estas técnicas são instrumentos psicométricos, utilizados dentro do espectro da avaliação da personalidade, que possuem a vantagem de minimizar a possibilidade do indivíduo, o qual está tendo a personalidade avaliada, de manipular os resultados [Urbina, 2007]; [Scheefer, 1962]. Como desvantagem, podemos considerar que as técnicas projetivas são mais complexas de serem aplicadas, demandando um maior conhecimento sobre as teorias psicológicas [Schultz & Schultz, 2003] e maior treinamento e experiência destas técnicas por parte do aplicador.

A definição de “técnica projetiva” remete ao conceito original de projeção, identificada pela primeira vez por Freud como um dos mecanismos de defesa do inconsciente [Freud, 1936; 1946]. Sendo um mecanismo de defesa, a projeção tem a função de proteger o ego (centro da consciência), direcionando os impulsos (afetos) que teriam potencial de ser inaceitáveis no nível do ego, para algum objeto. Podemos entender os mecanismos de defesa como protetores do ego, que, ao mesmo tempo têm potencial de satisfazer o inconsciente, conseguindo exteriorizar afetos inaceitáveis ao ego, provocando um alívio na tensão do mecanismo psíquico.

A tensão psíquica ocorre devido a impulsos, chamados de pulsões, que se originam no inconsciente, o reservatório das pulsões. Freud descreveu dois tipos básicos de pulsões, as pulsões de vida (conduzem a atos relacionados ao crescimento do ser humano) e as pulsões de morte (conduzem a atos de destruição e retorno à matéria inorgânica). Nossos pensamentos não são resultados apenas de um tipo de pulsão, mas da combinação delas. Podemos entender a pulsão como a energia psíquica que direciona o comportamento das pessoas. Para os psicanalistas, esta energia



sofre diversas dinâmicas, mas possui um único objetivo que é encontrar a satisfação, tornando-se consciente. Sendo assim, o inconsciente é regido pelo princípio do prazer, procurando a satisfação imediata das pulsões para promover o alívio energético intrapsíquico [Freud, 1915/1957a]. Desta maneira, caso a censura acabe por reprimir demasiadamente a demanda pulsional, existirá um aumento de tensão, desequilibrando o aparelho psíquico, que provocará ansiedade e possivelmente sintomas [Freud, 1920/1955a].

Sendo o inconsciente o reservatório de pulsões [Freud, 1915/1957b], obedecendo apenas ao princípio do prazer, por outro lado, a consciência obedece ao princípio da realidade [Freud, 1911/1958]. Para mediar estes dois extremos, a censura exerce um papel fundamental, regulando quais pulsões vindas do inconsciente podem entrar em contato com a consciência, pois caso a censura não existisse, as pulsões poderiam destruir completamente o ego, o centro da consciência. Sendo assim, o ego utiliza o mecanismo de defesa da repressão para censurar conteúdos inconscientes inapropriados.

O mecanismo de defesa da repressão não funciona de forma isolada; existem outros mecanismos de defesa que ajudam a proteger a integridade do ego, tal como o mecanismo de projeção. Na projeção, impulsos conseguem burlar a barreira da censura, sendo direcionados a algum objeto (na psicologia, objeto pode ser qualquer coisa, como uma pessoa, parte de uma pessoa ou algum objeto inanimado). É importante ressaltar que, além dos impulsos inconscientes, o ego é vítima de outro tirano, o superego [Freud, 1923/1961a]. O superego é uma instância mental construída a posteriori, em um período da infância que Freud denominou como complexo de Édipo [Freud, 1924/1961]. O superego tem a função de julgar o ego constantemente, não se importando com a sua integridade.

Partindo do princípio que os afetos pulsionais podem utilizar a via da projeção (um dos mecanismos de defesa do ego) para se exteriorizar, enganando de certa forma, o mecanismo da censura, fica evidente a vantagem deste mecanismo para um modelo de TB-APR. Neste sentido, um instrumento projetivo poderia revelar aspectos relativos à personalidade, os quais o sujeito jamais revelaria de forma consciente. A possibilidade de capturar afetos, sensações, emoções, sentimentos, opiniões e pensamentos projetados certamente permite uma aferição da personalidade mais verdadeira do que inventários de personalidade com perguntas e respostas pré-formuladas em uma escala *likert*. Em outras palavras, ao contrário dos inventários que capturam apenas superficialmente as dimensões de personalidade, os testes projetivos capturam sua verdadeira essência. A teoria psicanalítica, abordada em maior profundidade na seção 2.1.1, será utilizada como apoio para descrever a metodologia de TB-APR que criamos para dois instrumentos projetivos, amplamente

utilizados por psicólogos, o Z-teste [Vaz & Alchieri, 2016] e o TAT [Murray, 1943/ 2005]. Esperamos que esta nova metodologia permita correlações mais verdadeiras entre os textos e a personalidade.

Em nossa metodologia criamos dois *corpora* para TB-APR, sendo assim este capítulo foi dividido nas seguintes seções: a primeira descreve a metodologia utilizada para o *corpus* do Z-teste, a segunda descreve a metodologia utilizada para o *corpus* do TAT, e a terceira faz uma conclusão deste capítulo.

## **7.1 O *corpus* do Z-teste, Coleta dos Scores de Personalidade.**

A coleta dos scores de personalidade e a coleta textual do Z-teste foi realizada durante o ano de 2019, em três diferentes universidades da cidade de Curitiba, estado do Paraná, na região sul do Brasil. Participaram desta pesquisa 363 estudantes, 118 homens e 245 mulheres, todos do ensino superior. Dos estudantes, 236 eram alunos de psicologia, 71 de ciências da computação, 24 de relações públicas, e 8 de jornalismo. A idade dos estudantes variou entre 18 e 55 anos com desvio padrão de 5.57.

A coleta dos scores de personalidade foi realizada através da aplicação do instrumento projetivo Z-Teste, utilizando o manual adaptado para populações do sul do Brasil “Z-teste coletivo e individual”, dos autores Cícero E. Vaz e João Carlos Alchieri (2016). Este instrumento projetivo faz uso de projeções direcionadas à objetos na forma de manchas formadas ao acaso. Escolhemos o Z-teste, entre os outros testes projetivos, devido ao fato de sua grande riqueza de detalhes capturados da personalidade.

O Z-Teste ou Técnica de Zulliger [Zulliger, 1948] é um teste de personalidade baseado no Método de Rorschach (1939) [Beck, 1952], com vantagem em relação ao tempo de aplicação, pois utiliza um número bastante reduzido de imagens ou cartões, onde apenas 3 figuras são utilizadas (comparativamente, o teste Rorschach utiliza 10 figuras). Este teste é baseado em projeções do sistema psíquico em três manchas formadas ao acaso (uma em preto e branco e as outras duas coloridas), possuindo a opção de aplicação de forma coletiva que foi validada cientificamente. Sobre o processo de projeção de características da personalidade em manchas os autores, do manual que utilizamos pontuam o seguinte:

*“Não é a mancha que dá forma ao conteúdo; ela é um estímulo-meio a que o examinando dá a forma da imagem mnêmica que vem de sua mente organizadamente ou desorganizadamente, isto é,*

*conforme o seu mundo interno esteja sadamente organizado ou desorganizado” [Vaz & Alchieri, 2016, p.51].*

A possibilidade da aplicação coletiva do Z-teste é uma grande vantagem para a construção de um *corpus* para modelos TB-APR, entretanto a aplicação e correção do Z-Test não é trivial. Ela deve ser feita por um psicólogo com plenos direitos de exercer sua profissão, registrado no conselho regional de psicologia (CRP). Este profissional deve, preferencialmente, ser especializado e certificado na aplicação e correção do Z-teste. O autor desta pesquisa possui esses requisitos por ser graduado também em Psicologia. Subdividimos esta seção em duas sub-seções, uma referente à aplicação coletiva do Z-teste e a outra à correção, explicando as particularidades de cada uma destas etapas.

### **7.1.1 A Aplicação Coletiva do Z-teste.**

A aplicação do Z-teste foi realizada em sua forma coletiva; sendo assim, foram selecionados conjuntos de no máximo 35 indivíduos em dias diferentes para a realização do protocolo. Nos dias da execução do protocolo, cada coordenação de curso referente às instituições que participaram da pesquisa, forneceu uma sala. Estas salas eram bem arejadas, com uma mesa para cada indivíduo participante da pesquisa e com equipamento para a projeção das três figuras do Z-teste. Nestas salas, foi tomado o cuidado especial no sentido de certificar que todos os participantes pudessem enxergar as figuras projetadas sem dificuldades. O protocolo de aplicação do Z-teste teve a duração de 45 minutos. Antes de iniciar a aplicação do Z-teste, uma palestra introdutória motivacional sobre o desenvolvimento da pesquisa foi realizada nos 15 primeiros minutos, totalizando nesta etapa o tempo total de 1 hora.

No dia da aplicação do protocolo, antes de começar a palestra introdutória, o material relacionado a aplicação do Z-teste foi entregue para cada indivíduo que consistiu em 2 folhas de papel dentro de um envelope (foi solicitado que apenas abrissem o envelope quando fossem instruídos) e uma caneta esferográfica azul. As duas folhas de papel dentro do envelope era respectivamente:

1. Uma folha para os indivíduos escreverem as respostas, descrevendo o que foi lembrado e sugerido por cada imagem ou figura mostrada; esta folha é chamada de *folha de administração*.
2. A outra folha é para os indivíduos mapearem as partes ou o todo das figuras em que suas respostas foram relacionadas, chamada de *folha de mapeamento*.

Na *folha de administração* havia um cabeçalho com um número de identificação e campos de dados como idade, sexo, escolaridade, função que exerce no trabalho e a data. Logo após o cabeçalho, havia a seguinte instrução:

*“Procure escrever o que a imagem projetada na tela lhe sugere e lembra, em toda imagem, ou no centro, ou nos lados, conforme e onde você mesmo perceber, isto é, no total da imagem ou em partes. Escreva nesta folha, bem à esquerda o nome do que está sendo sugerido, do que está sendo lembrado, e em seguida procure comentar e explicar para que fique claro o que você está tentando dizer. Fazendo assim, você ajuda muito o psicólogo a entender o que está querendo dizer. Favor não escrever na última coluna à direita”* [Vaz & Alchieri, 2016, p.33].

Ainda na folha de administração (Tabela 12), logo abaixo do cabeçalho e das instruções, existia uma tabela. Um campo à esquerda da tabela foi reservado para o indivíduo escrever o que está sendo lembrado em cada imagem. Outro campo, no meio da tabela, foi reservado para o indivíduo explicar em detalhes o que foi identificado no campo à esquerda. Finalmente, no campo mais à direita, havia uma instrução para essa parte ser deixada em branco. Este último campo possui a função de auxiliar o psicólogo na futura quotação.

<b>Nome</b> do que está sendo lembrado.	<b>Comente</b> e explique o que está sendo sugerido e lembrado.	Não escrever nesta margem.
I – Um morcego.	Esta imagem, considerada no total parece um morcego. Tenho a impressão dele estar voando.	
Uma pessoa.	Considerando o meio da figura. Está de braços abertos, pedindo socorro	
Uma nave especial	Considerando o total da imagem. O branco do fundo é o espaço sideral.	
II- nome figura II.	Explicação nome.	
(outro nome)	Explicação outro nome.	
III – nome figura III.	Explicação nome.	

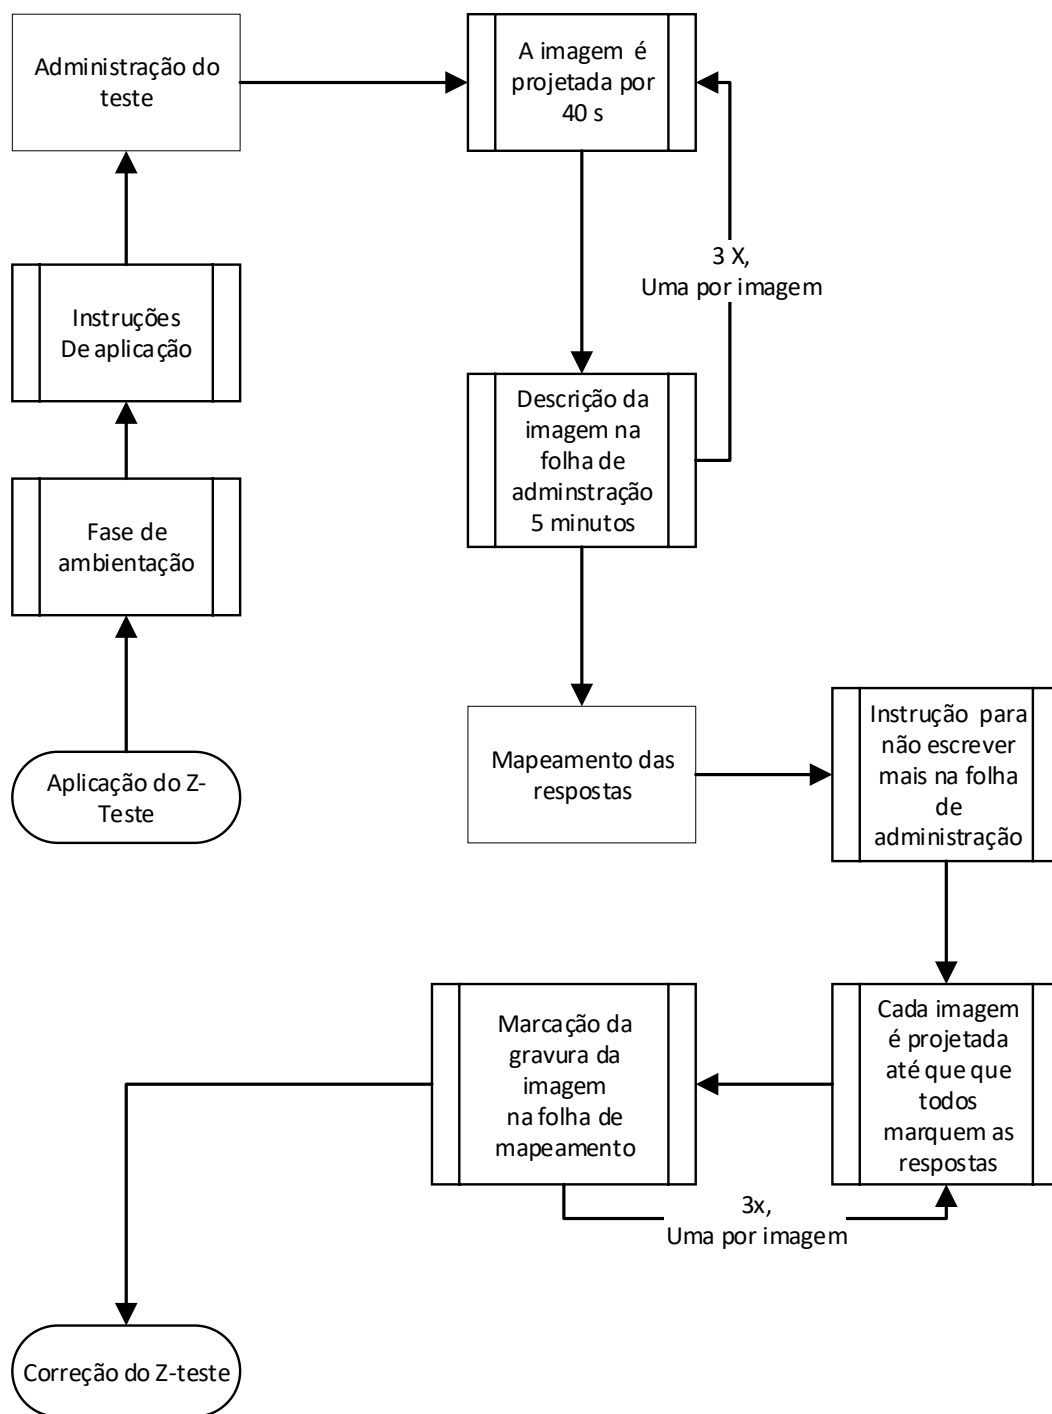
**Tabela 12.** Folha de administração do Z-teste. Adaptado de [Vaz & Alchieri, 2016, p. 33].

Na segunda folha entregue aos participantes, chamada de folha de mapeamento, havia o mesmo cabeçalho de identificação da folha de administração. Nesta folha, as três imagens utilizadas no Z-teste [Vaz & Alchieri, 2016, p. 34] estavam proporcionalmente alocadas, com a mesma ordem de exibição das figuras (verticalmente) especificadas no manual. Esta folha foi utilizada pelos participantes em uma fase do protocolo de aplicação do Z-teste, na qual é realizada a localização de respostas nas figuras. Após entregar o material aos participantes e terminar a palestra introdutória, deu-se início à aplicação do Z-teste propriamente dita.

O processo de aplicação do Z-teste, na sua forma coletiva, ocorreu em quatro fases distintas. Estas fases estão enumeradas a seguir [Vaz & Alchieri, 2016, p. 35]:

- 1) Ambientação (Rapport): Nesta fase a tarefa principal do psicólogo é a de formar um vínculo com o grupo com o qual o teste está sendo aplicado. Para isso é necessária uma conversa informal e espontânea que passe confiança ao grupo em relação ao trabalho. Este processo foi realizado por meio da palestra introdutória.
- 2) Instruções: As instruções foram dadas após a fase de ambientação, explicando para o grupo como o teste seria aplicado, frisando que o procedimento de aplicação é bastante simples. Foi falado que as luzes seriam apagadas, para que imagens, que são manchas feitas ao acaso, fossem projetadas por um tempo. Foi orientando que cada participante analisasse o que aquela imagem lembra ou sugere, pensando o que aquela imagem lembra, podendo ser o total da imagem, os lados ou o centro. Também foi frisado que tudo aquilo que fosse imaginado deveria ser escrito na folha de administração, não existindo resposta certa ou errada. Foi ressaltado que para algumas pessoas certas imagens podem remeter a mais lembranças e, para outras, menos, mas que o mais importante seria deixar a imaginação fluir da forma mais natural possível. Em seguida:
  - a. Foi permitido que todos os participantes retirassem a folha de administração dos envelopes.
  - b. Foi orientado que o cabeçalho da folha de administração deveria ser preenchido imediatamente.
  - c. Neste momento também foi orientado que após cada imagem ser exibida, todos deveriam escrever o nome daquilo que está sendo lembrado na primeira coluna da folha, numerando cada nome. Adicionalmente, foi orientado que um comentário sobre cada observação numerada na primeira coluna da folha, deveria ser feito na segunda coluna, detalhando da melhor maneira possível aquilo que foi observado. Finalmente foi orientado para que não se escrevesse nada na terceira coluna.

- 3) Administração: Antes do início do processo de administração do teste foi dada uma breve explicação de como o protocolo ocorreria. Foi explicado que, em um primeiro momento, a sala seria escurecida para mostrar uma imagem por vez, do total de 3 três imagens, por um certo tempo (40 segundos). Este tempo, em que a luz ficaria apagada, não se poderia escrever nada, seria um tempo dedicado apenas para observar atentamente os detalhes da figura exibida. Após a projeção de cada uma das imagens, as lâmpadas do fundo da sala seriam acesas, e 5 minutos seriam dados para que a folha de administração fosse preenchida, deixando a figura projetada em segundo plano, mas sendo exibida em todo este tempo. Terminado o tempo da fase de administração, após a exibição das três figuras, foi orientado para que se *escrevesse mais nada na folha de administração*.
- 4) Mapeamento: Na fase de mapeamento as luzes foram totalmente acesas, foi permitido que tirassem a *folha de mapeamento* dos envelopes e preenchessem o cabeçalho. Sendo assim:
  - a. Foi orientado que as imagens seriam novamente projetadas uma a uma, e que nesta folha seria necessário contornar o desenho (que é uma cópia idêntica das imagens, em menor escala), indicando os nomes que foram mapeados através de números na primeira coluna da *folha de administração* (fase anterior). Foi instruído que se indicasse explicitamente as partes da figura ou a figura inteira.
  - b. O tempo de exibição da projeção de cada imagem foi respeitado até que todos terminassem o processo de mapeamento para cada uma das três figuras.



**Figura 15.** Aplicação coletiva do Z-teste.

A Figura 15 mostra um fluxograma com as etapas de aplicação coletiva do Z-teste. No fim da fase de mapeamento, uma conversa informal para aliviar a ansiedade pode ser útil.

### 7.1.2 A Correção do Z-teste.

Após a aplicação do Z-Teste coletivo todas as respostas foram analisadas, uma a uma, por um psicólogo certificado a aplicar o teste. Para isso, foi utilizada uma folha especial chamada de *folha de tabulação* [Vaz & Alchieri, 2016, p. 71]. Nesta folha, o profissional quantificou cada resposta, contando o número de respostas de acordo com as diversas variáveis pré-especificadas no manual Z-teste. Estas variáveis são agrupadas em 4 principais dimensões variáveis (localização, determinantes, conteúdos e fenômenos especiais). No processo de correção, as folhas de aplicação e mapeamento de cada indivíduo foram cuidadosamente examinadas pelo psicólogo que realizou uma busca sistemática, contabilizando cada uma das variáveis descritivas pertencentes a estas dimensões. Em seguida, estas contagens foram tabuladas na folha de tabulação.

A seguir, seguem as quatro principais dimensões (em negrito) que foram tabuladas com suas respectivas variáveis a serem contabilizadas [Vaz & Alchieri, 2016, p. 42 - p. 69]:

1. **Localização:** O pedaço da figura (pode ser toda a figura) atrelado à percepção que originou a resposta. Para achar a localização utiliza-se a folha de marcação de cada indivíduo. Adicionalmente, um atlas de auxílio da correção, com os mais variados tipos de localizações é utilizado. Para cada figura é possível existir mais de uma localização, se as respostas forem atreladas a localizações diversas. Nesta dimensão são contados os números de associações às seguintes localizações:
  - a. *Global (G)*, caso exista fenômeno especial (ex: confabulação, contaminação), indicar no campo FE da folha de tabulação com o nome do fenômeno.
    - i. *Global Cortada (Gcort)*, resposta que incide no mínimo em dois tocos da mancha, cuja incidência estatística seja menor que 4%.
    - ii. *Global elaborada (DG + elaboração)*, inicia a resposta partindo de um detalhe (D) da mancha, organizando o pensamento de forma bem trabalhada, com a resposta final abrangendo o total da mancha (G).
    - iii. *Global confabulada (DG + confabulação)*, inicia a resposta a partir de um detalhe (D) da mancha, terminando em uma percepção global (G), mas o pensamento é caracterizado por fantasia e divagação verbal.
    - iv. *Global contaminada (DG + contaminação)*, inicia a resposta a partir de um detalhe (D) da mancha e tenta chegar em uma percepção global (G), fazendo uma síntese de forma incoerente, absurda ou ilógica.



- b. *Detalhe comum* (D). Incidência de detalhes de frequência igual ou maior que em 4.5 % das respostas.
- c. Detalhes incomuns. Incidência de detalhes de frequência menor que em 4.5% das respostas.
  - i. *Detalhe diminuto* (dd). A resposta se localiza em uma área muito pequena da mancha, geralmente nas extremidades.
  - ii. *Detalhe externo* (de). Quando existe ênfase apenas no contorno de certa área da mancha.
  - iii. *Detalhe inibitório* (DO). Também chamado de detalhe oligofrênico. Este tipo de detalhe incomum é referente à percepção de partes de pessoas e localizações nas quais a maioria dos indivíduos veriam pessoas inteiras.
  - iv. *Detalhe raro* (dr). Respostas de detalhes incomuns que não se enquadram em qualquer outro critério de detalhes incomuns.
- d. *Espaço branco* (S). No sistema Kopfer, o espaço em branco não é uma categoria específica de localização, ele é sempre associado a um dos três principais grupos de localização, ou seja, as Globais (a), os Detalhes comuns (b) e os Detalhes incomuns (c). Alguns exemplos de combinação do espaço em branco com as localizações estão exemplificados abaixo:
  - i. Global associada ao espaço em branco (GS). A resposta termina em uma percepção Global (G), com a inclusão do espaço em branco (S), mas sem enfatizar o branco.
  - ii. Global com S enfatizado (SG). A resposta inicia com um processo de percepção do branco (S), terminando em uma percepção Global (G).
  - iii. Global iniciada por detalhe com a inclusão do branco intermediário (DSG). A resposta é iniciada a partir de um detalhe comum da mancha (D), incluindo o espaço em branco intermediário (S), terminando em uma global (G).
  - iv. Detalhe comum com espaço em branco enfatizado (SD).
  - v. Detalhes incomuns combinados com espaço em branco. Exemplo, detalhe raro combinado com espaço em branco (drS).

2. **Determinantes:** São os processos psíquicos que determinam a percepção do conteúdo pelo indivíduo. Eles são fatores que dizem respeito a determinação de uma resposta

do examinando. “Os determinantes são a expressão do modo como o examinando estabelece a relação entre seu mundo interno e o mundo externo” [Vaz & Alchieri, 2016]. É possível ter dois ou mais determinantes na mesma resposta, sendo assim o determinante principal deve ser achado e os outros determinantes são marcados como adicionais.

- a. Critérios para os *determinantes de forma*. São respostas com ênfase em seus aspectos formais, sem combinações com ações, cores, texturas ou sombreado. Estes determinantes consideram que as respostas de forma são projeções do mundo interno do examinado, em relação à aprendizagem e internalização que permitem ao examinando dar formas a estruturas ambíguas (sem estruturação). As formas dizem respeito ao controle geral do examinando, investigando a expressão lógica e intelectual da percepção [Vaz & Alchieri, 2006, p. 88]
  - i. *Forma precisa* (F+). Conteúdo verbalizado de forma clara, compreendendo um dos dois requisitos: (1) a resposta é considerada comum (ou global) para a área que foi indicada, encerrando o conteúdo de forma simples (sem combinação de determinantes de cor, monocromáticos (preto, cinza/escuro), movimentos ou sombreados. (2) a resposta é considerada incomum para a área que foi indicada, mas o indivíduo caracteriza bem este conteúdo, descrevendo seu formato.
  - ii. *Forma imprecisa* (F-). Respostas envolvendo formas de má qualidade podendo ser: (1) confusa ou vaga, com dificuldades para descrever a forma, (2) formas acompanhadas de fenômenos especiais comprometedores tais como contaminação, confabulação, resposta de posição, resposta de auto-referência, (3) respostas abstratas.
  - iii. *Forma com precisão duvidosa* (F+-). Respostas em que o conteúdo não está claro ao examinado. Pode ser que o examinando forneça uma resposta simples, mas depois retire a precisão da forma, enumerando outra forma, ou achando que não era bem aquilo que tinha falado.
  - iv. *Somatório de formas* ( $\Sigma F$ ): Contagem de todas as formas. Representação do controle racional e controle geral do examinando.
- b. Critérios para os *determinantes de movimento*. Estes determinantes são relacionados a respostas que indiquem percepção de ações, podendo ser desencadeadas por pessoas, animais ou por ação abstrata, física, química ou mecânica.

- i. *Movimento humano* (M). O movimento humano diz respeito as funções integradoras do mundo interno da personalidade [Vaz & Alchieri, 2016, p.107], representando aspectos relacionados a espontaneidade, criatividade e empatia. As respostas referentes ao movimento humano são classificados como:
  - I. *Movimento humano de boa performance* (M+). Ser humano inteiro, em ação (deslocamento, tensão, postura).
  - II. *Movimento humano de tipo descaracterizado* (M-). (1) Detalhe humano em ação, (2) ser humano visto inteiro, mas com descaracterização (ex. seres mitológicos), (3) conteúdo humano acompanhando fenômenos especiais.
  - III. *Movimento humano duvidoso* (M+-). (1) Pessoas em ação, vistas por inteiro, mas o examinando coloca em dúvida se estão em ação ou não. (2) Pessoas em que o examinando explicita dúvidas se são pessoas do mundo real ou pessoas de um mundo fantasioso.
- ii. *Movimento animal* (FM). Respostas referentes a movimentos de animais. É um indicador de iniciativa e competição [Vaz & Alchieri, p. 91].
- iii. *Movimento inanimado*. Respostas relacionadas à ação física, química ou abstrata. É um indicador de conflitos intrapsíquicos [Vaz & Alchieri, p. 110]. As respostas de movimento inanimado são divididas em:
  - I. (Fm), quando o movimento inanimado é verbalizado com uma forma definida.
  - II. (mF), quando o movimento inanimado é percebido com uma forma não definida.
  - III. (m), quando o movimento inanimado não possui forma.
- c. Critérios para a cor: As cores são marcadores fundamentais da personalidade no Z-teste. Estímulos coloridos em tons de vermelho, verde, marrom estão presentes nas imagens II e III. Estímulos em escalas de cinza, preto e escuro estão presentes na imagem I. Podemos entender os determinantes de cor, como estímulos de impacto mobilizador do mundo interno do examinando [Vaz & Alchieri, 2016, p.107], fornecendo pistas sobre o relacionamento interpessoal [Vaz & Alchieri, 2016, p. 92]. Os determinantes de cor são classificados em:

- i. *Cor e forma precisa* (FC). Presença de cor na resposta, com forma bem definida e a cor compatível à área de localização no atlas da mancha.
- ii. *Cor e forma imprecisa / Cor e tentativa de forma* (CF). (1) Presença de cor na resposta, sem que o examinando perceba com precisão o formato, (2) conteúdos gasosos, líquidos e difusos, (3) forma definida, mas associada a sangue, (4) percepções onde o examinando afirma que é uma “mancha de tinta”.
- iii. *Cor arbitrária* (F/C e C/F). Quando a percepção do examinando acredita tratar-se de um colorido artificial que sofreu um processo realizado por algum tratamento de imagem fotográfica ou de laboratório. (1) se o conteúdo tem a forma precisa, classifica-se como (F/C), caso contrário, (2) classifica-se como (C/F).
- iv. *Cor forçada* (F-C e C-F). Quando uma cor é atribuída, sendo que ela não está presente na mancha, mesmo que a forma real do que foi percebido, tipicamente seja da cor que o examinando relatou. (1) Se o conteúdo tem a forma precisa, classifica-se como (F-C), caso contrário, (2) classifica-se como (C-F).
- v. *Cor pura* (C). Quando a cor é percebida sem menção a forma alguma, com compatibilidade entre a cor relatada e a área da mancha indicada.
- vi. *Cor descrita* (Cdesc). O examinando descreve apenas as nuances da cor, não conseguindo organizar o pensamento de forma mais objetiva.
- vii. *Cor simbólica* (Csimb). Quando a região colorida é descrita em relação a alguma simbologia, como por exemplo “aqui é um verde da sorte”.
- viii. *Cor nomeada/enumerada* (cn). Sinal típico de perturbação de pensamentos, onde o sujeito fornece uma resposta enumerando as cores presentes na mancha.
- ix. *Cor acromática* (FC’, C’F, C’). Respostas relacionadas a cor acromática (preto, escuro, cinza), compatíveis com a área indicada na mancha. (1) Classifica-se o examinando com (FC’) se o conteúdo tem forma bem definida, (2) caso a forma não seja bem explicada, classifica-se como (C’F) e (3) caso não se faça referência a formas na resposta, classifica-se como (C’).

- d. Critérios para o sombreado. Os sombreados são indicadores de ansiedade, em relação a esta ansiedade pode ocorrer a adaptação afetiva ou o precário controle [Vaz & Alchieri, 2016 p. 95]. Os determinantes relacionados ao sombreado são detalhados abaixo [Vaz & Alchieri, 2016, p. 61]:
- i. *Sombreado radiológico* (Fk, kF, K). Estes determinantes são referentes a áreas percebidas na mancha como sombreados, dando a impressão de se tratar de um espaço tridimensional, projetado em uma superfície bidimensional. Classifica-se o examinando com (Fk) se o conteúdo for percebido como mapa, transparência, radiografia, foto ou filme. (2) Caso o conteúdo não tenha forma bem definida, utiliza-se o (kF). (3) Se o examinando não conseguir dar forma nenhuma ao sombreado, classifica-se como (k).
  - ii. *Sombreado perspectiva* (FK, KF, K). São respostas referentes a espaços tridimensionais, projetadas no espaço dimensional, que sempre estão relacionadas a uma perspectiva de espaço (ex: “lá no fundo”). (1) utiliza-se (FK), quando o conteúdo é relatado em profundidade ou perspectiva com forma bem definida. (2) Caso exista apenas alguma ideia de forma, utiliza-se o (KF). (3) Se o conteúdo for difuso (estado líquido ou gasoso), utiliza-se o (K).
  - iii. *Sombreado textura* (Fc, cF,c). Sendo a textura um indicador de percepção tátil, podemos entendê-la como um dos estados de afetos mais primordiais dos seres humanos. Este determinante é caracterizado pela sensação de superposição de camadas (ex: “áspero”). (1) utiliza-se (Fc) quando o conteúdo relacionado à textura é relatado com forma bem definida, (2) se a forma for vaga, utiliza-se (cF). (3) Caso não exista forma relacionada, utiliza-se a marcação (c).
3. **Conteúdos:** Entende-se por conteúdos tudo aquilo que foi percebido; os conteúdos são contabilizados quantitativamente e classificados em tipos [Vaz & Alchieri, 2016 p. 66].
- a. *Humano* (H).
    - i. Humano descaracterizado ((H)).
    - ii. Detalhe humano (HD).
    - iii. Detalhe Humano descaracterizado ((HD)).
  - b. *Animal* (A).

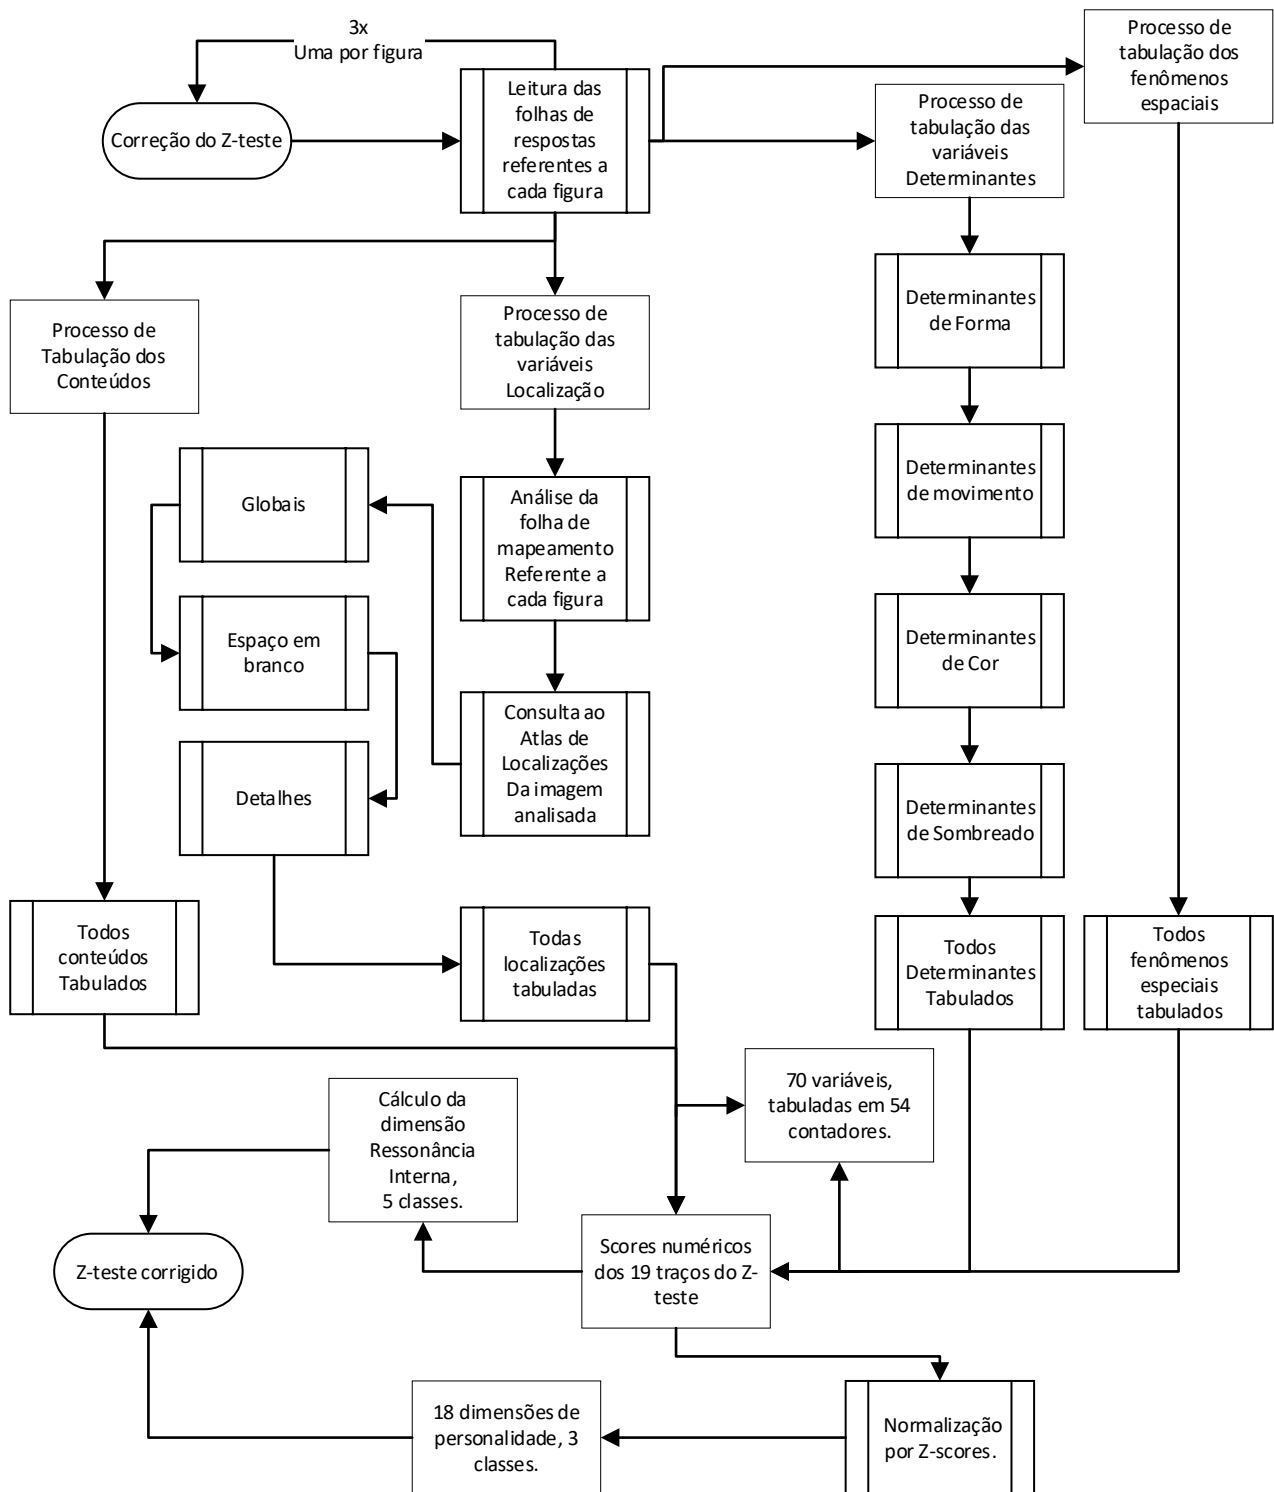
- i. Animal descaracterizado (Ad).
  - ii. Detalhe animal (Ad).
  - iii. Detalhe animal descaracterizado ((Ad)).
- c. *Objeto* (obj).
  - i. Objeto humano (Hobj).
  - ii. Objeto animal (Aobj).
  - iii. Objeto espacial (Objesp).
- d. *Abstrato* (Abst).
- e. *Alimento* (Al).
- f. *Anatômico* (At).
- g. *Planta* (PL).
- h. *Natureza* (Nat).
- i. *Água* (Água).
- j. *Arte* (Arte).
- k. *Nuvem* (Nuv).
- l. *Geográfico* (Geo).
- m. *Arquitetônico* (Arq).
- n. *Mecânico* (Mec).
- o. *Sangue* (Sangue).
- p. *Sex* (sexo).
- q. *Fogo* (Fogo).

4. **Fenômenos especiais:** Respostas não possíveis ou difíceis de serem quantificadas [Vaz & Alchieri, 2016 p. 68].

- a. *Choque ao branco.* Preocupação do examinando em relação as áreas brancas referentes ao exterior das manchas. Indicador de ansiedade situacional, sentimentos de insegurança, inferioridade.
- b. *Choque ao vazio.* Preocupação do examinando em relação as áreas brancas situadas no interior das manchas. Mais grave que o choque ao branco, podendo ser indicador de perda afetiva, abandono ou dificuldade psicosssexuais.
- c. *Choque acromático.* Perturbação do examinando em relação as áreas acromáticas das manchas. Podendo ser (1) comentários depreciativos sobre a área, (2) diminuição de quantidade e qualidade de respostas relacionadas as partes acromáticas destas manchas, (3) comentários depreciativos sobre o colorido e (4) expressões de repugnância.

- d. *Choque cromático*. Perturbação em relação as áreas coloridas das manchas, utilizando os mesmos critérios do choque acromático, mas em relação a parte cromática das manchas.
- e. *Choque de exclamação*. Expressões caracterizadas por expressões fortes.
- f. *Confabulações*. Utilização de excesso de fantasia nas respostas (história), indicador de fuga.
- g. *Contaminação*. Síntese de forma incoerente, absurda ou ilógica. É um fenômeno especial comprometedor em relação à organização, coerência e precisão dos pensamentos.
- h. *Crítica a técnica*. Críticas ao teste, as manchas de forma generalizada. Estas críticas são típicas de defesas paranóides.
- i. *Ideia de auto-referência*. Respostas indentificando partes de si mesma ou coisas de sua propriedade. Pode indicar esquizofrenia.
- j. *Ideia de referência*. Respostas relacionadas a coisas ou pessoas de seu relacionamento. Pode ser um indicador de neurose ou confusão.
- k. *Linguajar requintado*. Expressões requintadas, esnobes. Podem indicar transtorno psicosexual ou epilepsia.
- l. *Mutilação*. Caracterização por pessoas ou animais com membros mutilados, cortados, machucados. Pode indicar uma tendência ao sadismo.
- m. *Sentimento de incapacidade*. Caracterização por uma indicação de dificuldade para realizar as tarefas propostas pela técnica. Pode ser um indicativo de depressão.

No total aproximadamente 70 variáveis foram analisadas e quantificadas, produzindo 54 tabulações de contagens diferentes, sendo assim algumas tabulações são reduções fatoriais destas variáveis. Destas tabulações foram extraídas 19 dimensões de personalidade. A Figura 16 mostra o fluxograma da correção do Z-teste.



**Figura 16.** Fluxograma de correção do Z-teste.

Finalmente, após a correção dos protocolos, foi realizada a interpretação do Z-teste. A próxima seção relata os detalhes do processo de interpretação do Z-teste.



### 7.1.3 O *Feedback* aos Participantes do Corpus Z-teste.

Todos os participantes da pesquisa receberam via e-mail, um documento de texto eletrônico com as análises personalizadas relativas à interpretação das 19 dimensões de personalidade do Z-teste. O relatório de personalidade continha o título “Z-teste – Relatório Individual de Personalidade”, com o seguinte cabeçalho:

Este experimento avaliou a sua personalidade através da aplicação coletiva de uma técnica projetiva chamada de Z-teste, ou teste de Zulliger. Neste experimento utilizamos o protocolo do Z-teste adaptado para populações do sul do Brasil proposto por Cícero E. Vaz e João Carlos Alchieri [Vaz & Alchieri, 2016], líderes em pesquisa com o Z-teste no Brasil. O processo de análise da personalidade foi realizado através da avaliação das folhas de respostas e folhas de mapeamento. A análise utilizou métodos de contagens de variáveis de acordo com as localizações, determinantes e conteúdos seguindo o protocolo proposto pelos pesquisadores. Todas as contagens foram categorizadas para cada um dos 19 construtos psicológicos do protocolo. Para fins de diagnósticos da personalidade, os scores brutos de cada indivíduo foram comparados com os scores brutos dos demais 363 indivíduos que participaram desta pesquisa (todos estudantes ou graduados em nível superior de universidades do sul do Brasil). Estas comparações produziram a seguinte escala de classificação da personalidade: aumento (acima de um desvio padrão), diminuição (abaixo de um desvio padrão) ou média (entre mais ou menos um desvio padrão). Como a maioria dos participantes desta pesquisa são estudantes de psicologia, propusemos neste feedback uma análise mais técnica das dimensões do Z-teste, permitindo ao estudante verificar quais aspectos de percepção foram levados em conta para cada constructo psicológico, com todos os possíveis desfechos categóricos. Ressaltamos que estes desfechos encontrados para cada construto são passíveis de mudanças ao longo do tempo, de acordo com o amadurecimento do indivíduo e de acordo com o tamanho e especialização da amostra utilizada para comparação.

Depois do cabeçalho, as 19 dimensões de personalidade foram detalhadas minuciosamente em tópicos, com todos os desfechos possíveis para cada dimensão, conforme a seção 7.1.4. Sendo assim, antes de relatar as dimensões de personalidade no relatório, a seguinte instrução foi deixada em negrito:

**Para o diagnóstico individual de personalidade, o desfecho encontrado na sua análise encontra-se em negrito. Sendo assim, em todos os construtos psicológicos do Z-teste, para fins de avaliação de sua personalidade, considere apenas o desfecho que está em negrito.**

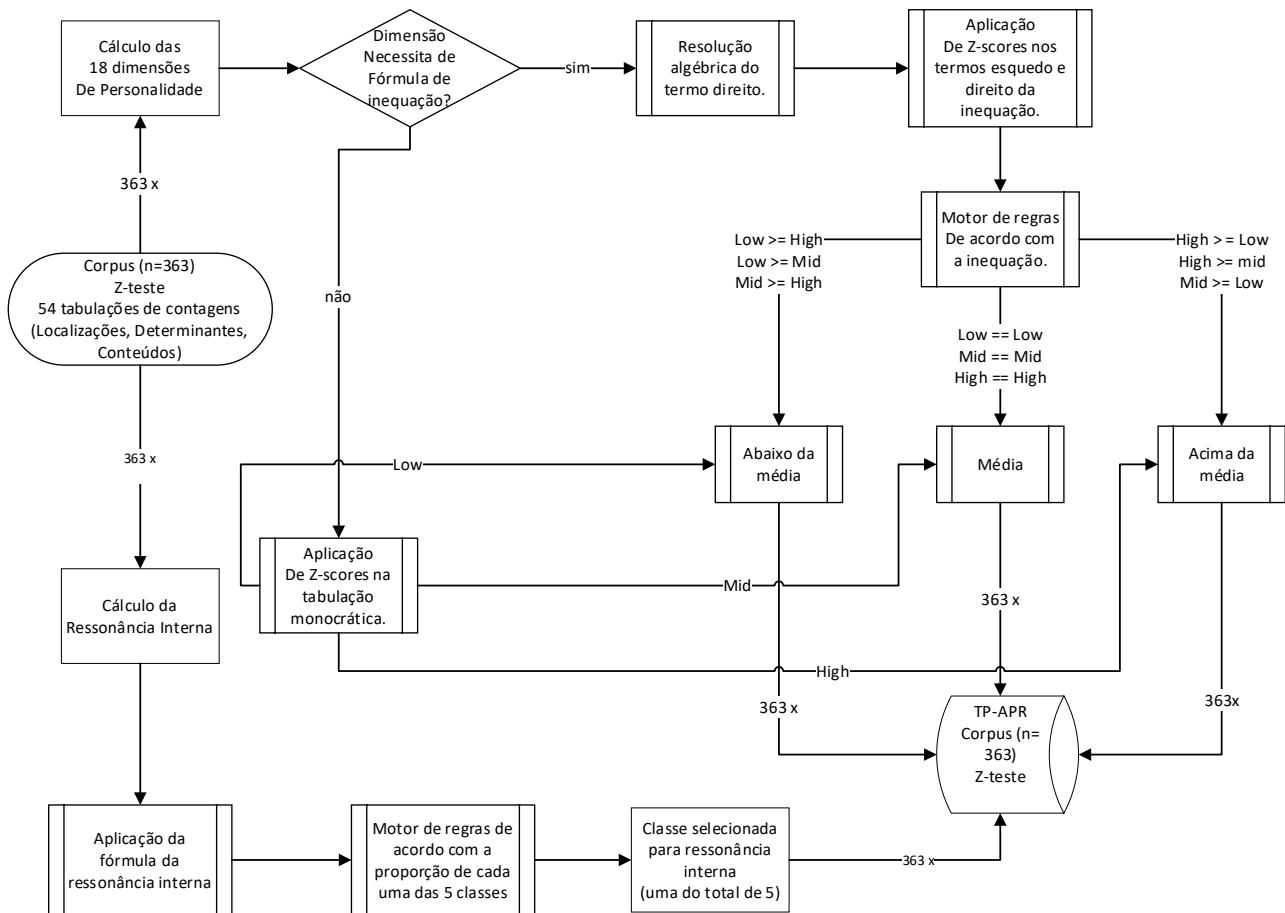
Desta maneira, no final de cada explicação dimensional da personalidade, após enumerar todos os desfechos de personalidade possíveis, o desfecho personalizado a cada indivíduo foi deixado em negrito, utilizando uma fonte maior para dar ênfase.

#### **7.1.4 As Dimensões de Personalidade e a Interpretação do Z-teste.**

A metodologia de interpretação foi diretamente deduzida do manual do Z-teste [Vaz & Alchieri, 2016], sendo revisada por um psicólogo experiente.

“Diferente de outros testes psicométricos, a utilização e a interpretação dos resultados do Zulliger necessariamente exigem do usuário um conhecimento aprofundado da técnica e dos constructos psicológicos envolvidos, visto que não são dados numéricos que fundamentam a interpretação e sim o significado, empiricamente estabelecido, das figuras apresentadas pelo respondente”. [Vaz & Alchieri, 2016, p. 15]

Entre as 19 dimensões de personalidade do Z-teste, 18 dimensões possuem três desfechos possíveis (classes). Estas dimensões foram inferidas por fórmulas ou pela tabulação de maneira monocrática, combinadas com a técnica de Z-scores. A Figura 17 detalha o fluxograma da metodologia utilizada para calcular as classes referentes as dimensões do Z-teste. Estas classes são utilizadas para a interpretação da personalidade em cada constructo psicológico.



**Figura 17.** Metodologia utilizada para calcular as classes para as 19 dimensões do Z-teste.

Conforme podemos observar no fluxograma da Figura 17, a ressonância interna possui particularidades em relação às outras dimensões (ex. 5 classes ao invés de 3). Detalharemos estas particularidades na seção 7.1.4.19. As próximas sub-seções detalham a interpretação e os possíveis desfechos de cada dimensão do Z-teste.

#### 7.1.4.1 Respostas ( $\Sigma R$ ): Capacidade de Desempenho e de Adaptação Geral.

O Z-Teste “expõe o examinando a diversas situações de dificuldades, que serão resolvidas através de sua inteligência e de acordo com a sua personalidade, sendo assim, o número de respostas pode ser entendido como a Capacidade de Desempenho e Adaptação Geral” [Vaz & Alchieri, 2016, p. 87, 88]. A *Capacidade de Desempenho e Adaptação Geral* ( $\Sigma R$ ) é inferida através da fórmula 16, compreendendo o número total de respostas nos três cartões.

$(\Sigma R) = ((\Sigma R1) + (\Sigma R2) + (\Sigma R3))$	(16)
--	------

Desta maneira, utilizando a técnica de Z-scores, comparando a contagem dos determinantes ( $\Sigma F$ ) que cada indivíduo obteve em um protocolo, com as contagens de ( $\Sigma R$ ) dos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Capacidade de Desempenho e de Adaptação Geral*.

1. O aumento em ( $\Sigma R$ ) é um indicativo de obsessividade, preocupação excessiva com detalhes e minúcias. Neste sentido, pode haver prejuízo da percepção do conjunto, mas por outro lado, também caracteriza um poder de análise minucioso e acurado.
2. A média em ( $\Sigma R$ ) indica um bom desempenho e adaptação geral em situações de dificuldades. Denota uma adequada capacidade de produção, com condições de improviso e adaptação adequada a tarefas ou situações de trabalho.
3. A diminuição em ( $\Sigma R$ ) é um indicativo de condutas defensivas, medo de se expor e ansiedade de não conseguir controlar adequadamente. Também pode indicar uma limitação referente a capacidade intelectual em situações de dificuldades, relacionada à ansiedade, bloqueios emocionais ou processos defensivos.

#### 7.1.4.2 Forma Pura ( $\Sigma F$ ): Controle Geral (dimensão racional), expressão lógica do processo perceptivo.

O Controle Geral "representa a capacidade para pontuar, retardar e antecipar adequadamente atitudes e reações comportamentais. Expressa importante papel da inteligência no aprendizado do ser humano". Podemos entender que os determinantes de forma pura "examinam o potencial intelectual, racional e lógico na captação, na percepção e integração das coisas" [Vaz & Alchieri, pp. 88, 89]. O Controle Geral ( $\Sigma F$ ) é inferido através da fórmula 17, compreendendo a soma dos determinantes que se atém à forma: forma precisa (F+), forma sem precisão (F-) e forma duvidosa (F±).

$(\Sigma F) = ((F+) + (F-) + (F\pm))$	(17)
---------------------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a contagem dos determinantes de ( $\Sigma F$ ) que cada indivíduo obteve em um protocolo, com as contagens de ( $\Sigma F$ ) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Controle Geral (dimensão racional), Expressão Lógica do Processo Perceptivo*.

1. O aumento em ( $\Sigma F$ ) pode ser interpretado como um nível de exigência elevado, rigidez, severidade ou até mesmo repressão. A expressividade e espontaneidade do indivíduo poderão estar prejudicadas, principalmente quando houver exigência em demasia.

2. A média em ( $\Sigma F$ ) indica equilíbrio na Dimensão Racional e Expressão Lógica do processo perceptivo. O indivíduo mostra uma personalidade adequadamente estruturada, com a percepção das coisas e situações de maneira integrada à realidade, com objetividade, senso lógico e capacidade para perceber as coisas como de fato se apresentam na vida real.
3. A diminuição em ( $\Sigma F$ ) indica falta de objetividade. Além disso, o indivíduo pode ter uma tendência maior a envolvimento relacionados a fatores de ordem emocional ou ansiogênica, podendo haver algum nível de prejuízo na percepção do cotidiano.

**7.1.4.3 Forma e Precisão formal (F+): Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva.**

As formas precisas fornecem pistas do Funcionamento do Pensamento Lógico, utilizado para diferenciar pessoas, situações e coisas, por seus detalhes, peculiaridades e características. Este construto psicológico revela como a personalidade do indivíduo reage em relação à percepção do mundo, indicando o grau de clareza de expressão, considerando a precisão, coerência e objetividade de seus pensamentos. [Vaz & Alchieri, pp. 89, 90]. O *funcionamento do Pensamento Lógico, capacidade para estabelecer diferenciação afetiva* é deduzido monocraticamente através do determinante de forma precisa (fórmula 18).

(F+), monocraticamente	(18)
------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a contagem dos determinantes de (F+) que cada indivíduo obteve em um protocolo, com as contagens de (F+) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva*.

1. O aumento em (F+) é um indicador de clareza, precisão e organização do pensamento lógico. As pessoas, situações e coisas são diferenciadas pelas suas peculiaridades e características, com senso de objetividade. O aumento pode ser entendido como um reforçador adicional desta hipótese.
2. A média em (F+) é um indicador de clareza, precisão e organização do pensamento lógico. As pessoas, situações e coisas são diferenciadas pelas suas peculiaridades e características, com senso de objetividade.

3. A diminuição em (F+) pode ser um indicador de alguma alteração ou prejuízo no funcionamento do processo lógico. A diminuição em (F+), relacionada a uma pessoa intelectualmente bem-dotada, pode ser um sinal de interferência de certos fatores afetivos, especialmente estados constritivos ou depressivos.

#### 7.1.4.4 Movimento Humano ( $\Sigma M$ ): Espontaneidade, criatividade, empatia.

O Movimento Humano tem ligação com os processos de imaginação, criatividade e empatia. Também é relacionado à expressão da personalidade em relação à espontaneidade e ajustamento ao ambiente humano. Podemos entender a dimensão *Espontaneidade, Criatividade, Empatia* como uma representação do que o indivíduo viveu e experimentou em relação ao convívio com outras pessoas [Vaz & Alchieri, p. 90]. A dimensão *Espontaneidade, Criatividade, Empatia* é inferida através da fórmula 19, compreendendo os determinantes de movimentos humanos, ou seja, a soma dos movimentos humanos de boa performance (M+), movimentos humanos descaracterizados (M-) e movimentos humanos duvidosos (M±).

$(\Sigma M) = ((M+) + (M-) + (M\pm))$	(19)
---------------------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a contagem dos determinantes de ( $\Sigma M$ ) que cada indivíduo obteve em um protocolo, com as contagens de ( $\Sigma M$ ) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Espontaneidade, Criatividade, Empatia*.

1. O aumento de ( $\Sigma M$ ) expressa inteligência altamente criativa, capacidade criadora com imaginação fértil e ótima capacidade de integração a grupos humanos com espontaneidade no trato com as pessoas.
2. A média de ( $\Sigma M$ ) expressa criatividade adequada, imaginação fértil, capacidade de integração a grupos humanos, empatia e espontaneidade suficientes no trato com as pessoas.
3. A diminuição em ( $\Sigma M$ ) está relacionada a baixa espontaneidade e prejuízo em situações exigidas de integração a grupos humanos ou criatividade.

Neste construto, após verificar as hipóteses de ( $\Sigma M$ ), é possível fazer a comparação dos scores brutos dos determinantes (M+) e (M-), utilizando a fórmula 20:

$(M+) \geq (M-)$	(20)
------------------	------

Sendo assim, utilizando a fórmula 20 em combinação com o diagnóstico feito a partir de  $(\sum M)$ , teremos um dos dois desfechos:

1. Após verificar o desfecho de  $(\sum M)$ , foi constatado o aumento ou igualdade dos scores brutos de  $(M+)$  em relação a  $(M-)$ , que é um reforçador positivo esperado para este constructo.
2. Após verificar o desfecho de  $(\sum M)$ , foi constatada a diminuição de  $(M+)$  em relação a  $(M-)$ , que é um indicador de receio, tensão, inibição e ansiedade nos relacionamentos interpessoais. Neste sentido, mesmo que o  $(\sum M)$  esteja na média ou aumentado, devemos fazer o diagnóstico com essa ressalva. Isso não impede que o indivíduo seja criativo, espontâneo, flexível ou empático, mas a forma com que isso acontece é de forma tensa, limitada, baseada em preceitos de desconforto.

#### 7.1.4.5 Movimento Animal (FM): Impulsividade e dinamismo.

A *Impulsividade e Dinamismo*, expressa através do movimento animal, denota a iniciativa e capacidade para competição da personalidade. Este determinante é relacionado com "o que há de mais primário e arcaico na estrutura da personalidade" [Vaz & Alchieri, pp. 91, 92], ou seja, uma representação dos instintos e impulsos. A *Impulsividade e Dinamismo* é inferida através da fórmula 21.

(FM), monocraticamente.	(21)
-------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a contagem dos determinantes de (FM) que cada indivíduo obteve em um protocolo, com as contagens de (FM) dos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Impulsividade e Dinamismo*.

1. O aumento de (FM) significa impulsividade aumentada, com possível imaturidade e infantilismo nas situações cotidianas.

2. A média de (FM) demonstra que os instintos e impulsos estão sendo liberados naturalmente. Neste sentido o indivíduo apresenta poder de iniciativa e condições para disputa (ou competição) frente as suas necessidades.
3. A diminuição de (FM) é um indicador de baixo senso de iniciativa, dinamismo e de competição.

#### 7.1.4.6 Relacionamento interpessoal (FC) e a tendência a excitabilidade emocional ((CF) + (C)).

O *Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional* são representações de características de personalidade relacionadas à capacidade de receber, proporcionar e retribuir afetos, com adequação e maturidade, proporcionando um relacionamento interpessoal apropriado [Vaz & Alchieri, pp. 92, 93, 94]. Este construto psicológico é inferido através da fórmula 22, comparando os itens enumerados abaixo:

- i. Os conteúdos que indicam adequada expressão do relacionamento interpessoal, percebidos como coloridos, com a cor relatada compatível na área de localização, utilizando formas bem definidas (FC).
- ii. Os conteúdos percebidos como coloridos, mas com a forma vaga (CF), que podem ser caracterizados por: (1) presença de cor na resposta, sem que o examinando perceba com precisão o formato, (2) conteúdos percebidos como gasosos, líquidos e difusos, (3) formas definidas, mas associadas a sangue ou (4) percepções onde o examinando emprega respostas como “mancha de tinta”, indicando um precário controle na liberação emoções.
- iii. Os conteúdos de (ii) são somados com os conteúdos percebidos como coloridos, mas sem nenhuma tentativa de forma (C), indicando total descontrole emocional.

$(FC) \geq ((CF) + (C))$	(22)
--------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (FC) e ((CF) + (C)) que cada indivíduo obteve em um protocolo, com as proporções de (FC) e ((CF) + (C)) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para o *Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional*.



1. O aumento de (FC) em relação a (CF + C) favorece o indivíduo em relação ao relacionamento interpessoal; é um indicador de um padrão ajustado. Neste contexto, quando o indivíduo recebe estímulos, ele é capaz de liberar afetos, emoções e sentimentos de forma adequada e madura. O aumento é um reforçador ainda mais positivo que a média em relação a esta hipótese.
2. A média de (FC) em relação a (CF + C) favorece o indivíduo em relação ao relacionamento interpessoal; é um indicador de um padrão ajustado. Neste contexto, quando o indivíduo recebe estímulos, ele é capaz de liberar afetos, emoções e sentimentos de forma adequada e madura.
3. A diminuição de (FC) em relação a (CF+C) desfavorece o indivíduo em relação ao relacionamento interpessoal; é um indicador de que na presença de estímulos que mobilizem o indivíduo de forma afetiva, emocional e sentimental, existe uma tendência a reações precipitadas. Neste contexto, o indivíduo terá um controle mais precário sobre os afetos, emoções e sentimentos (ex: reações emocionais precipitadas – próprias de adolescentes, liberação de emoção sem controle, escapes agressivos).

#### **7.1.4.7 Ansiedade com adaptação afetiva (FK) e ansiedade com precário controle ((K)+(KF)).**

A *Ansiedade com Adaptação Afetiva e Ansiedade com Precário Controle* representa os aspectos da personalidade relacionados a situações que geram ansiedade na vida cotidiana das pessoas [Vaz & Alchieri, pp. 95, 96]. Os conteúdos em sombreado são conhecidos por gerar ansiedade, sendo assim, quanto maior a qualidade da forma relacionada aos conteúdos, mais efetivo será o controle da ansiedade. Este construto psicológico é inferido através da fórmula 23, onde é verificada a relação entre:

- i. Os conteúdos que são percebidos em perspectiva ou profundidade, mas com a forma bem definida (FK), indicando um controle no manejo da ansiedade.
- ii. Os conteúdos que são percebidos em perspectiva ou profundidade, mas apenas com uma ideia vaga de forma (KF), indicando um controle precário no manejo da ansiedade
- iii. Os conteúdos de (ii) são somados aos conteúdos percebidos de maneira totalmente difusa (K), indicando incapacidade de controlar ou suportar a ansiedade.

$$(FK) \geq ((KF) + (K))$$

(23)

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (FK) e (KF + K) que cada indivíduo obteve em um protocolo, com as proporções de (FK) e ((KF) + (K)) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para o *Ansiedade com adaptação afetiva e ansiedade com precário controle*.

1. O aumento de (FK) em relação a ((KF) + (K)), indica que a ansiedade situacional não provoca prejuízos ao equilíbrio emocional. Neste sentido, o examinando controla com introspecção e compreensão interna suas ações em relação a ansiedade. É um indicativo de que em situações de pressão externa, o examinando é capaz de voltar-se a si mesmo, fazendo uma autoavaliação, suportando possíveis sofrimentos e evitando estados depressivos. O aumento é um reforçador desta hipótese, em relação à proporção equilibrada.
2. A proporção equilibrada de (FK) em relação a ((KF) + (K)), indica que a ansiedade situacional não provoca prejuízos ao equilíbrio emocional. Neste sentido, o examinando controla com introspecção e compreensão interna suas ações em relação a ansiedade. É um indicativo de que em situações de pressão externa, o examinando é capaz de voltar-se a si mesmo, fazendo uma autoavaliação, suportando possíveis sofrimentos e evitando estados depressivos.
3. A diminuição de (FK) em relação a ((KF) + (K)) é um indicador de que a ansiedade provoca reações emocionais com precária elaboração de controle (ou ausência de controle). Neste sentido, a ansiedade pode gerar um aumento da angústia, podendo desencadear estados depressivos.

#### 7.1.4.8 Cor Acromática (FC'), (C'F), (C'): Traços depressivos da personalidade.

Os *Traços Depressivos da Personalidade* estão relacionados à áreas percebidas como escuro, preto ou cinza, desde que exista a compatibilidade de cor onde as percepções são indicadas. Podemos entender percepções acromáticas como uma forma do examinando evitar mobilizar sentimentos e emoções [Vaz & Alchieri, pp. 96, 97]. Os *Traços Depressivos da Personalidade* são inferidos através da fórmula 24, comparando:

- i. Os conteúdos percebidos como acromáticos, mas com a forma bem definida (FC'), indicando um controle adequado relacionado aos sentimentos depressivos.
- ii. Os conteúdos percebidos como acromáticos, mas com a forma mal explicada ou duvidosa (C'F), indicando um precário controle relacionado aos sentimentos depressivos.

- iii. Os conteúdos de (ii) são somados aos conteúdos percebidos como acromáticos, mas sem nenhuma tentativa de forma (C'), indicando o descontrole total em relação aos sentimentos depressivos.

$(FC') \geq ((CF') + (C'))$	(24)
-----------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (FC') e ((CF') + (C')) que cada indivíduo obteve em um protocolo, com as proporções de (FC') e ((CF') + (C')) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para os *Traços Depressivos da Personalidade*.

1. O aumento de (FC') em relação a ((C'F) + (C')), indica uma personalidade mais preparada para enfrentar sentimentos de depressão, desânimo e inferioridade. Isto significa que o examinando possui adequadas condições de enfrentar estes sentimentos depressivos, minimizando possíveis efeitos colaterais nocivos em suas atividades. O aumento é um reforçador desta hipótese em relação à proporção equilibrada.
2. A proporção equilibrada (que é um reforçador desta hipótese) de (FC') em relação a ((C'F) + (C')), indica uma personalidade mais preparada para enfrentar sentimentos de depressão, desânimo e inferioridade. Isto significa que o examinando possui adequadas condições de enfrentar estes sentimentos depressivos, minimizando possíveis efeitos colaterais nocivos em suas atividades.
3. A diminuição de (FC') em relação a ((C'F) + (C')), indica uma personalidade menos preparada para enfrentar as manifestações de sentimentos de cunho depressivos. Isto significa que os sentimentos depressivos podem causar uma sensação mais duradoura de desânimo e inferioridade, podendo impactar no desempenho das atividades cotidianas.

#### **7.1.4.9. Textura (Fc), (cF), (c): Contato humano e interação social.**

Podemos entender a percepção tátil como a expressão de contato afetivo mais primária nos seres humanos [Vaz & Alchieri, pp. 62]. Estas percepções são marcadores de conflitos entre o mundo interno e o mundo externo, polarizando experiências entre a intimidade e o mundo externo [Oñativia, 1972]. Neste sentido, "a textura é uma forma tátil de expressão das condições afetivas da pessoa, quer buscando o afeto de alguém ou em alguma coisa, quer investindo o afeto em outras pessoas, situações e objetos" [Vaz & Alchieri, pp. 97, 98]. Além disso, a percepção tátil demonstra ansiedade e angústia,

expressas pela necessidade de contato [Lopes, 1943]. No Z-teste coletivo, este processo é caracterizado pelo mecanismo de deslocamento dos sentimentos emocionais por meio da descrição de textura. No caso do Z-teste individual também é possível identificar este processo por meio da fricção afetiva direta sobre o cartão.

O *Contato Humano e a Interação Social* são inferidos por meio da fórmula 25, comparando:

- i. Os conteúdos que são percebidos como textura, mas com uma forma bem definida (Fc), indicando um preparo adequado em relação a elaboração das próprias necessidades em relação as outras pessoas.
- ii. Os conteúdos que são percebidos como textura, mas com a forma vaga (cF), indicando um preparo mais precário em relação a elaboração das próprias necessidades em relação as outras pessoas.
- iii. Os conteúdos de (ii) são somados aos conteúdos que são percebidos como textura, mas sem forma (c), indicando um despreparo na elaboração das necessidades em relação as outras pessoas.

$(F_c) \geq ((cF) + (c))$	(25)
---------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (Fc) e ((cF) + (c)) que cada indivíduo obteve em um protocolo, com as proporções de (Fc) e ((cF) + (c)) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para o *Contato Humano e a Interação Social*.

1. aumento de (Fc) em relação a ((cF)+ (c)), indica uma personalidade que possui necessidades de contato social, mas consegue adequar suas necessidades com as demais pessoas. Neste sentido, o examinando possui condições de elaborar estas necessidades, obtendo uma adaptação eficaz e eficiente no convívio social. O aumento é um reforçador desta hipótese em relação à proporção equilibrada.
2. A proporção equilibrada de (Fc) em relação a ((cF) + (c)), indica uma personalidade que possui necessidades de contato social, mas consegue adequar suas necessidades com as demais pessoas. Neste sentido, o examinando possui condições de elaborar estas necessidades, obtendo uma adaptação eficaz e eficiente no convívio social.

3. A diminuição de (Fc) em relação a ((cF) + (c)), indica uma personalidade que possui necessidades de contato social, mas é menos preparada para adequar e elaborar estas necessidades em relação com as demais pessoas.

#### 7.1.4.10. Cor pura (C): Tendência à Reação Emocional Intensa.

Isoladamente, a cor pura é o determinante específico que caracteriza as projeções de reações emocionais livres, intensas e carregadas de sentimentos. Estes sentimentos podem ser os mais variados, de apreciação, estima, admiração, amor e paixão, ou de depreciação, desprezo, ódio, raiva e agressividade [Vaz & Alcheieri, pp. 98, 99]. A *Tendência à Reação Emocional Intensa* é calculado monocraticamente através do determinante da fórmula 26.

(C), monocraticamente.	(26)
------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de (C) que cada indivíduo obteve em um protocolo, com as contagens de (C) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a *Tendência à Reação Emocional Intensa*.

1. O aumento de (C) demonstra uma personalidade com maior probabilidade de reações emocionais intensas. Neste sentido, nas diversas situações de cunho emocional cotidianas, podem ocorrer a explosividade de sentimentos, com um menor controle das reações emocionais, podendo caracterizar um indivíduo mais agressivo.
2. A média de (C) indica uma personalidade que possui um controle emocional mais elaborado. Sendo assim, nas diversas situações de cunho emocional cotidianas, o indivíduo conseguirá elaborar de forma mais adequada suas reações.
3. A diminuição de (C), indica uma personalidade que possui um controle emocional mais elaborado. Sendo assim, nas diversas situações de cunho emocional cotidianas, o indivíduo conseguirá elaborar de forma mais adequada suas reações. A diminuição é um reforçador desta hipótese em relação média.

#### 7.1.4.11. Conteúdos Humanos ((H) + (Hd)): As pessoas na percepção do examinando.

Os Conteúdos Humanos revelam como o examinando percebe as outras pessoas. As pessoas na percepção do examinando são inferidas através das percepções de conteúdos de seres humanos (H) percebidos em sua forma inteira, somados com as percepções de membros externos de seres humanos (Hd) [Vaz & Alchieri, pp. 100, 101]. A dimensão *As Pessoas na Percepção do Examinando* é inferida através da fórmula 27.

((H) + (Hd))	(27)
--------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de ((H) + (Hd)) que cada indivíduo obteve em um protocolo, com as contagens de ((H) + (Hd)) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para *As Pessoas na Percepção do Examinando*.

1. O aumento em relação a ((H) + (Hd)) demonstra um grande interesse e preocupação pelas pessoas como parte de seu cotidiano.
2. A média em relação a ((H) + (Hd)) demonstra capacidade de interesse pelas pessoas, sendo possível ajustamentos para um relacionamento mais maduro. Revela uma personalidade flexível no modo de perceber e avaliar as pessoas.
3. A diminuição em relação a ((H) + (Hd)) demonstra um menor interesse e preocupação com as demais pessoas. É possível que o indivíduo evite pessoas em suas atividades e preferências.

#### 7.1.4.12. Conteúdo Animal ((A) + (AD)): Percepções infantis, também presentes no mundo interno do adulto.

Os conteúdos de animais são representantes do mundo infantil, sendo considerados como a parte da infância que ainda permanece no mundo adulto. As percepções sadias de adultos e crianças podem possuir conteúdos animais. Ao se desenvolver e amadurecer é esperado que o indivíduo diminua as percepções de animais, mas elas geralmente não se extinguem por completo. É interessante ressaltar que pessoas com um nível cultural mais elevado geralmente possuem menos percepções deste tipo [Vaz & Alchieri, pp. 101, 102]. A dimensão *Percepções infantis, também presentes no mundo interno do adulto* é inferida através da fórmula 28.

((A) + (AD))	(28)
--------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de ((A) + (AD)) que cada indivíduo obteve em um protocolo, com as contagens de ((A) + (AD)) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Percepções infantis, também presentes no mundo interno do adulto*.

1. O aumento de ((A) + (AD)) é um indicador de que o interesse pelos fatos e situações cotidianas são baseados em características mais primitivas, com uma menor variabilidade de expressão. Também indica pouca flexibilidade em processos de adaptação.
2. A média de ((A) + (AD)) é um indicador de que o interesse pelos fatos e situações cotidianas evidenciam os aspectos atuais como importantes.
3. A diminuição de ((A) + (AD)) é um indicador de que o interesse pelos fatos e situações cotidianas evidenciam os aspectos atuais como importantes. A diminuição é um reforçador desta hipótese em relação à média.

#### 7.1.4.13. Globais (G): Percepção de conjunto e capacidade de síntese.

Fazendo parte das localizações, as Globais são representações inerentes ao modo operacional perceptivo da realidade. É através das globais que o indivíduo expressa as condições intelectuais de percepção de conjunto, síntese e capacidade de planejamento. Podemos também entender as globais como a inteligência dirigida ao abstrato [Vaz & Alchieri, pp. 102, 103]. A dimensão *Percepção de Conjunto e Capacidade de Síntese* é inferida através da fórmula 29.

(G), monocraticamente.	(29)
------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de (G) que cada indivíduo obteve em um protocolo, com as contagens de (G) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Percepção de Conjunto e Capacidade de Síntese*.

1. O aumento de (G) caracteriza um indivíduo que possui capacidade de percepção e visão de conjunto, mas este aumento pode ser um indicador de defensividade, possivelmente com o uso inadequado da fantasia.
2. A média em relação a (G) é um indicador de uma adequada percepção e visão de conjunto, com capacidade de síntese e integração intelectual dos fatos.
3. A diminuição em relação a (G) é um indicador de falta de visão de conjunto. É possível que o indivíduo possua uma tendência a se perder na preocupação com detalhes, prejudicando a percepção e avaliação do conjunto.

**7.1.4.14. Detalhes Comuns (D): Discernimento e Senso de Objetividade.**

Assim como as Globais, os Detalhes Comuns também fazem parte das localizações, e são representações inerentes ao modo operacional perceptivo da realidade. Podemos entender os Detalhes Comuns como a visão objetiva da realidade e a inteligência voltada ao concreto e pragmático [Vaz & Alchieri, p. 102]. Os detalhes comuns são marcadores da inteligência prática e objetiva [Vaz & Alchieri, p. 104]. Este tipo de localização é o mais comum entre todas as localizações, atingindo as maiores contagens de localização, pois geralmente estas localizações são atreladas às respostas mais óbvias. A dimensão *Discernimento e Senso de Objetividade* é inferido através da fórmula 30.

(D), monocraticamente.	(30)
------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de (D) que cada indivíduo obteve em um protocolo, com as contagens de (D) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Discernimento e Senso de Objetividade*.

1. O aumento de (D) é um indicador de preocupação demasiada com minúcias, uma autoexigência em relação a percepção do mundo em prejuízo a percepção da realidade.
2. A média em relação a (D) fornece indícios de senso prático, percepção do óbvio, capacidade de análise crítica adequada às situações.
3. A diminuição de (D) é um indicador de falta de senso prático, objetividade e de visão adequada da realidade. É também um indicativo da tendência de evitar encarar o óbvio.



#### 7.1.4.15. Detalhes Incomuns (Dd): Capacidade de análise e senso de observação.

Assim como as Globais e os Detalhes Comuns, os Detalhes Incomuns também fazem parte das localizações e são representações inerentes ao modo operacional perceptivo da realidade. Podemos entender os detalhes incomuns como a capacidade de análise, observação e bom senso [Vaz & Alchieri, p. 102]. Os detalhes incomuns são indicativos da capacidade de percepção que o examinando possui para a percepção das partes de um todo. Neste sentido, quanto mais cuidadoso e minucioso for o examinando, produzirá mais respostas com localização de detalhes incomuns [Vaz & Alchieri, pp. 104, 105]. Nesta localização são classificadas respostas em áreas de frequência indicadas inferiores à porcentagem de 0.045, ou seja, abaixo da razão de 1/22 [Vaz & Alchieri, p. 48].

Podemos inferir a dimensão *Capacidade de Análise e Senso de Observação* através da fórmula 31, na qual somamos os determinantes de Detalhes Incomuns (Dd), compreendendo:

- i. Os Detalhes Raros (dr), que são respostas de detalhes incomuns que não se encaixam nos demais critérios, são indicadores bom senso.
- ii. Os Detalhes Diminutos (dd), que são respostas em áreas muito pequenas da mancha, são indicadores de obsessividade.
- iii. Os Detalhes Externos (de), que são respostas que utilizam apenas a borda da mancha, são indicadores de tendência à fuga da realidade.
- iv. Os detalhes inibitórios (DO), que são respostas relacionadas a percepção de partes de pessoas, mas que comumente são percebidas como pessoas inteiras pela maioria das pessoas, são indicadores de inibição e ansiedade situacional.

$(Dd) = ((dr) + (dd) + (de) + (DO))$	$(31)$
--------------------------------------	--------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de (Dd) que cada indivíduo obteve em um protocolo, com as contagens de (Dd) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Capacidade de Análise e Senso de Observação*.

1. O aumento de (Dd) é um indicador de constante preocupação com detalhes. Também é um indicador de possível obsessividade, um grau excessivo pela preocupação com detalhes e minúcias.
2. A média em relação a (Dd) é um indicador de boa capacidade de percepção de detalhe e senso de observação. Também é um indicador de uso da análise com uma crítica adequadamente elaborada.

3. A diminuição de (Dd) é um indicador de possível falta de visão crítica e de observação. Também é indicador do poder de análise diminuído.

#### 7.1.4.16. Espaço branco ( $\Sigma S$ ): Ansiedade Situacional.

O Espaço em Branco também faz parte das localizações. No Z-teste os espaços em branco podem ser combinados com as demais localizações (Globais (G), detalhes comuns (D), detalhes incomuns (Dd)), podendo ser enfatizado na resposta ou não (ex: Detalhe Comum combinado com espaço em branco (DS), Detalhe Comum combinado com espaço em branco enfatizado (SD)). O uso de espaços em branco nas combinações de respostas é interpretado como oposicionismo em relação a si mesmo ou ao mundo externo [Vaz & Alchieri, pp. 105, 106]. A *Ansiedade Situacional* é inferida através da fórmula 32, que pode combinar qualquer localização com o espaço em branco, sendo ele enfatizado ou não.

$(\Sigma S) = ((S) + \text{qualquer combinação de localização})$	(32)
--	------

Desta maneira, utilizando a técnica de Z-scores, comparando as contagens do determinante de ( $\Sigma S$ ) que cada indivíduo obteve em um protocolo, com as contagens de ( $\Sigma S$ ) referentes aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Ansiedade Situacional*.

1. O aumento de ( $\Sigma S$ ) é um indicador de um nível de ansiedade elevado, propensão a perturbar o curso do pensamento na elaboração das respostas, podendo levar a fazer críticas excessivas.
2. A média em relação a ( $\Sigma S$ ) é um indicador que demonstra condições para defender seus pontos de vista, capacidade de realizar crítica adequada.
3. A diminuição de ( $\Sigma S$ ) é um indicador de pouca expressão, entretanto a ausência total de ( $\Sigma S$ ) pode estar indicando rigidez, defesa de tipo paranóide ou ainda negação.

#### 7.1.4.17. Movimento Inanimado ((Fm), (mF), (m)): Conflito Intrapsíquico.

O movimento inanimado possui uma relação com conflitos internos, difíceis de serem controlados. Estes conflitos são ocasionados entre afetos do mundo interno e valores socioculturais do mundo externo. Neste sentido, a necessidade de optar por um ou outro gera tensões que são

projetadas nestes determinantes [Vaz & Alchieri, p. 110]. A dimensão *Conflito Intrapsíquico* é inferida através da fórmula 33, onde são comparados:

- i. Os conteúdos percebidos com movimento inanimado, mas com a forma bem definida (Fm), indicando uma adaptação adequada ao mundo externo.
- ii. Os conteúdos percebidos com movimento inanimado, mas percebidos com a forma duvidosa (mF), indicando uma adaptação precária ao mundo externo.
- iii. Os conteúdos de (ii) são somados com os conteúdos percebidos com movimento inanimado, sem nenhuma forma (m), indicando incapacidade de adaptação ao mundo externo.

$(Fm) \geq ((mF) + (m))$	(33)
--------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (Fm) e ((mF) + (m)) que cada indivíduo obteve em um protocolo, com as proporções de (Fm) e ((mF) + (m)) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Conflito Intrapsíquico*.

1. O aumento de (Fm) em relação a ((mF) + (m)) é um indicador de que quando ocorrem conflitos entre o mundo interno e os valores socioculturais do mundo externo, o indivíduo consegue adaptar-se adequadamente. O aumento é um reforçador desta hipótese em relação à média.
2. A média de (Fm) em relação a ((mF) + (m)) é um indicador de que quando ocorrem conflitos entre o mundo interno e os valores socioculturais do mundo externo, o indivíduo consegue adaptar-se adequadamente.
3. A diminuição de (Fm) em relação a ((mF) + (m)) é um indicador de tensão e conflitos intrapsíquicos, com expressão de ansiedade.

#### **7.1.4.18. Sombreado Radiológico ((Fk), (kF), (k)): Ansiedade e Adaptação Racional.**

O Sombreado Radiológico inclui percepções de conteúdos radiográficos, mapas geográficos ou negativos de fotos ou filmes. Estes determinantes têm relação com sentimentos desagradáveis da vida cotidiana das pessoas, possuindo uma sensibilidade mais específica para revelar como será o controle da ansiedade diante de acontecimentos novos, desconhecidos e que precisam ser superados

[Vaz & Alchieri, pp. 65, 110, 111]. Podemos inferir a dimensão *Ansiedade e Adaptação Racional* através da fórmula 34, onde são comparados:

- i. Os conteúdos percebidos como sombreado radiológico, mas com a forma bem definida (Fk), indicando uma adaptação racional adequada em relação a situações de ansiedade.
- ii. Os conteúdos percebidos como sombreado radiológico, mas com a forma vaga (kF), indicando uma adaptação racional mais precária em relação a situações de ansiedade.
- iii. Os conteúdos de (ii) são somados com os conteúdos percebidos como sombreado radiológico, mas sem forma (k), indicando um descontrole racional em relação a situações de ansiedade.

$(Fk) \geq ((kF) + (k))$	(34)
--------------------------	------

Desta maneira, utilizando a técnica de Z-scores, comparando a proporção dos determinantes de (Fk) e ((kF) + (k)) que cada indivíduo obteve em um protocolo, com as proporções de (Fk) e ((kF) + (k)) referente aos protocolos dos 363 indivíduos participantes desta pesquisa, obtivemos três desfechos possíveis para a dimensão *Ansiedade e Adaptação Racional*.

1. O aumento de (Fk) em relação a ((kF) + (k)) é um indicador de que a manifestação de ansiedade situacional não traz maiores interferências nas ações cotidianas, pois o examinando faz o uso da intelectualização para o entendimento das coisas e dos fatos. Este processo ocorre devido a uma adaptação racional, sem envolver sentimentos e afetos. O Aumento é um reforçador desta hipótese em relação à média.
2. A média de (Fk) em relação a ((kF) + (k)) é um indicador de que a manifestação de ansiedade situacional não traz maiores interferências nas ações cotidianas, pois o examinando faz o uso da intelectualização para o entendimento das coisas e dos fatos. Este processo ocorre devido a uma adaptação racional, sem envolver sentimentos e afetos.
3. A diminuição de (Fk) em relação a ((kF) + (k)) é um indicador de que a ansiedade situacional na vida cotidiana é mais impactante ao indivíduo, pois ele possui uma menor capacidade de adaptação racional as situações que geram ansiedade.

#### 7.1.4.19. Ressonância Interna ( $(\Sigma M) : (\Sigma C)$ ).

A *ressonância interna* é um construto psicológico inferido através da relação entre percepções de movimento e cores. A *ressonância interna* utiliza fatores que eram valorizados por Hermann Rorschach [Rorschach, 1967] como fundamentais para a construção do seu método. No Z-Teste estas

reduções fatoriais são chamadas de ressonância interna, que podem ser entendidas como a vivência do indivíduo [Vaz & Alchieri, 2016, p. 106 - 108]:

*“O movimento humano ( $\Sigma M$ ) é um determinante das funções integradoras da dimensão do mundo interno da personalidade. Já as cores em seu somatório ( $\Sigma C$ ) são os estímulos do impacto mobilizador do mundo interno da pessoa, provocando-lhe reações afetivo-emocionais, com as mais variadas repercussões na estrutura e funcionamento da personalidade”. [Vaz & Alchieri, 2016, p. 107]*

A proporção entre as contagens dos movimentos humanos e cores ( $(\Sigma M) : (\Sigma C)$ ) é o tipo de *Ressonância Interna* da personalidade, o que Rorschach denominou como *Erlebnistyp* [Rorschach, 1967, p. 25]. Os indivíduos, que em suas respostas privilegiam cores puras (C), indicam possuir um descontrole afetivo-emocional. Cores puras também são um indicador de reações intensas de amor, paixão, raiva, ódio. Se a contagem de cor e forma imprecisa for alta (CF) é um indicador adicional de descontrole, revelando que o sistema emocional é ativado com a mínima sensibilidade. Rorschach diferenciava os tipos introversivos e extratensivos dos tipos introvertidos e extrovertidos da teoria analítica [Jung, 2002]. Para Rorschach estes tipos eram apenas uma propensão em um determinado período da vida, sem implicar na estabilidade do traço psicológico.

*“Na prática observa-se a predominância do tipo extratensivo na infância, introversivo na adolescência e uma leve tendência de aumento da frequência ambigüa nas fases mais avançadas da idade”. [Vaz & Alchieri, p. 107]*

A Tabela 13 mostra os 5 tipos de ressonância interna no Z-teste.

Movimento Humano	Proporção	Cor Cromática	Tipo Ressonância	Representação
$\sum M$	>	$\sum C$	Introversivo	(i) Afetividade intensa. (ii) Criatividade. Introspeção elaborativa. (iii) Preocupação com a realidade.
$\sum M$	<	$\sum C$	Extratensivo	(i) Facilidade para se expor. (ii) Propensão a perder o controle. (iii) Demora a se dar conta do que fantasiou.
$\sum M$	0/0	$\sum C$	Coartado	(i) Estreitamento afetivo. (ii) Indecisão ante situação de pressão ou conflito.
$\sum M$	1/1	$\sum C$	Coartativo	(i) Defensividade. (ii) Propensão à repressão.
$\sum M$	2/2, 3/3, 4/4		Ambigüal	(i) Tipo ideal, equilibrado.

**Tabela 13.** Tabela de cálculo do tipo de ressonância interna. Adaptado de [Vaz & Alchieri, 2016. p. 108].

O Z-teste não necessita validar a proporção  $((FM)+(m)):((Fc) + (c) + (C'))$ , como Rorschach (1967) sugeriu, devido ao fato deste instrumento ser uma versão de aplicação mais rápida e simplificada que o teste de Rorschach. É interessante ressaltar que, no Z-teste, os tipos introversivos e extratensivos são diferentes dos tipos introvertidos e extrovertidos da teoria analítica [Jung, 2002]. Estes tipos são definidos como uma propensão da personalidade em um determinado período da vida, sem implicar na estabilidade permanente do traço psicológico. Sendo a proporção  $((\Sigma M): (\Sigma C))$  utilizada para inferir o tipo de ressonância interna da personalidade, o movimento humano  $(\Sigma M)$  é calculado através da fórmula 19, já descrita anteriormente na seção 7.1.4.4. O somatório de cores  $(\Sigma C)$  é calculado através da fórmula 35.

$(\Sigma C) = ((FC) + (2*(CF)) + (3*(C)) / 2)$	(35)
--	------

Onde  $(\Sigma C)$  é o somatório de cores,  $(FC)$  é a contagem de percepções de cores com formas bem definidas.  $(CF)$  é a contagem de percepções de cores com forma duvidosa ou com a retirada explícita da precisão da forma.  $(C)$  é a contagem de percepções de cores puras, sem tentativa de forma.

Desta maneira, comparando diretamente a proporção dos determinantes de  $(\Sigma C)$  e  $(\Sigma M)$  que cada indivíduo obteve em um protocolo, obtivemos cinco desfechos possíveis para a dimensão *Ressonância Interna*.

1. O tipo de ressonância Introversivo  $((\Sigma M) > (\Sigma C))$  ocorre quando acontece o aumento de movimento humano e a diminuição de cores cromáticas. É indicador de pessoas mobilizadas pela afetividade, criativas, com introspecção elaborativa. Estes indivíduos possuem uma maior preocupação com a realidade.
2. O tipo de ressonância Extratensivo  $((\Sigma M) < (\Sigma C))$  é o polo oposto do tipo de ressonância Introversivo. É um indicador de pessoas mais ativas que reflexivas, com facilidade de se expor.
3. O tipo de ressonância Coartado  $((\Sigma M = 0) \text{ e } (\Sigma C = 0))$  é um indicador de estreitamento afetivo, geralmente marcado por indecisões perante os momentos tensos ou conflitantes da vida.
4. O tipo de ressonância Coartativo  $((\Sigma M = 1) \text{ e } (\Sigma C = 1))$  é um indicador de propensão a repressão e utilização de mecanismos de defesa.
5. O tipo de ressonância Ambigüal  $((\Sigma M = 2) \text{ e } (\Sigma C = 2))$  ou  $((\Sigma M = 3) \text{ e } (\Sigma C = 3))$  ou  $((\Sigma M = 4) \text{ e } (\Sigma C = 4))$  ... etc) é o mais equilibrado, é um indicador de um indivíduo mais apto a lidar com as condições emocionais.

### 7.1.5 Coleta Textual para o *Corpus* do Z-teste.

A metodologia que utilizamos para a coleta dos ensaios textuais para o *corpus* do Z-teste foi adaptada de um trabalho que tinha como objetivo verificar a confiabilidade do léxico LIWC (seção 4.2.1), originando a base de dados *essays* [Pennebaker & King, 1999]. Esta metodologia utilizava ensaios textuais livres, chamada pelos autores de “*Stream of Consciousness*”, entretanto, optamos por fazer algumas melhorias nesta metodologia que serão descritas adiante. Posteriormente, a base de dados *essays* se tornou um *corpus* de referência para os trabalhos de TB-APR. Este *corpus* inicialmente foi utilizado no trabalho de Mairesse em 2007, e em seguida foi explorado por diversos trabalhos que competiram no *workshop of personality computing – shared task* [Celli et. al., 2013]. Mais recentemente este *corpus* foi utilizado no trabalho de Majumder e seus colegas (2017).

Para cada turma de até 35 pessoas, para as quais aplicamos o protocolo do Z-teste na forma coletiva, logo após a aplicação do teste projetivo, foi feita a coleta textual. Antes de coletar os textos, foi explicado aos participantes, de forma clara e objetiva, que o conteúdo textual seria utilizado de forma sigilosa, possuindo a finalidade única de construir um modelo computacional para reconhecer a personalidade de forma automática. Neste sentido, foi ressaltado que quanto mais detalhados e sinceros fossem os textos, o modelo computacional que construiríamos seria mais confiável. A coleta textual foi realizada em três etapas. Em cada etapa, um ensaio textual diferente foi coletado de cada participante, na forma manuscrita. Para isso, cada participante recebeu folhas de papel ao maço. Cada etapa de coleta textual durou exatamente o tempo de 15 minutos, totalizando 45 minutos. No final de cada etapa, foi sugerido que os participantes traçassem uma linha no papel delimitando o fim da etapa. Estas três etapas, e as razões, elucidando o motivo para o qual cada uma delas foi selecionada, serão descritas de forma detalhada nos parágrafos a seguir.

Na primeira etapa foi coletado um ensaio textual totalmente livre. Esta etapa utilizou a metodologia “*Stream of Consciousness*” de Pennebaker e King (1999) sem modificações, com exceção da adaptação do tempo permitido para escrever, que foi ajustado em 15 minutos. Antes de começar a contar o tempo, foi avisado aos participantes que poderiam escrever qualquer coisa que estivessem pensando naquele momento. Como neste ensaio textual alguns participantes ainda estavam um pouco inibidos, foi exemplificado que poderiam escrever qualquer coisa, como por exemplo, sobre como estavam se sentindo naquele momento, ou ainda relatar os últimos acontecimentos de suas vidas. Foi explicado, ainda, que os ensaios textuais poderiam remeter a sentimentos de diversas valências, podendo ser neutros, positivos ou negativos.



Na segunda etapa foi coletado um ensaio textual sobre os fatos mais marcantes da vida do indivíduo, referentes às três principais fases da vida: infância, adolescência e vida adulta. Escolhemos este tópico textual para estabelecer correlações entre a linguagem e dinâmicas psicológicas relacionadas à personalidade nas diversas fases da vida. Para isso, foi dada a sugestão (não obrigatória) de dividir o ensaio textual em três parágrafos, um para cada uma das fases da vida. Foi solicitado, nesta etapa, que os participantes tentassem ignorar a censura, não estabelecendo limites relacionados ao tema, além disso foi aconselhado que não medissem quais palavras deveriam ser utilizadas, podendo, inclusive, ser empregadas palavras de baixo calão (grosseiras ou rudes).

Consideramos este segundo ensaio relevante para acessar a personalidade, pois dividir a vida em fases ou etapas é algo relativamente comum entre as diversas teorias psicológicas [Feist & Feist; Roberts, 2015]. Devido a grande heterogeneidade de teorias psicológicas (capítulo 2), cada teoria tende a valorizar e detalhar dinâmicas relacionadas à formação da personalidade em etapas diferentes da vida. No senso comum, a personalidade é tudo aquilo que é mais marcante em um indivíduo, mas o desenvolvimento da personalidade é sempre subjetivo em relação a teoria. Para os psicanalistas, a personalidade é formada nos primeiros anos de vida, dando bastante ênfase para as três fases iniciais que foram denominadas de (seção 2.1.1): fase oral (0 a 1 ano de idade), fase anal (1 a 2 anos de idade) e fase fálica (4 e 6 anos de idade). Além dessas três fases, esta teoria descreve peculiaridades das fases posteriores, referindo-se ao período de latência (período da fase fálica até a puberdade) e fase genital (período da puberdade até vida adulta). A psicóloga Melanie Klein, em sua teoria das relações objetivas (seção 2.1.4), afirmava que a personalidade começava a se formar por volta dos 4 aos 6 meses de idade, por meio do contato da criança com a mãe, em relações de contexto (segurança) e foco (que permite o aprendizado). Ao invés de utilizar o termo fases, Melanie Klein preferia utilizar o termo posições, definindo os conceitos de posição esquizo-paranóide e posição depressiva. Para o psicólogo Erick Erickson (seção 2.1.7), o desenvolvimento da personalidade tem início no nascimento e termina na velhice, passando por oito estágios de desenvolvimento psicossocial. Estes estágios eram sempre caracterizados por uma dicotomia. Para Erickson, durante cada estágio, os indivíduos experimentam crises psicossociais e a resolução dessas crises produzem forças que possibilitam ao indivíduo avançar para o estágio seguinte.

Finalmente, a terceira etapa consistiu em criar uma história. Para que este ensaio textual revelasse a subjetividade de cada indivíduo, foi ressaltado que seria válido qualquer tipo de história, podendo ser real, fantasmagórica ou biográfica. Novamente, nesta etapa, foi frisado para não estabelecer limites em relação ao conteúdo da narrativa e nem em relação às palavras empregadas, deixando a censura de lado para se concentrar ao máximo nos detalhes e desenvolvimento da história.

Contar histórias é um processo bastante utilizado por psicólogos para aferir a personalidade. Consideramos que os textos de histórias poderiam se correlacionar com personalidade, pois são bastante pessoais. O instrumento de aferição de personalidade projetivo TAT [Murray, 2005], amplamente utilizado para avaliar a personalidade, tem sua metodologia inteiramente baseada em contar histórias a partir de estímulos visuais (que são cartões). Obviamente, os três cartões do Z-teste são diferentes dos cartões do TAT, entretanto, como aplicamos o Z-teste antes dos ensaios textuais, e também coletamos o ensaio textual sobre as três fases da vida antes de coletar o ensaio textual sobre as histórias, consideramos que as representações mnemônicas do Z-teste e as lembranças de fatos marcantes que ocorreram na vida, poderiam, de certa forma, contribuir na forma de estímulos para a criação das histórias.

## **7.2 O corpus TAT.**

O TAT [Scaduto & Barbieri, 2013] é uma técnica projetiva, descrita por Morgan Murray (1943), como uma técnica projetiva para acessar a personalidade, auxiliando no processo da psicoterapia. Esta técnica foi desenvolvida originalmente por um time de psicólogos, coordenados por Henry A. Murray, tornando-se uma derivação da teoria psicológica motivacional da Personalologia [Murray, 1943 - 2005].

No TAT assume-se que, partindo de um conjunto de cartões, cuja função é fornecer estímulos visuais de diversas situações cotidianas, sejam elaboradas histórias, que através do mecanismo de projeção, forneçam pistas do funcionamento da personalidade. Em outras palavras, o examinando irá interpretar as situações ilustradas pelos cartões de acordo com suas tendências individuais de perceber, julgar e reagir a situações reais de uma forma geral. Sendo assim, durante a aplicação do protocolo do TAT, o examinando interpreta subjetivamente cada um dos cartões selecionados, com base em suas experiências anteriores. Neste processo de interpretação, as diferenças individuais são capturadas através do processo aperceptivo [Silva, 1984]. Podemos entender este processo aperceptivo de acordo com a seguinte definição:

O processo pelo qual a nova experiência é assimilada e transformada pelo resíduo da experiência passada de um indivíduo para formar um novo todo. [Runes, 1972]

A última revisão do TAT foi descrita por Murray em 1943, no trabalho “*TAT: Teste de apercepção temática*” [Murray, 1943 - 2005]. Nesta versão foram padronizados 31 cartões que mostram situações cotidianas, servindo de estímulos para a criação de histórias. Destes cartões, 20

são selecionados para cada indivíduo, baseados em critérios de idade e sexo fornecidos pelo manual de aplicação do instrumento projetivo.

### **7.2.1 Coleta dos Scores de Personalidade e dos Ensaio Textuais do TAT.**

A coleta de textos e dos scores de personalidade para os experimentos do TAT ocorreu na cidade de Ribeirão Preto, no estado de São Paulo. Este *corpus* faz parte da tese de doutorado “*O Teste de Apercepção Temática (TAT) em adultos: Dados normativos para o sistema morlaviano*”, na qual a principal contribuição foi uma nova normatização para o sistema de quotação morlaviano do TAT [Scaduto, 2016]. Esta normatização é conhecida como sistema *morval-scaduto* (MS).

Os participantes desta pesquisa foram selecionados utilizando a metodologia de Pasion (1988). Neste processo, alguns bairros da cidade de Ribeirão Preto foram incluídos em uma amostra, selecionando participantes com níveis de escolaridade e nível sócioeconômicos altos e baixos. Os quarteirões dos bairros escolhidos foram numerados e sorteados, e depois foi sorteada uma face deste quarteirão e uma casa nesta face. Ao todo foram visitadas 2888 casas, tendo sido possível deixar o convite para a pesquisa em 2298 delas. Do total, 261 pessoas se interessaram pela pesquisa, e destas 113 foram incluídas na amostra. Finalmente, das 113 pessoas selecionamos 100 para este corpus, utilizando o critério de legibilidade dos textos manuscritos. O processo de coleta de dados ocorreu em três entrevistas [Scaduto, 2016]:

1. Primeira entrevista: Assinatura do TCLE e verificação do roteiro de pesquisa para o *rapport* inicial; em seguida aplicação dos 10 primeiros cartões do TAT.
2. Segunda entrevista: Aplicação dos 10 cartões restantes do TAT e do TIG-VN. Agendando da entrevista devolutiva.
3. Terceira entrevista: Apresentação e discussão dos resultados obtidos durante a avaliação.

O sistema MS utiliza a seguinte instrução que é verbalizada ao examinando pelo psicólogo no momento da aplicação do protocolo TAT [Scaduto, 2016]:

*“Vou lhe mostrar algumas figuras e pedir que você invente uma história para cada uma delas. Peço que você me conte o que está acontecendo na figura, o que aconteceu antes e como a história termina, ou seja, uma história com começo, meio e fim. Também peço que você me conte o que as pessoas na história estão pensando e sentindo; enquanto isso, vou anotar tudo o que você disser; também irei anotar o tempo que você leva para contar*

*cada história. São 10 figuras (em cada um dos dois dias de aplicação); peço que você tente levar 5 minutos para cada uma delas, mas fique a vontade para levar o tempo que quiser. Você tem alguma dúvida (Em caso negativo). Então essa é a primeira figura”.*

Após a leitura da instrução, os 20 cartões do TAT foram apresentados para os 100 indivíduos selecionados na amostra, em duas entrevistas distintas. Em cada entrevista 10 cartões foram aplicados. Os cartões foram selecionados de acordo com o sexo e a idade dos participantes, a partir do manual da última versão da técnica projetiva [Murray, 1943 -2005]. Para cada cartão, foi solicitado que o participante contasse uma história. Todas as histórias foram anotadas manualmente por um psicólogo experiente e especialista na aplicação do TAT. As instruções de aplicação da técnica projetiva consistiram em perguntar para o indivíduo:

1. “O que aconteceu antes na história?”
2. “O que acontece depois?”
3. “Como a história termina?”
4. “Quais os pensamentos dos personagens da história?”
5. “O que os personagens da história estão sentindo?”
6. “Gostaria que você contasse um pouco mais sobre isso (o que aconteceu antes, depois, o final da história, o que os personagens estão pensando ou sentindo).”
7. “Você gostaria de contar algo mais sobre essa história?”

Durante a aplicação da técnica, se necessário, foi perguntado por elementos não descritos. Também foram solicitados mais detalhes, no caso da formulação de histórias muito simples ou curtas. Para manter a homogeneidade da técnica, instruções de suporte foram padronizadas para:

1. O fim de cada história.
2. Intervenções de suporte e encorajamento durante a aplicação dos cartões.
3. Instruções em caso de dúvidas.
4. Instruções específicas para o cartão 16, que é um cartão em branco (“Imagine que aqui tem uma imagem, descreva ela para mim em detalhes. Agora conte uma história sobre esta imagem”).

Alguns autores recomendam que depois do examinando criar cada história, seja sugerida a criação de um título [Jacquemin et. al, 2003], desta forma, cada participante da pesquisa foi orientado a elaborar um título, para cada uma das 20 histórias do protocolo. Depois de aplicar todos os cartões, foi solicitado ao participante para escolher a história que ele havia gostado mais e a que apreciou menos.

Após o psicólogo transcrever manualmente todas as histórias, elas foram quotadas no sistema Morval-Scaduto (MS). Este sistema de quotação foi proposto originalmente por Morval (1982), derivando do Sistema de análise, propostos por Morgan Murray (1943), com contribuições das teorias psicodinâmicas e cognitivas que emergiram nos anos de 1970 [Jenkins, 2008]. O Sistema morlaviano [Morval, 1982] é de orientação qualitativa, consistindo em categorias que descrevem o comportamento dos indivíduos durante o processo de contar histórias. Morval afirmava que este sistema de quotação permitia acessar as funções egóicas. Estas funções regulam a adaptação geral e os processos internos e externos que remetem a aspectos afetivos, emocionais e outros aspectos relacionados ao pensamento.

O sistema MS contempla 17 escalas de personalidade para rotular as histórias. Apesar destas escalas serem customizadas para cada uma das 17 dimensões de personalidade, elas são as mesmas para cada um dos 20 cartões. Em nossa metodologia, para obter o *corpus* TB-APR do TAT, foi necessário digitar os protocolos manuscritos pelo psicólogo. Estes manuscritos eram referentes aos 100 participantes que selecionamos. Sendo assim, digitamos as 20 histórias de cada participante, totalizando 2.000 histórias digitadas.

Para obter uma quantidade adequada de textos para os modelos, concatenamos as 20 histórias de cada indivíduo em um único arquivo de texto eletrônico. As 17 escalas de personalidade referentes a cada indivíduo foram obtidas pela moda da escala em relação as 20 histórias. Depois de se obter a moda das escalas, foi feita uma triagem em cada uma das escalas finais, excluindo aquelas que tinham desbalanceamentos extremos. Excluímos estas dimensões devido ao fato destes desbalanceamentos serem prejudiciais uma amostra pequena ( $n = 100$ ), introduzindo problemas no processo de aprendizagem de máquina supervisionada. Ficaram estabelecidos como tópicos de exclusão dimensional os seguintes critérios:

1. Quando a classe majoritária possuía 90% ou mais das instâncias.
2. Quando existiam mais de duas classes minoritárias representando menos de 10% das instâncias cada uma.

Os modelos em que apenas uma classe minoritária representava menos de 10% das instâncias foram mantidos, desde que o critério 1 enumerado acima, fosse atendido. Em uma amostra maior, certamente o número de exemplos destas classes minoritárias seriam suficientes para a construção do modelo, possibilitando utilizar técnicas de *sampling* para tratar o desbalanceamento, mas não é o caso deste *corpus*. A tabela 14 mostra o desbalanceamento das escalas de personalidade do *corpus* TAT. Para os modelos finais, foram selecionadas apenas as dimensões em negrito, que são as que não se encontraram nos critérios de exclusão.

<b>Nome Categoria</b>	<b>Escala no Sistema MSS</b>	<b>Distribuição da amostra (n=100)</b>
<b>Atendimento às instruções</b>	<b>0, 1, 2, 3, 4, 5</b>	<b>(3, 3), (4, 38), (5, 59)</b>
<b>Autonomia para a tarefa</b>	<b>0, 1, 2, 3</b>	<b>(1, 26), (2, 51), (3, 23)</b>
<b>Complexidade do Herói</b>	<b>0, 1, 2, 3</b>	<b>(1, 3), (2, 52), (3, 45)</b>
<b>Complexidade Temporal</b>	<b>0, 1, 2, 3, 4, 5</b>	<b>(2, 6), (3, 33), (4, 61)</b>
Eficácia Conduta Final	0, 1, 2, 3, 4, 5	(3,1), (5, 99)
Eficácia Conduta Inicial	0, 1, 2, 3, 4, 5	(1, 2), (3, 2), (4, 51), (5, 45)
Idealização do Herói	0, 1, 2, 3, 4	(1,3), (2, 7), (3, 81), (4, 9)
Integração Narrativa	0, 1, 2, 3, 4, 5	(2, 1), (3, 14), (4, 76), (5, 9)
Intensidade Pressão do Meio	-5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5	(-5,1), (-4, 16), (-3, 32), (-2,5), (0,9), (2, 2), (3, 35)
Intensidade Necessidade Secundária	0, 1, 2, 3, 4, 5	(0,4), (2, 1), (3, 95)
Intensidade Necessidade Primária	0, 1, 2, 3, 4, 5	(3, 90), (4, 10)
Nível de Participação	0, 1, 2, 3	(1, 1), (2, 99)
Nível Evolutivo da Conduta	0, 1, 2, 3, 4	(1,2), (4,98)
<b>Qualidade da História</b>	<b>0, 1, 2, 3, 4</b>	<b>(2, 46), (3, 48), (4, 6)</b>
Qualidade da Linguagem	0, 1, 2, 3	(1, 2), (2, 98)
Autonomia do Herói	0, 1, 2, 3, 4, 5, 6, 7, 8	(0, 2), (7, 2), (8, 96)
<b>Pressão do Ambiente</b>	<b>-1, 0, 1</b>	<b>(-1, 80), (0,1), (1,19)</b>

**Tabela 14.** Desbalanceamento de classes e seleção das dimensões personalidade para o corpus TAT.

A próxima seção irá detalhar as dimensões selecionadas para a construção dos modelos utilizando o corpus TAT.

### 7.2.2 Detalhamento das Dimensões selecionadas para o modelo do TAT.

Dedicamos esta seção para detalhar as categorias e sub-categorias que selecionamos para o modelo do TAT. Após o critério de exclusão ser aplicado na amostra, foi possível trabalhar com seis sub-categorias do TAT, referentes a três categorias. Estas sub-categorias e suas relações com a personalidade, são explicadas em detalhes nos próximos parágrafos.

Podemos, entender o funcionamento dos sistemas de quotação do TAT como uma tentativa de verificar distorções no processo aperceptivo em relação ao que seria um processo ideal. A tabela 15 explicita as sub-categorias de *Análise de Comportamento* do sistema MS. Estas sub-categorias permitem aferir impressões do examinando, especificamente em relação a realização de tarefas e seguir instruções de uma maneira geral.

CATEGORIAS DE ANÁLISE DO COMPORTAMENTO		
Nome Categoria	Definição	Escala de classes
<b>Autonomia para a Tarefa</b>	Verifica a autonomia do examinando em relação as intervenções realizadas pelo aplicador.	(0) O examinando recusou o cartão / não contou história. (1) Muitas intervenções foram necessárias (>3). (2) Poucas intervenções foram necessárias (<=3). (3) Nenhuma intervenção foi necessária.
<b>Atendimento às Instruções</b>	Verifica se os elementos solicitados (passado, presente, desfecho, pensamento e sentimentos do herói) estão presentes na história.	(0) Faltam todos os elementos (ex: mera descrição do cartão, recusa do cartão). (1) Foram suprimidos quatro elementos solicitados. (2) Foram suprimidos três elementos solicitados. (3) Foram suprimidos dois elementos solicitados. (4) Foi suprimido um elemento solicitado. (5) A história possui todos elementos solicitados.

**Tabela 15.** Categorias do sistema MS relacionadas ao Comportamento. Adaptado de [Scaduto,2016].

Analisando a tabela 15, é possível verificar os detalhes das sub-categorias de *Análise do Comportamento*. Em relação a dimensão *Autonomia para a Tarefa*, o sistema MS considera que quanto menor for o número de intervenções do aplicador, melhor é a capacidade de autonomia do examinando para realizar tarefas de forma geral. Na dimensão *Atendimento às Instruções*, é verificado se todos os elementos estão presentes na história, desta maneira, quanto mais elementos estiverem

presentes, mais favorável é a capacidade de concentração do examinando, em relação a seguir instruções de uma forma geral.

As *Categorias de Análise de Conteúdo* no sistema MS são utilizadas para descrever o conteúdo das histórias, tais como os personagens das histórias (heróis), as motivações, a performance dos heróis, os estados internos, os efeitos secundários, as circunstâncias e as possíveis interferências ambientais sobre os personagens. Nestas sub-categorias, considera-se herói o protagonista da história, podendo ser incluídos nessa categoria mais de um personagem. Critérios para identificar os heróis são estabelecidos pela literatura [Morval, 1982]. As identificações dos heróis ocorrem ao analisar o contexto das condições que cercam os principais personagens na trama, que podem ser boas ou ruins. Também deve-se avaliar as condições às quais os personagens são submetidos no final da trama. O processo de análise do herói permite obter uma auto-imagem do examinando, nas suas formas “presente (atual) e ideal (futura)” [Jacquemim et. al, 2003]. A tabela 16 detalha as *Categorias de Análise de Conteúdo* que selecionamos.

<b>CATEGORIAS DE ANÁLISE DE CONTEÚDO</b>		
<b>Nome Categoria</b>	<b>Definição</b>	<b>Escala de classes</b>
<b>Complexidade do Herói</b>	Grau de presença com que características do herói aparecem.	(0) Sem descrição, nenhuma característica. (1) Descrição superficial, apenas uma característica, do pensamento ou sentimento do herói. (2) Descrição pouco articulada, poucas características, com apenas um pensamento ou sentimento do herói. (3) Descrição dinâmica, diversas características, dos pensamentos e sentimentos do herói.
<b>Pressão do Ambiente</b>	Verifica se o ambiente facilita ou dificulta o cumprimento da necessidade do herói.	(-1) Pressão negativa do ambiente sobre a necessidade do herói. (0) Nenhuma pressão do ambiente sobre a necessidade do herói. (1) Pressão positiva do ambiente sobre a necessidade do herói.

**Tabela 16.** Categorias do sistema MS relacionadas a Análise de Conteúdo. Adaptado de [Scaduto,2016].



Analisando a tabela 16, é possível verificar os detalhes das sub-categorias de *Análise de Conteúdo*. A dimensão *Complexidade do Herói* fornece pistas de como a percepção do examinando funciona em relação a si mesmo e às outras pessoas. Quanto maior a *Complexidade do Herói*, mais desenvolvida é a capacidade de percepção que está relacionada a cognição e afetos.

A dimensão *Pressão do Ambiente* está relacionada com a expectativa do examinando. O ambiente nas histórias pode ser entendido como um processo de projeção, referente às pessoas e às condições externas do ambiente em que o examinando está inserido. Em outras palavras, o ambiente da história possibilita uma interpretação, em relação ao otimismo ou pessimismo, referente a situações gerais, envolvendo os outros e as diversas circunstâncias.

Finalmente, as *Categororias de Análise Formal* do sistema MS, contemplam sub-categorias que descrevem formalmente a história, por exemplo, analisando a forma como os examinandos estruturam os elementos narrativos das histórias. Estas categorias estão elencadas na tabela 17.

<b>CATEGORIAS DE ANÁLISE FORMAL</b>		
<b>Nome Categoria</b>	<b>Definição</b>	<b>Escala de classes</b>
<b>Complexidade Temporal</b>	Verifica como os elementos da história estão arranjados, em termos da ordem de apresentação e a lógica de suas interrelações.	<p>(0) Sem ordem temporal ou recusa do cartão.</p> <p>(1) Ilógica, ausência de interrelação entre os eventos ou relação confusa.</p> <p>(2) Incompleta, ausência de um dos elementos temporais (início, meio e fim da história).</p> <p>(3) Literal às instruções, os acontecimentos são narrados de acordo com as instruções do TAT. Esta classe é marcada quando muitas intervenções são realizadas pelo examinador.</p> <p>(4) Lógica, inclui a escala (3); mas apresentando oscilações de ordem, ou seja, ocorrendo explicações casuais no meio da história, remetendo ao começo da mesma, sem alterar a ordem lógica dos eventos.</p> <p>(5) Lógica e Dinâmica, inclui a escala (4); adiciona novos acontecimentos, sentimentos e pensamentos dos personagens em relação aos mesmos e suas mudanças ao longo dos eventos, tornando a história mais complexa e interligada.</p>

<p><b>Qualidade Geral da História</b></p>	<p>Qualidade literária da narrativa das histórias, integrando três categorias: (i) qualidade da linguagem, (ii) complexidade temporal e (iii) integração narrativa.</p>	<p>(1) História Confusa ou Desordenada; possui presença de falhas lógicas ou pouca integração entre os elementos. Narrativas de difícil compreensão ou de baixa organização.</p> <p>(2) História Superficial; apesar da presença de todos ou quase todos elementos e de uma certa organização, o nível de detalhamento é baixo.</p> <p>(3) História organizada; narrativa com coerência e interligação entre os elementos, incluindo detalhes sobre os personagens e suas reações.</p> <p>(4) História rica; grande quantidade de detalhes com suas interrelações, lembrando uma narrativa literária tal como um conto ou fábula.</p>
---	---	---

**Tabela 17.** Categorias do sistema MS relacionadas a Análise de Conteúdo. Adaptado de [Scaduto,2016].

Analisando a tabela 17, é possível verificar os detalhes das sub-categorias de *Análise Formal*. A *Complexidade Temporal* é uma sub-categoria relacionanda à ordem de tempo dos acontecimentos das histórias, permitindo acesso à dimensão lógica e ao controle do processo criativo e perceptivo. Neste sentido, os indivíduos irão contar histórias organizadas ou desorganizadas, de acordo com a organização ou desorganização de seus estados internos, permitindo verificar o nível de funcionamento cognitivo, ou seja, a forma com que a realidade é percebida. Alguns autores afirmam que a projeção da *Complexidade Temporal* nas histórias está relacionada com a magnitude de organização temporal e cognitiva do examinando [Morval, 1982] [Jaquemin et al. 2003]. A escala da *Complexidade Temporal* no sistema MSS foi elaborada de acordo com a teoria cognitivo-comportamental, estabelecendo componentes de integração cognitiva através da diferenciação de experiências (pensamentos, sentimentos, contextos, relacionamentos, intenções) [Teglasi, 2010]. A sub-categoria *Qualidade Geral da História* se refere a uma análise formal mais abrangente, verificando o grau de *Qualidade da Linguagem, Complexidade Temporal e Integração Narrativa* do examinando.

A próxima seção irá comentar como construímos e avaliamos os modelos de TB-APR utilizando a metodologia proposta neste capítulo.

### 7.3 Modelos de TB-APR

A construção dos modelos de TB-APR iniciou após a coleta dos dados. Para melhor organizar esta tese, detalhamos a metodologia de coleta dos *scores* da personalidade, coleta textual, quotação dimensional dos *scores* de personalidade e seleção das dimensões da personalidade neste capítulo. Esta metodologia dois conjuntos de dados:

- O *corpus* Z-teste (seção 7.1): três ensaios textuais manuscritos para cada um dos 363 participantes da pesquisa, totalizando 1089 ensaios textuais. Todos os participantes possuem *scores* de personalidade relativos à aplicação coletiva da técnica projetiva do Z-teste.
- O *corpus* TAT (seção 7.2): 20 histórias relatadas por cada um dos 100 participantes da pesquisa, que foram transcritas, na forma manuscrita, por um psicólogo experiente, totalizando 2000 histórias. Todos os participantes possuem *scores* de personalidade para cada uma das 20 histórias, relativos à aplicação individual da técnica projetiva do TAT.

Utilizando estes dois *corpus*, construímos modelos inéditos de TB-APR para as dimensões cada um deles, totalizando 25 modelos. O paradigma de classificação adotado foi o da classificação multiclasse (seção 5.2.2). Reservamos o capítulo 8 para descrever mais detalhadamente estes modelos e os experimentos realizados, compreendo as etapas: (i) pré-processamento (seção 8.1), (ii) extração de características (seção 8.2), (iii) aprendizagem de máquina (seção 8.3), (iv) seleção de características (seção 8.4), (v) métricas de avaliação de desempenho (seção 8.5) e (vi) experimentos (seção 8.6 e seção 8.7). A próxima seção irá fazer as considerações finais deste capítulo.

### 7.3 Considerações finais

Neste capítulo, descrevemos a principal contribuição desta tese, uma metodologia para o reconhecimento automático de personalidade a partir de textos, utilizando duas técnicas projetivas diferentes, o Z-teste e o TAT. Acreditamos que este seja o primeiro trabalho de TB-APR a desenvolver uma metodologia utilizando técnicas projetivas. A metodologia que elaboramos permite verificar se é possível encontrar correlações entre as técnicas de acesso à linguagem (LBA) e as dimensões de personalidade calculadas a partir de técnicas projetivas.

No que diz respeito à construção do modelo, foram utilizados paradigmas de aprendizagem de máquina que tratam o problema de TB-APR de forma coerente. Nesta metodologia, não fizemos simplificações grosseiras nas escalas de personalidade, pelo contrário, utilizamos as classes originais

de personalidade das técnicas selecionadas. Finalmente, utilizar esta metodologia para comparar os resultados obtidos com os resultados da literatura é possível, mas as dimensões de personalidade exploradas por esta tese são inéditas, então esta comparação deve ser realizada com cautela. O próximo capítulo irá detalhar os modelos de TB-APR e os experimentos que realizamos.

## 8 Detalhamento dos Modelos de TB-APR e Experimentos.

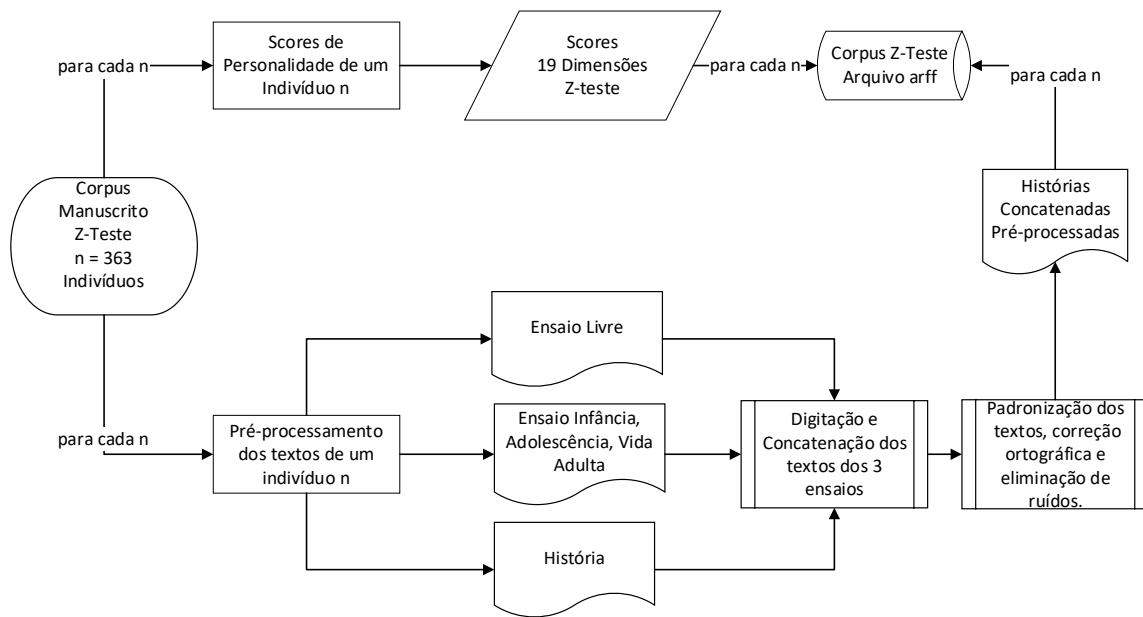
Neste capítulo, detalharemos os modelos e experimentos que desenvolvemos utilizando os *corpus* Z-teste (seção 7.1) e o *corpus* do TAT (seção 7.2). Este capítulo foi dividido nas seguintes seções: a seção 8.1 descreve o pré-processamento, a seção 8.2 a técnica de extração de características textuais, a seção 8.3 a técnica de amostragem e os algoritmos de aprendizagem de máquina, a seção 8.4 a técnica de seleção de características textuais, a seção 8.5 as métricas de avaliação de desempenho, a seção 8.6 os experimentos e avaliação dos resultados utilizando o *corpus* Z-teste, a seção 8.7 os experimentos e avaliação dos resultados utilizando o *corpus* TAT e, finalmente, a seção 8.8 faz uma discussão final deste capítulo.

### 8.1 Pré-Processamento

A etapa de pré-processamento teve como objetivos tornar os textos aptos ao processamento computacional e eliminar ruídos. Como os textos originalmente estavam manuscritos, eles tiveram que ser manualmente digitados em arquivos de textos eletrônicos. Após digitados, todos os textos de autoria de um mesmo indivíduo foram concatenados, gerando um único documento eletrônico de texto por indivíduo. Devido ao fato de alguns textos possuírem erros de grafia, durante o processo de digitação foi habilitado o corretor de palavras do *Microsoft Word*, para a língua portuguesa do Brasil. Em seguida, ruídos foram eliminados dos textos, excluindo números, caracteres de pontuação e outros caracteres especiais desnecessários. Entre os caracteres desnecessários, as aspas foram retiradas dos textos para facilitar a transformação em *strings*, que são exigidas pelas APIs (*Application Programming Interfaces*) de aprendizagem de máquina. Finalmente, deixamos todos os textos em caixa baixa. Utilizar listas de stop-words e stemmers não se mostraram efetivos em nossos experimentos preliminares, então não fizemos o uso destes artifícios no pré-processamento.

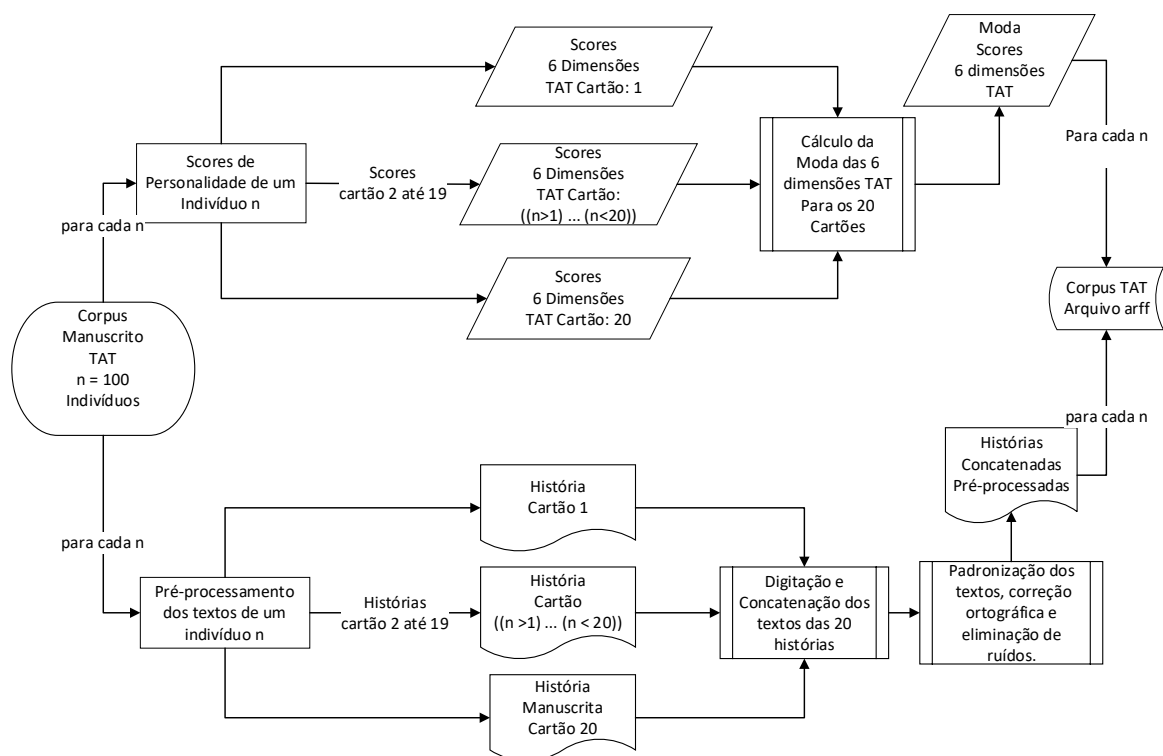
Terminando o pré-processamento, os textos foram transformados em arquivos do tipo arff (formato utilizado pelo Weka [Frank et al, 2016]), sendo gerado um arff para cada *corpus*. Para cada arquivo arff, foi adicionado o cabeçalho exigido pelo Weka, com as informações referentes aos atributos e classes de cada *corpus*. Finalmente, para cada *corpus*, os textos de cada indivíduo foram colocados entre aspas (forma de string), sendo alocados em uma única linha do arquivo. Em seguida, estes textos foram concatenados com as suas respectivas dimensões, na forma de atributos, utilizando um caractere separador.

No *corpus* do Z-teste, os atributos meta foram obtidos através de contagens de variáveis e fórmulas derivadas do sistema de quotação Klopfer [Vaz & Alchieri, 2016] e Z-scores (seção 7.1.4). A Figura 18 detalha o fluxograma de pré-processamento do *corpus* Z-teste.



**Figura 18.** Fluxograma de pré-processamento do corpus Z-teste.

No *corpus* TAT, os atributos meta foram obtidos através de contagens de variáveis e fórmulas derivadas do sistema de quotação MS (seção 7.2.2) para cada uma das 20 histórias. Como as histórias foram concatenadas, o atributo meta de cada dimensão da personalidade foi obtido através da moda. A Figura 19 detalha o fluxograma de pré-processamento do corpus TAT.



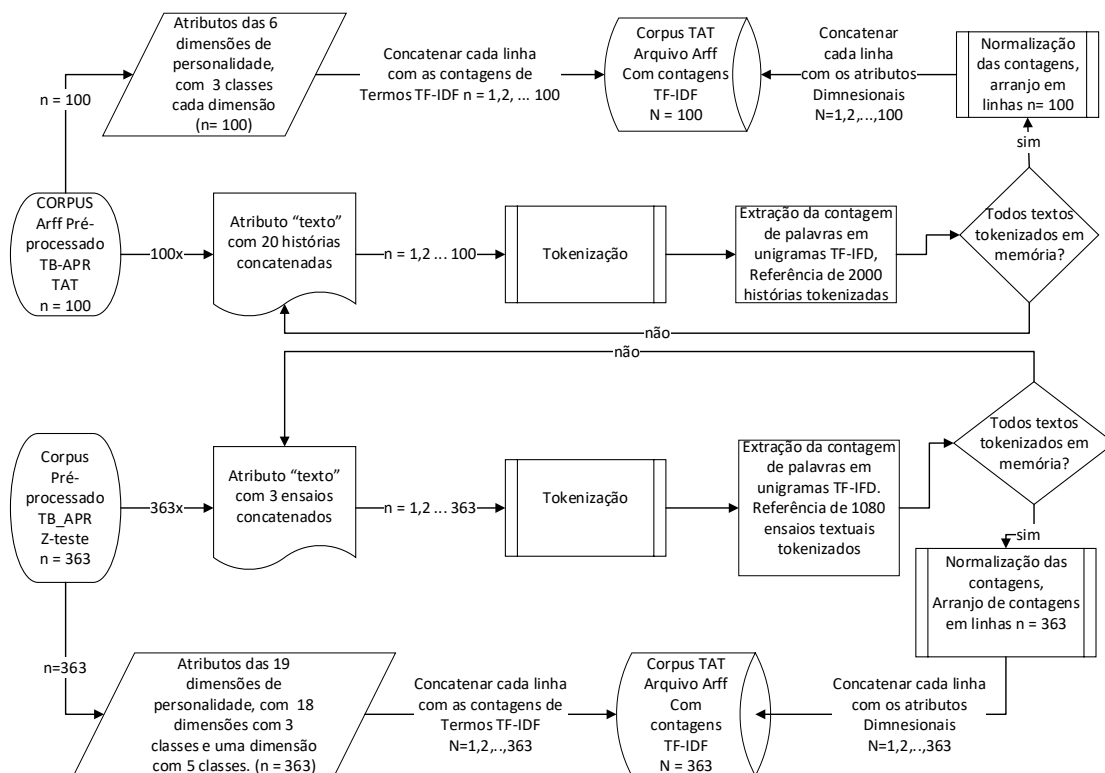
**Figura 19.** Fluxograma de pré-processamento do corpus TAT.

A próxima seção irá comentar o processo de extração de características textuais.

## 8.2 Extração de Características

Para a extração de características, optamos por utilizar uma técnica *bottom-up* (seção 4.3), utilizando especificamente o TF-IDF (seção 4.3.2), implementado pelo filtro não supervisionado *StringToWordVector* da API do Weka. Demos preferência a esta técnica em detrimento às técnicas de *top-down* (seção 4.2), devido ao fato de que estas últimas necessitariam um número maior de textos para popular os vetores das dimensões especializadas de cada léxico.

O filtro *StringToWordVector* tokenizou o texto em *bag-of-words*, extraíndo unigramas (*tokenização* a nível de palavras). Para fazer a extração dos termos TF-IDF, habilitamos no filtro a transformação TF e a transformação IDF, ajustando o parâmetro *wordsToKeep* para realizar a extração de 1000 termos, deixando a opção *minTermFreq* em 1. Também habilitamos a opção *outputWordCounts* que forneceu na saída do filtro a contagem dos termos TF-IDF. Finalmente, habilitamos a opção *normalizeDocLength*, normalizando as contagens das frequências. Todas as demais opções do filtro foram deixadas em *default*. Após a extração de características, os modelos foram submetidos à aprendizagem de máquina supervisionada. A Figura 20 detalha o Fluxograma do processo de extração de características textuais para os corpus Z-teste e TAT.



**Figura 20.** Fluxograma de extração de características textuais.

A próxima seção irá descrever o processo de aprendizagem de máquina.

### 8.3. Aprendizagem de Máquina.

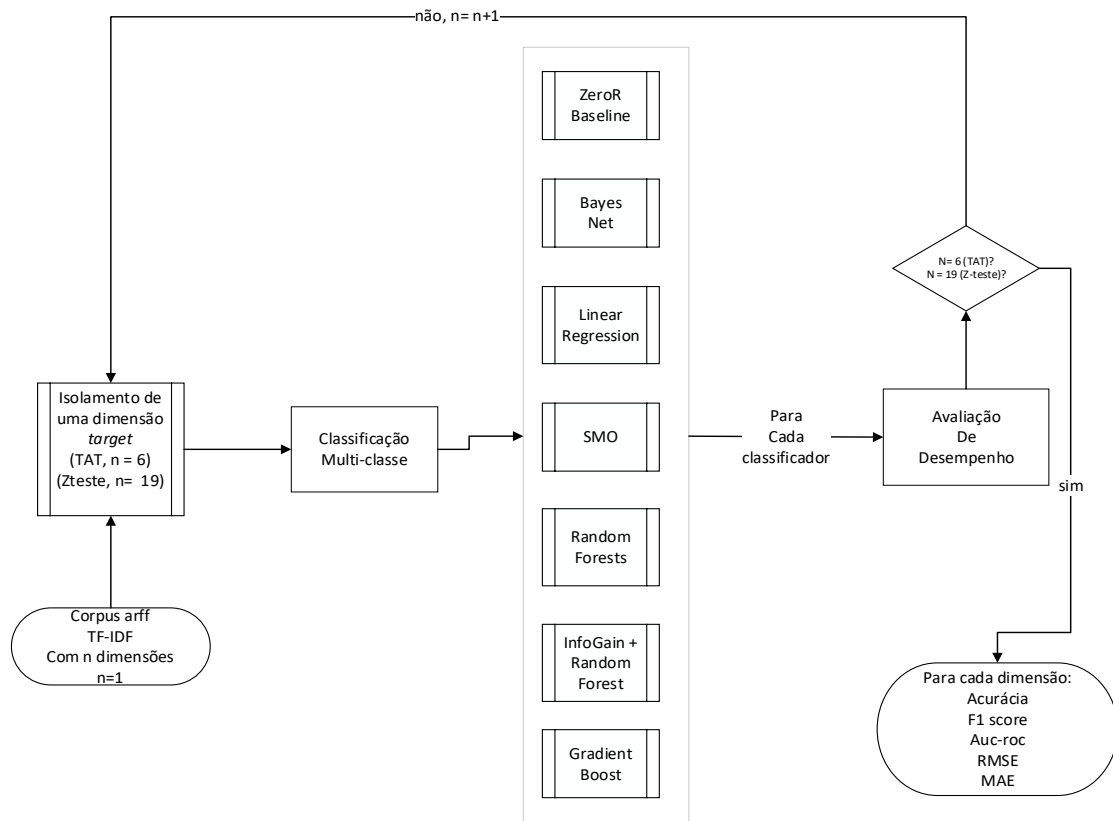
Na etapa de aprendizagem de máquina, optamos por utilizar o paradigma de classificação multi-classe, detalhado no capítulo 6. Este paradigma foi selecionado devido ao fato das dimensões de personalidade possuírem de três a cinco classes, possibilitando gerar modelos com uma simplicidade maior, sendo possível ajustar um modelo específico para cada dimensão de personalidade. Neste sentido, o paradigma de classificação multi-classe é adequado para a previsão automática de personalidade, pois ele permitem que os indutores se especializem em cada dimensão, sendo um paradigma compatível com as escalas de personalidade originais especificadas pelos manuais das técnicas projetivas que utilizamos [Vaz & Alchieri, 2016] [Scaduto, 2016].

Para o corpus do Z-teste construímos um modelo de 5 classes para a dimensão ressonância interna. Para todas as outras 18 dimensões utilizamos um modelo de 3 classes, representando os valores da média, acima da média e abaixo da média para cada dimensão. Em relação ao corpus TAT, apesar das dimensões possuírem mais que 3 classes, nossos modelos utilizaram apenas 3 classes. Isto ocorreu devido ao tamanho pequeno da amostra, que enviesou o processo de de capturar a tendência geral de cada dimensão de personalidade (através da moda das escalas) em 3 classes.

Para fins de comparação de resultados, todos experimentos relatados neste capítulo, utilizaram os mesmos conjuntos de pipeline de aprendizagem de máquina e as mesmas medidas de avaliação de desempenho. Para o baseline utilizamos o classificador ZeroR. Quanto a técnica de amostragem (seção 5.1), todos os classificadores foram submetidos à validação cruzada [Kohavi, 1995] em 10 *folds*. Todos os classificadores fazem parte da api do Weka, com exceção do Gradient Boosting, que faz parte da api do *scikit-learn* [Pedregosa et al, 2011]. Para avaliar o desempenho do Gradient Boosting no mesmo pipeline dos outros algoritmos, um *wrapper* para a linguagem python versão 2.7 foi utilizado na interface do weka, permitindo submeter os classificadores do *scikit-learn* ao *pipeline* de amostragem e avaliação de desempenho do weka.

Os experimentos construíram modelos baseados nos classificadores ZeroR, IBK, BayesNet, Logistic Regression, Random Forest e Gradient Boosting. Adicionalmente, a técnica de seleção de características InfoGain foi utilizada em um modelo, dentro do pipeline do classificador Random Forest. O fluxograma do *pipeline* de aprendizagem de máquina está detalhado na Figura 21.





**Figura 21.** Fluxograma do *pipeline* de aprendizagem de máquina.

Todos os indutores detalhados pela Figura 21 pertencem ao paradigma de classificação multi-classe. Estes classificadores estão detalhados abaixo:

1. ZeroR: É um classificador baseado em uma única regra fixa, comumente utilizado para *baseline* em tarefas de classificação e regressão. Para prever o *target* na tarefa de regressão, o classificador utiliza a média do *target* das instâncias de treinamento. Para prever o atributo meta na tarefa de classificação, o classificador utiliza a moda do *target* das instâncias de treinamento.
2. IBK [Aha, Kibler & Albert, 1991]: É um classificador é do tipo *lazy*. Classificadores deste tipo são chamados assim (*lazy*) porque eles constroem um modelo, se baseando apenas na distância entre os atributos das instâncias de treinamento. Para classificar uma instância no conjunto de teste, o IBK aloca as instâncias de treinamento na memória *a priori*. Neste sentido o classificador compara a distância dos atributos da instância de teste com os atributos de todas as instâncias de treinamento, encontrando os *k*-vizinhos mais próximos. Para selecionar os vizinhos mais próximos o algoritmo utiliza a medida da distância euclidiana [Black, 2004]. Em classificadores *lazy*, o valor de *k* geralmente é um parâmetro customizável. Na classificação binária, recomenda-se utilizar um valor ímpar para *k*, evitando empates na

decisão. Via de regra, também não é recomendado utilizar valores de  $k$  que são múltiplos do número de classes. Apesar destas recomendações, nem sempre seguir estas regras gera o melhor resultado de previsão. Na api do *weka*, o algoritmo IBK permite utilizar a validação cruzada, para o próprio algoritmo encontrar o melhor valor para  $k$ .

3. BayesNet [Bouckaert, 2004]: É um classificador probabilístico, baseado em redes bayesianas. Para entender as redes bayesianas é necessário pensar em incertezas, utilizando o conceito de probabilidades condicionais. Neste sentido, este classificador utiliza inferência Bayesiana [Joaquim, 2010], para construir um modelo que agrega o conhecimento de incertezas, relacionadas aos dados, em tabelas. Posteriormente o algoritmo representa o modelo através de uma espécie de rede de conectivos, utilizando um grafo acíclico direto. Inferir dados em redes bayesianas pode ser um problema *NP-Hard*, sendo assim, as implementações de redes bayesianas podem utilizar diferentes algoritmos, tanto no método de busca, quanto no processo de população das tabelas de probabilidades. Para inferir as tabelas de probabilidade nossos modelos utilizaram os algoritmos *simple estimator* (que é o estimador padrão do *weka*) e o *bayes model averaging* (BMA) [Fragoso, Bertoli & Louzada, 2018].
4. SMO [Jplatt, 1988]; [Keerthi et. al, 2001]: É um classificador baseado em máquinas de vetores de suporte, que implementa um algoritmo de otimização chamado de *Sequential Minimal Optimization* [Jplatt, 1988]. A idéia do algoritmo é estabelecer vetores de suporte que servem de *threshold* para separar as classes. Uma idéia simples para resolver este problema, seria maximizar margem entre os exemplos de cada classe e o vetor de suporte, mas utilizar esta estratégia tornaria o modelo muito sensível a *outliers*. Sendo assim, vetores de suporte utilizam margens flexíveis (*soft margin*) ao invés da maior margem possível. Estas margens flexíveis são calculadas por validação cruzada no conjunto de treinamento, observado as classificações corretas e os erros, obtendo um maior equilíbrio entre o enviesamento e a variância do modelo. Essa flexibilidade, por um lado, permite que o modelo cometa alguns erros, mas por outro lado, também permite classificações sobrepostas corretas. Dependendo do número de atributos, vetor de suporte (*threshold* de separação) pode ser: (i) para 1 atributo, um ponto, que separa o espaço de uma linha, (ii) para 2 atributos, uma linha, que separa o espaço bi-dimensional, (iii) para 3 atributos, um plano, que separa o espaço tri-dimensional e (iv) para 4 ou mais atributos, um hiperplano. Finalmente, é possível que mesmo utilizando margens flexíveis, o vetor de suporte ainda não consiga separar as classes adequadamente, neste sentido as máquinas de vetor de suporte podem aumentar o espaço dimensional do modelo, movendo os dados para uma dimensão maior. A matemática utilizada nos atributos para aumentar o espaço dimensional do modelo é chamada de função *kernel*.

Uma das funções utilizadas para esta finalidade é o *polynomial kernel* onde  $d$  é um parâmetro que diz respeito ao grau do polinômio que irá corresponder ao número dimensões do modelo. Neste sentido é possível usar validação cruzada no treinamento para achar o melhor valor pra  $d$ .

5. Multinomial Logistic Regression [Cessie & Houwelingen, 1992]: A regressão logística é utilizada na tarefa de classificação, utilizando a ideia da regressão linear (utilizada em problemas de regressão). Na regressão linear, o algoritmo procura separar as classes através da soma dos quadrados dos resíduos. Na regressão logística, os dados são separados através de uma função logística sigmóide. Como na regressão logística não existe o conceito de resíduo, o algoritmo utiliza a estatística de *maximum likelihood* [Rossi, 2018], que otimiza o local da função logística sigmoide sobre os dados.
6. Random Forests [Breiman, 2001]: Random Forests é um algoritmo que utiliza uma técnica chamada de *ensemble*. Esta técnica utiliza árvores de decisão em combinação com a técnica de *bootstrap aggregating* [Breiman, 1996] (ou *bagging*). A ideia do *bagging* é agregar diversidade ao modelo, dividindo as instâncias de treinamento em múltiplos compartimentos (*bags*) randômicos, podendo ocorrer a repetição de uma instância já selecionada em um compartimento. As instâncias de cada compartimento (*bag*) são posteriormente utilizadas para construir cada árvores de decisão. Este algoritmo também introduz diversidade a nível de atributos, através do parâmetro *numFeatures*, que define quantos atributos randômicos serão considerados em cada *split*. Em nossos experimentos com random forest customizamos os seguintes parâmetros: (i) *numIterations*, que define o número total de árvores do modelo, (ii) *maxDepth*, utilizado para definir um corte de profundidade das árvores (poda) e (iii) *numFeatures*, utilizado para introduzir diversidade em relação aos atributos. Após construir as árvores, o classificador consulta cada uma delas, fazendo a previsão do modelo por votação. Neste sentido, o erro de generalização tende a diminuir à medida que mais árvores são construídas. Este classificador geralmente performa adequadamente devido a introdução dos fatores randômicos aqui mencionados, que ajudam reduzir a variância e o risco de *overfitting*.
7. Gradient Boosting [Friedman, 2001]: Assim como o Random Forests, o Gradient Boosting utiliza uma técnica de ensemble de classificadores. Apesar de possuírem diferenças significativas, a ideia do Gradient Boosting partiu do conceito de um outro algoritmo, chamado de AdaBoost [Yoav & Robert, 1996]. A principal diferença entre o *boosting* e o *bagging*, é que no *boosting* as instâncias que foram classificadas erradas nos modelos do *ensemble*, possuem uma chance maior de serem selecionadas para o próximo modelo. Este Algoritmo seleciona o primeiro node baseado no logaritmo natural das probabilidades

( $\log(odds)$ ). Em seguida o ( $\log(odds)$ ) é convertido em probabilidade, através da função logística, representada pela fórmula 36. Posteriormente, os pseudo-resíduos são calculados. Os pseudo-resíduos são a diferença entre a probabilidade esperada e a probabilidade prevista. Após o cálculo dos pseudo-resíduos, uma nova árvore é construída, utilizando uma estratégia de *split* para prever os pseudo-resíduos calculados anteriormente. Finalmente, após cada nova árvore ser construída, os pseudo-resíduos de cada folha são transformados (por serem probabilidades) utilizando a fórmula 37. No Gradient Boosting árvores são modeladas podendo serem tunados os seguintes parâmetros: (i) velocidade de aprendizagem (*learning rate*), (ii) profundidade máxima, (iii) número máximo de *features* a serem consideradas em cada *split* e (iv) número máximo de folhas, (v) *subsample*. Este último (v) é um parâmetro na forma de um número entre 0 e 1, onde *subsample* < 1 adiciona diversidade de instâncias ao algoritmo, transformando o Gradient Boosting em Stochastic Gradient Boosting, aumentando o *bias* do indutor, mas por outro lado, reduzindo a variância. O *learning rate* (i), geralmente é um número muito pequeno, que é multiplicado pelo  $\log(odds)$  para diminuir a contribuição de cada árvore, permitindo um ajuste mais elaborado do modelo.

$\text{Função Logística} = \frac{e^{\log(odds)}}{1 + e^{\log(odds)}}$	(36)
---	------

Onde  $\log(odds)$  representa logaritmo natural (base neperiana) das probabilidades das classes e a letra *e* (*épsilon*) representa o número de Neper (2.7182818285).

$\frac{\sum Residual}{\sum [Probabilidade anterior_i * (1 - Probabilidade anterior_i)]}$	(37)
--	------

Onde  $\sum Residual$  representa a soma de todos pseudo-resíduos em uma única folha. O denominador representa a soma de todas as probabilidades previstas anteriormente para cada pseudo-resíduo, multiplicado por 1 menos a mesma soma de probabilidades.

#### 8.4. Seleção de Características.

Quanto ao pipeline do classificador Random Forests, também adicionamos uma categoria de experimentos em conjunto com a técnica de seleção de características Information Gain (IG) [Hall &

Holmes, 2003]. Optamos por esta técnica por ser uma das formas mais simples e rápidas de se fazer ranqueamento de variáveis, sendo amplamente utilizada na categorização textual [Yang & Pedersen, 1997]; [Dumais, Heckerman & Shami, 1988].

Esta técnica utiliza o conceito de entropia. Na teoria da informação, entropia é uma medida de grau médio de incerteza a respeito das fontes de informação, qualificando informações de um sistema. Podemos entender entropia como o contrário do conceito de redundância. Se a redundância é tudo aquilo que não é necessário para se entender uma informação, à entropia é justamente seu complemento (contrário). Trazendo o conceito de entropia para os modelos de TB-APR, podemos utilizar esta medida para selecionar os atributos discriminantes para as dimensões da personalidade, com alto poder combinatório. A partir da fórmula de Hartley (fórmula 38), podemos calcular a entropia de uma classe (fórmula 39) e a entropia de uma classe observando um atributo (fórmula 40).

$I(E) = -\log_2(p(E))$	(38)
------------------------	------

A medida da informação relativa a um evento E, é uma função que desce a medida que a probabilidade de p(E) aumenta [Hartley, 1928].

$H(C) = - \sum_{c \in C} p(c) \log_2 p(c)$	(39)
--	------

Onde H(C) é a entropia de uma dimensão (C), antes de observar um atributo. Ela é uma função que desce a medida que a probabilidade de uma classe p(c) aumenta.

$H(C A) = - \sum_{a \in A} p(a) \sum_{c \in C} p(c a) \log_2 p(c)$	(40)
--	------

Sendo H(C|A) a entropia de uma dimensão (C) observando um conjunto de atributos (A). H(C|A) é uma função que desce na medida em que a probabilidade de um atributo p(a), a probabilidade de um atributo dada a probabilidade de uma classe p(c|a) e a probabilidade da classe p(c) aumentam.

Sendo assim, utilizamos a técnica de IG para construir um modelo que permite trabalhar com variáveis pré rankeadas dentro do pipeline de Random Forests. Antes de aplicar o filtro IG, o algoritmo implementado pelo weka discretiza os valores numéricos, utilizando o método proposto por Fayyad e Irani [Fayyad, Irani, 1992]. Sendo assim, os modelos de Random Forest que sofreram seleção de características a priori, cada atributo  $A_i$  obteve uma pontuação baseada no IG entre o

próprio atributo e a classe. A fórmula 41 apresenta as equações para o cálculo do ganho de informação (IG), baseadas no cálculo da entropia [Hall & Holmes, 2003].

$\begin{aligned}IG_i &= H(C) - H(C A_i) \\ &= H(A_i) - H(A_i C) \\ &= H(A_i) + H(C) - H(A_i C).\end{aligned}$	(41)
---	------

Para não privilegiar o modelo com o ganho de informação referente aos dados dos *fold*s de testes, o Random Forest foi aplicado em conjunto com o meta-classificador *FilteredClassifier*, possibilitando o ranqueamento dos atributos baseado apenas na informação dos *fold*s de treinamento. A seção 8.5 irá detalhar as métricas utilizadas para a avaliação do desempenho dos modelo propostos.

## 8.5 Métricas de Avaliação de Desempenho

Nesta seção serão detalhadas as métricas utilizadas para avaliar o desempenhos dos modelos. Estas métricas são comumente utilizadas em problemas de classificação. Nossos modelos utilizam o paradigma de classificação multi-classe, mas as métricas utilizadas são adaptadas do paradigma de classificação binária. Como utilizamos a API do Weka [Frank et al, 2016], para avaliar o desempenho dos classificadores no paradigma de classificação multiclasse, é utilizada a estratégia de um contra todos, calculando-se no final a média do desempenho. Em classificação, existem 4 conceitos básicos para calcular o desempenho de um modelo:

1. Verdadeiro Positivo (TP): Quando o modelo prevê corretamente a classe positiva.
2. Falso Positivo (FP): Quando o modelo prevê incorretamente a classe positiva.
3. Verdadeiro Negativo (TN): Quando o modelo prevê corretamente a classe negativa.
4. Falso Negativo (FN): Quando o modelo prevê incorretamente a classe negativa.

Partindo destes conceitos básicos, enumeramos as medidas de avaliação de desempenho que os modelos utilizaram:

1. Acurácia: Também conhecida como taxa de erro. É uma métrica mede a frequência em que um algoritmo classifica corretamente uma instância. O cálculo da acurácia é representado pela fórmula 42.

$Acurácia = \frac{TP + TN}{TP + TN + FP + FN}$	(42)
--	------

2. F1score: A precisão (fórmula 43) é uma medida que avalia quantas instâncias classificadas como verdadeiras, realmente são verdadeiras. O recall (fórmula 44) é uma medida que avalia com que frequência o classificador está encontrando os exemplos da classe positiva. O F1score é a média harmônica entre a precisão e o recall (fórmula 45).

$Precisão = \frac{TP}{TP + FP}$	(43)
$Recall = \frac{TP}{TP + FN}$	(44)
$F1Score = 2 * \frac{Precisão * Recall}{Precisão + Recall}$	(45)

3. AUC-ROC: A área abaixo da curva das características operacionais do receptor é uma medida de avaliação de desempenho utilizada como uma medida de avaliação para quantificar o tanto que um modelo de classificação pode distinguir entre as classes. A medida de avaliação AUC-ROC também é utilizada em outras áreas, como na psicologia, por exemplo, para avaliar se um indivíduo consegue distinguir entre um estímulo e um não estímulo [Green & Swets, 1989]. Na computação a curva ROC é uma medida de avaliação de desempenho adequada para domínios onde existe um desbalanceamento entre as classes ou quando se deseja considerar os diferentes custos para os diferentes erros de classificação [Prati, Batista & Monard, 2008]. O gráfico ROC é baseado na probabilidade de detecção (taxa) dos verdadeiros positivos ( $tpr = P(Y|X)$ ), e na probabilidade de detecção (taxa) dos falsos positivos ( $fpr = P(Y|X')$ , onde  $X'$  é o complemento de  $X$ ). Para plotar o gráfico de ROC, o eixo dos ordenadas é representado por  $tpr$  (taxa de positivos verdadeiros) e o eixo das abscissas é representando por  $fpr$  (taxa de falsos positivos). Finalmente, o modelo de classificação é representado por um ponto no espaço do gráfico. Para se obter o ponto, é calculada a taxas de  $tpr$  e  $fpr$  a partir da sua matriz de contingência. Na curva ROC quatro pontos possuem destaque. (i) O ponto (0,0) significa que o modelo nunca classificou uma instância como positivo, neste sentido o modelo não

possui nenhum TP e nenhum FP. (ii) O ponto (1,1) representa o inverso, ou seja, o modelo classificou todas instâncias como positivo. (iii) O ponto (0,1) representa um modelo perfeito, que classificou todas as instâncias corretamente. (iv). O ponto (1,0) representa o pior modelo, que classificou todas as intâncias de forma errada.

4. MAE (mean average error): Nesta medida de avaliação de desempenho, calcula-se o erro através da media da diferença absoluta entre os valores reais ( $y$ ) e os valores previstos pelo modelo ( $y'$ ). O cálculo do MAE é detalhado pela formula 46. Esta métrica é bastante utilizada pois não está sujeita à diferença entre valores positivos e negativos, além disso ela possui menos efeitos colaterais em relação a *outliers*, se comparada com a métrica RMSE por exemplo. Esta medida de erro é dependente da escala (conjunto de dados)

$MAE = \frac{1}{n} \sum_{i=1}^n  y_i - y'_i $	(46)
---	------

5. RMSE (root mean square error): É outra medida de avaliação de desempenho baseada no erro, onde calcula-se a media da raiz quadrática da potência da diferença entre os valores reais ( $y$ ) e os valores previstos pelo modelo ( $y'$ ). O RMSE é calculado através da fórmula 47. Como no cálculo do RMSE, os erros são elevados ao quadrado, antes do cálculo da média, de acordo com a particularidade de cada erro, o RMSE pode aumentar consideravelmente, por exemplo, quando existem muitos *outliers*. Esta medida de erro é independente da escala (conjunto de dados).

$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - y'_i)^2}$	(47)
---	------

Quanto às medidas de erro MAE e RMSE, elas podem ser um valor entre 0 e o infinito, retornado a quantidade média do erro de previsão, ou seja, quanto menor o valor, melhor será a capacidade de previsão do modelo. A principal diferença entre as duas medidas de erro, é que o RMSE dá um peso maior aos erros maiores (devido a potência das diferenças). Neste sentido, caso exista *outliers* no conjunto de dados, irá influenciar muito mais a medida RMSE do que a medida MAE. O cálculo do erro na tarefa de classificação é obtido através da distribuição de probabilidades para cada uma das classes previstas que são comparadas com os valores reais (0 ou 1) que indicam a presença ou ausência da classe. A próxima seção irá detalhar os experimentos realizados com o corpus z-teste.



## 8.6 Experimentos com o corpus z-teste.

O corpus do Z-teste, detalhado na seção 7.1, possui informações de 363 indivíduos, estudantes de universidades do sul do Brasil, categorizados em 19 dimensões da personalidade. Destas dimensões, 18 dimensões possuem 3 classes e uma dimensão possui 5 classes (detalhes na seção 7.1.4). Para gerar as classes, as contagens brutas de variáveis foram agregadas em 54 tabulações (seção 7.1.2) e em seguida foram categorizadas por *z-scores* (seção 7.1.4). A metodologia de coleta textual está detalhada na seção 7.1.5.

Utilizar *z-scores* para avaliar a personalidade, é uma das técnicas descritas no manual que utilizamos [Vaz & Alchieri, 2016, pp. 88 - 111] para avaliar as dimensões de personalidade do Z-teste. A tabela 18 detalha o corpus do Z-teste.

CORPUS Z-TESTE	
Total de participantes	363
Masculinos	118
Femininos	245
Idades min – max / Desvio padrão	18 -55 anos / 5.57
Alunos de psicologia	236
Alunos de ciência da computação	71
Alunos de relações públicas	24
Alunos de publicidade e propaganda	24
Alunos de Jornalismo	8
Tipo de texto / Quantidade	3 ensaios textuais por indivíduo / 1089
Número de palavras	145.516
Dimensões Totais / (Dimensões, Classes)	19 / (18, 3), (1, 5)

**Tabela 18.** Detalhes do corpus Z-teste.

As próximas seções irão detalhar os experimentos referentes ao corpus Z-teste: (i) o balanceamento de cada dimensão de personalidade, (ii) os parâmetros inseridos nos indutores de cada modelo e (iii) a avaliação do desempenho de cada modelo.

### 8.6.1 Respostas ( $\Sigma R$ ): Capacidade de Desempenho e de Adaptação Geral.

O Z-Teste “expõe o examinando a diversas situações de dificuldades, que serão resolvidas através de sua inteligência e de acordo com a sua personalidade, sendo assim, o número de respostas pode ser entendido como a Capacidade de Desempenho e Adaptação Geral” [Vaz & Alchieri, 2016, p. 87, 88].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 30), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000, maxDepth=3), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 1000, maxFeatures = 25, maxDepth = 5), Gradient Boost (n\_estimators = 1000, max\_depth = 4, min\_samples\_split = 2, min\_samples\_leaf = 30, max\_features = 60). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 19 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Capacidade de Desempenho e de Adaptação Geral*.

$(\Sigma R)$	Distribuição de Classes: (low, 55), (mid, 258), high (50)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.710	?????	0.485	0.303	0.388
IBK	0.314	0,312	0.635	0.4535	0.531
Bayes	0.732	0.716	0.780	0.222	0.359
SMO	0.724	0.678	0.630	0.298	0.387
Logistic	0.672	0.693	0.788	0.221	0.443
Random Forest	0.710	?????	0.851	0.294	0.379
InfoGain RF	0.782	0.729	0.822	0.239	<b>0.337</b>
GradientBoost	<b>0.785</b>	<b>0.740</b>	<b>0.860</b>	<b>0.156</b>	0.356

Tabela 19. *Capacidade de Desempenho e de Adaptação Geral*.

Analizando a tabela 19, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.860. Este classificador também obteve a maior acurácia (0.785), o maior F1score (0.740) e o menor erro MAE (0.156). Finalmente, o classificador Random forest, combinado com a técnica de seleção de características InfoGain obteve o menor erro RMSE (0.337).

### 8.6.2 Forma Pura ( $\Sigma F$ ): Controle Geral (dimensão racional), Expressão Lógica do Processo Perceptivo.

O Controle Geral "representa a capacidade para pontuar, retardar e antecipar adequadamente atitudes e reações comportamentais. Expressa importante papel da inteligência no aprendizado do ser

humano". Podemos entender que os determinantes de forma pura "examinam o potencial intelectual, racional e lógico na captação, na percepção e integração das coisas" [Vaz & Alchieri, pp. 88, 89].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 30), Random Forest (numIterations = 1000, maxFeatures = 50, maxDepth=5), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 100, numIterations = 1000, maxFeatures = 25), Gradient Boost (n\_estimators = 1000, max\_depth = 2, min\_samples\_split = 8, min\_samples\_leaf = 30, max\_features = 90). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 20 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Controle Geral (dimensão racional), expressão lógica do processo perceptivo*.

$(\Sigma F)$	Distribuição de Classes: (low, 44), (mid, 263), high (56)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.724	0.000	0.475	0.292	0.381
<b>IBK</b>	0.297	0.321	0.598	0.460	0.572
<b>Bayes</b>	0.727	0.724	0.831	0.194	0.366
<b>SMO</b>	0.721	0.663	0.590	0.303	0.393
<b>Logistic</b>	0.685	0.702	0.764	0.214	0.424
<b>Random Forest</b>	0.724	0.000	0.844	0.267	0.355
<b>InfoGain RF</b>	<b>0.782</b>	<b>0.731</b>	0.831	0.235	<b>0.330</b>
<b>GradientBoost</b>	0.763	0.726	<b>0.852</b>	<b>0.163</b>	0.306

**Tabela 20.** *Controle Geral, Expressão Lógica do Processo Perceptivo.*

Analizando a tabela 20, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.852. Este classificador também obteve o menor erro MAE (0.163). Finalmente, o Classificador Random Forest, combinado com a técnica de seleção de características InfoGain obteve a maior acurácia (0.782), o maior F1score (0.731) e o menor erro RMSE (0.330).

### 8.6.3 Forma e Precisão formal (F+): Funcionamento do Pensamento Lógico, Capacidade para Estabelecer Diferenciação Perceptiva.

As formas precisas fornecem pistas do Funcionamento do Pensamento Lógico, utilizado para diferenciar pessoas, situações e coisas, por seus detalhes, peculiaridades e características. Este construto psicológico revela como a personalidade do indivíduo reage em relação à percepção do mundo, indicando o grau de clareza de expressão, considerando a precisão, coerência e objetividade de seus pensamentos. [Vaz & Alchieri, pp. 89, 90].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 1), Random Forest (numIterations = 1000, maxFeatures = 25, maxDepth = 5), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 6, min\_samples\_split = 2, min\_samples\_leaf = 15, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 21 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva*.

(F+)	Distribuição de Classes: (low, 55), (mid, 253), high (55)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.696	0.000	0.476	0.313	0.395
<b>IBK</b>	0.185	0.146	0.526	0.513	0.653
<b>Bayes</b>	0.677	0.670	0.757	0.236	0.400
<b>SMO</b>	0.721	0.677	0.628	0.303	0.393
<b>Logistic</b>	0.680	0.695	0.798	0.210	0.420
<b>Random Forest</b>	0.697	0.000	0.803	0.295	0.377
<b>InfoGain RF</b>	0.732	0.669	0.775	0.268	<b>0.359</b>
<b>GradientBoost</b>	<b>0.746</b>	<b>0.687</b>	<b>0.823</b>	<b>0.180</b>	0.370

**Tabela 21.** *Funcionamento do pensamento lógico, capacidade para estabelecer diferenciação perceptiva.*

Analisando a tabela 21, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.823. Este classificador também obteve a maior acurácia (0.746), o maior F1score (0.687) e o menor erro MAE (0.180). Finalmente, o Classificador Random Forest combinado com a técnica de seleção de características InfoGain obteve o menor erro RMSE (0.359).

#### 8.6.4 Movimento Humano ( $\Sigma M$ ): Espontaneidade, Criatividade e Empatia.

O Movimento Humano tem ligação com os processos de imaginação, criatividade e empatia. Também é relacionado à expressão da personalidade em relação à espontaneidade e ajustamento ao ambiente humano. Podemos entender a dimensão *Espontaneidade, Criatividade, Empatia* como uma representação do que o indivíduo viveu e experimentou em relação ao convívio com outras pessoas [Vaz & Alchieri, p. 90].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 1$ ), Random Forest ( $\text{numIterations} = 1000$ ,  $\text{maxFeatures} = 100$ ), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker  $\text{numToSelect} = 100$ ,  $\text{numIterations} = 1000$ ,  $\text{maxFeatures} = 50$ ), Gradient Boost ( $\text{n\_estimators} = 1000$ ,  $\text{max\_depth} = 6$ ,  $\text{min\_samples\_split} = 2$ ,  $\text{min\_samples\_leaf} = 11$ ,  $\text{max\_features} = 30$ ). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 22 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Espontaneidade, Criatividade e Empatia*.

$(\Sigma M)$	Distribuição de Classes: (low, 77), (mid, 206), high (80)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.567	0.000	0.488	0.390	0.441
IBK	0.264	0.197	0.510	0.488	0.669
Bayes	0.559	0.505	0.630	0.353	0.440
SMO	0.561	0.539	0.607	0.355	0.453
Logistic	0.553	<b>0.567</b>	0.700	0.303	0.527
Random Forest	<b>0.595</b>	0.471	<b>0.714</b>	0.365	<b>0.419</b>
InfoGain RF	0.595	0.537	0.669	0.347	0.426
GradientBoost	0.589	0.527	0.710	<b>0.279</b>	0.458

**Tabela 22.** *Espontaneidade, Criatividade e Empatia*.

Analizando a tabela 22, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, com uma AUC-ROC de 0.714. Este classificador também obteve a maior acurácia (0.595) e o menor erro RMSE (0.419). O classificador Logistic Regression obteve o maior F1score (0.687). Finalmente, o classificador Gradient Boost obteve o menor erro MAE (0.279).

### 8.6.5 Movimento Animal (FM): Impulsividade e Dinamismo.

A *Impulsividade e Dinamismo*, expressa através do movimento animal, denota a iniciativa e capacidade para competição da personalidade. Este determinante é relacionado com "o que há de mais primário e arcaico na estrutura da personalidade" [Vaz & Alchieri, pp. 91, 92], ou seja, uma representação dos instintos e impulsos.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 1$ ), Bayes Net ( $\text{estimator} = \text{BMAEstimator}$ ), Random Forest ( $\text{numIterations} = 1000$ ), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker  $\text{numToSelect} = 100$ ,  $\text{numIterations} = 1000$ ), Gradient Boost ( $\text{n\_estimators} = 1000$ ,  $\text{max\_depth} = 6$ ,  $\text{min\_samples\_split} = 2$ ,

min\_samples\_leaf = 3, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 23 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Impulsividade e Dinamismo*.

(FM)	Distribuição de Classes: (low, 40), (mid, 323)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.889	0.000	0.497	0.198	0.313
IBK	0.203	0.207	0.567	0.682	0.755
Bayes	0.928	0.934	0.976	<b>0.089</b>	0.2546
SMO	0.719	0.771	0.809	0.281	0.530
Logistic	0.763	0.806	0.936	0.237	0.486
Random Forest	<b>0.936</b>	<b>0.942</b>	<b>0.990</b>	0.372	0.381
InfoGain RF	0.931	0.936	0.985	0.272	0.301
GradientBoost	0.911	0.921	0.983	0.120	<b>0.247</b>

**Tabela 23.** *Impulsividade e Dinamismo*.

Analizando a tabela 23, verificamos que na amostra existe a falta de uma classe, ou seja, neste *corpus* (n=363), nenhuma instância foi classificada como *high* (acima de um desvio padrão) para a dimensão *Impulsividade e Dinamismo*. Neste sentido, em uma amostra de dados maior (n>363) ou mais heterogênea (ex. indivíduos de diferentes níveis de escolaridade), seria provável que parte dos indivíduos fossem classificados como *high*. Nos experimentos verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, com uma AUC-ROC de 0.990. Este classificador também obteve a maior acurácia (0.936) e o maior F1score (0.942). O classificador Bayes Net, obteve o menor erro MAE (0.089). Finalmente, o classificador Gradient Boost obteve o menor erro RMSE (0.247).

#### 8.6.6 Relacionamento interpessoal (FC) e a tendência a excitabilidade emocional ((CF) + (C)).

O *Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional* são representações de características de personalidade relacionadas à capacidade de receber, proporcionar e retribuir afetos, com adequação e maturidade, proporcionando um relacionamento interpessoal apropriado [Vaz & Alchieri, pp. 92, 93, 94].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 1), Random Forest (numIterations = 1000), Random Forest combinado com a técnica de seleção de

características InfoGain (IG Ranker numToSelect = 100, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 2, min\_samples\_split = 2, min\_samples\_leaf = 23, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 24 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional*.

(FC) ≥ ((CF) + (C))	Distribuição de Classes: (low, 54), (mid, 243), high (66)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.669	0.000	0.489	0.332	0.406
<b>IBK</b>	0.250	0.228	0.491	0.494	0.686
<b>Bayes</b>	0.636	0.629	0.758	0.255	0.405
<b>SMO</b>	0.693	0.642	0.619	0.318	0.412
<b>Logistic</b>	0.625	0.639	0.750	0.251	0.467
<b>Random Forest</b>	0.669	0.000	0.801	0.308	0.384
<b>InfoGain RF</b>	0.680	0.576	0.765	0.294	<b>0.377</b>
<b>GradientBoost</b>	<b>0.732</b>	<b>0.696</b>	<b>0.810</b>	<b>0.195</b>	0.388

**Tabela 24.** *Relacionamento Interpessoal e a Tendência a Excitabilidade Emocional.*

Analizando a tabela 24, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.810. Este classificador também obteve a maior acurácia (0.732), o maior F1score (0.696) e o menor erro MAE (0.195). Finalmente, o classificador Random Forest, em conjunto com a técnica de seleção de características Infogain, obteve o menor erro RMSE (0.377).

### 8.6.7 Ansiedade com adaptação afetiva (FK) e ansiedade com precário controle ((K)+(KF)).

A *Ansiedade com Adaptação Afetiva e Ansiedade com Precário Controle* representa os aspectos da personalidade relacionados a situações que geram ansiedade na vida cotidiana das pessoas [Vaz & Alchieri, pp. 95, 96].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 1), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 200, numIterations = 1000, maxFeatures = 50), Gradient Boost (n\_estimators = 1000, max\_depth = 7, min\_samples\_split = 2, min\_samples\_leaf = 20, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 25 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Ansiedade com Adaptação Afetiva e Ansiedade com Precário Controle*.

(FK) ≥ ((KF) + (K))	Distribuição de Classes: (low, 78), (mid, 244), high (41)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.672	0.000	0.489	0.327	0.403
<b>IBK</b>	0.247	0.256	0.526	0.493	0.686
<b>Bayes</b>	0.661	0.615	0.593	0.312	0.404
<b>SMO</b>	0.699	0.655	0.705	0.251	0.384
<b>Logistic</b>	0.650	<b>0.659</b>	0.742	0.242	0.452
<b>Random Forest</b>	0.683	0.000	0.756	0.301	0.390
<b>InfoGain RF</b>	<b>0.719</b>	0.631	0.740	0.276	<b>0.366</b>
<b>GradientBoost</b>	0.716	0.646	<b>0.755</b>	<b>0.194</b>	0.394

**Tabela 25.** *Ansiedade com Adaptação Afetiva e Ansiedade com Precário Controle.*

Analizando a tabela 25, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.755. Este classificador também obteve o menor erro MAE (0.194). O classificador Logistic Regression obteve o maior F1score (0.696). Finalmente, o classificador Random Forest, em conjunto com a técnica de seleção de características Infogain, obteve a melhor acurácia (0.719) e o menor erro RMSE (0.366).

### 8.6.8 Cor Acromática (FC'), (C'F), (C'): Traços depressivos da personalidade.

Os *Traços Depressivos da Personalidade* estão relacionados à áreas percebidas como escuro, preto ou cinza, desde que exista a compatibilidade de cor onde as percepções são indicadas. Podemos entender percepções acromáticas como uma forma do examinando evitar mobilizar sentimentos e emoções [Vaz & Alchieri, pp. 96, 97].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 30), Random Forest (numIterations = 1000, maxFeatures = 200, maxDepth = 7), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 1000, maxDepth = 7), Gradient Boost (n\_estimators = 1000, max\_depth = 9, min\_samples\_split = 2, min\_samples\_leaf = 10, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 26 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Traços Depressivos da Personalidade*.



$(FC') \geq ((CF') + (C'))$	Distribuição de Classes: (low, 70), (mid, 270), high (23)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.743	0.000	0.488	0.272	0.367
IBK	0.738	0.000	0.609	0.293	0.376
Bayes	0.719	0.000	0.514	0.297	0.386
SMO	0.790	<b>0.788</b>	<b>0.790</b>	0.177	0.334
Logistic	0.484	0.550	0.608	0.349	0.576
Random Forest	<b>0.793</b>	0.000	0.767	0.224	0.325
InfoGain RF	0.793	0.710	0.753	0.219	<b>0.322</b>
GradientBoost	0.793	0.719	0.749	<b>0.151</b>	0.360

**Tabela 26.** Traços Depressivos da Personalidade.

Analizando a tabela 26, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o SMO, com uma AUC-ROC de 0.790. Este classificador também obteve o maior F1score (0.788). O classificador Logistic Regression obteve a maior Acurácia (0.793). O classificador Gradient Boost, obteve o menor erro MAE (0.151). Finalmente, o classificador Random Forest, em conjunto com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.322).

### 8.6.9. Textura (Fc), (cF), (c): Contato humano e interação social.

Podemos entender a percepção tátil como a expressão de contato afetivo mais primária nos seres humanos [Vaz & Alchieri, pp. 62]. Estas percepções são marcadores de conflitos entre o mundo interno e o mundo externo, polarizando experiências entre a intimidade e o mundo externo [Oñativia, 1972]. Neste sentido, "a textura é uma forma tátil de expressão das condições afetivas da pessoa, quer buscando o afeto de alguém ou em alguma coisa, quer investindo o afeto em outras pessoas, situações e objetos" [Vaz & Alchieri, pp. 97, 98]. Além disso, a percepção tátil demonstra ansiedade e angústia, expressas pela necessidade de contato [Lopes, 1943]. No Z-teste coletivo, este processo é caracterizado pelo mecanismo de deslocamento dos sentimentos emocionais por meio da descrição de textura. No caso do Z-teste individual também é possível identificar este processo por meio da fricção afetiva direta sobre o cartão.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 29), Random Forest (numIterations = 1000, maxFeatures = 200), Random Forest combinado com a técnica

de seleção de características InfoGain (IG Ranker numToSelect = 100, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 9, min\_samples\_split = 2, min\_samples\_leaf = 10, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 27 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Contato humano e interação social*.

(Fc) ≥ ((cF) + (c))	Distribuição de Classes: (low, 17), (mid, 277), high (69)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.763	0.000	0.481	0.254	0.355
<b>IBK</b>	0.741	0.000	0.656	0.310	0.386
<b>Bayes</b>	0.760	0.694	0.544	0.285	0.371
<b>SMO</b>	0.787	<b>0.781</b>	0.750	0.162	0.329
<b>Logistic</b>	0.550	0.612	0.630	0.296	0.524
<b>Random Forest</b>	0.796	0.000	0.792	0.216	0.317
<b>InfoGain RF</b>	<b>0.816</b>	0.726	0.771	0.210	<b>0.311</b>
<b>GradientBoost</b>	0.796	0.726	<b>0.793</b>	<b>0.142</b>	0.347

**Tabela 27.** *Contato humano e interação social.*

Analizando a tabela 27, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.793. Este classificador também obteve o menor erro MAE (0.142). O classificador SMO obteve o maior F1Score (0.781). Finalmente, o classificador Random Forest, em conjunto com a técnica de seleção de características InfoGain, obteve a maior acurácia (0.816) e o menor erro RMSE (0.311).

#### 8.6.10. Cor pura (C): Tendência à Reação Emocional Intensa.

Isoladamente, a cor pura é o determinante específico que caracteriza as projeções de reações emocionais livres, intensas e carregadas de sentimentos. Estes sentimentos podem ser os mais variados, de apreciação, estima, admiração, amor e paixão, ou de depreciação, desprezo, ódio, raiva e agressividade [Vaz & Alcheieri, pp. 98, 99].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 26), Random Forest (numIterations = 1000, maxFeatures = 200), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 200, numIterations = 1000),

Gradient Boost ( $n\_estimators = 1000$ ,  $max\_depth = 8$ ,  $min\_samples\_split = 2$ ,  $min\_samples\_leaf = 11$ ,  $max\_features = 30$ ). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 28 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Tendência à Reação Emocional Intensa*.

(C)	Distribuição de Classes: (mid, 296), high (67)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.815	0.000	0.480	0.302	0.388
<b>IBK</b>	0.834	0.838	0.852	0.229	0.332
<b>Bayes</b>	0.865	<b>0.858</b>	0.732	<b>0.135</b>	0.367
<b>SMO</b>	0.856	0.853	0.856	0.150	0.339
<b>Logistic</b>	0.840	0.831	0.784	0.168	0.359
<b>Random Forest</b>	<b>0.865</b>	0.848	0.828	0.204	<b>0.322</b>
<b>InfoGain RF</b>	0.859	0.840	0.831	0.205	0.323
<b>GradientBoost</b>	0.785	0.805	<b>0.868</b>	0.231	0.401

**Tabela 28.** *Tendência à Reação Emocional Intensa.*

Analizando a tabela 28, verificamos que na amostra existe a falta de uma classe, ou seja, neste *corpus* ( $n=363$ ), nenhuma instância foi classificada como *low* (abaixo de um desvio padrão) para a dimensão *Impulsividade e Dinamismo*. Neste sentido, em uma amostra de dados maior ( $n>363$ ) ou mais heterogênea (ex. indivíduos de diferentes níveis de escolaridade), seria provável que parte dos indivíduos fossem classificados como *low*. Nos experimentos, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.868. O classificador Bayes Net obteve o maior F1Score (0.858) e o menor erro MAE (0.135). Finalmente, o classificador Random Forest, obteve a maior acurácia (0.865) e o menor erro RMSE (0.322).

#### **8.6.11 Conteúdos Humanos ((H) + (Hd)): As pessoas na percepção do examinando.**

Os Conteúdos Humanos revelam como o examinando percebe as outras pessoas. As pessoas na percepção do examinando são inferidas através das percepções de conteúdos de seres humanos (H) percebidos em sua forma inteira, somados com as percepções de membros externos de seres humanos (Hd) [Vaz & Alchieri, pp. 100, 101].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 1), Random Forest (numIterations = 1000, maxFeatures = 150), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 8, min\_samples\_split = 2, min\_samples\_leaf = 21, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 29 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *As Pessoas na Percepção do Examinando*.

((H) + (Hd))	Distribuição de Classes: (low, 44), (mid, 263), high (56)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.724	0.000	0.489	0.292	0.381
<b>IBK</b>	0.253	0.253	0.531	0.495	0.671
<b>Bayes</b>	0.724	0.679	0.610	0.299	0.388
<b>SMO</b>	0.735	<b>0.712</b>	0.794	0.206	0.352
<b>Logistic</b>	0.687	0.698	0.748	0.214	0.426
<b>Random Forest</b>	0.754	0.000	0.802	0.252	0.343
<b>InfoGain RF</b>	0.763	0.696	<b>0.811</b>	0.238	<b>0.335</b>
<b>GradientBoost</b>	<b>0.771</b>	0.708	0.790	<b>0.163</b>	0.363

**Tabela 29.** *As Pessoas na Percepção do Examinando*.

Analisando a tabela 29, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, combinado com a técnica de seleção de características InfoGain, com uma AUC-ROC de 0.811. Este classificador também obteve o menor erro RMSE (0.335). O classificador SMO obteve o maior F1Score (0.712). Finalmente, o classificador Gradient Boost obteve a maior acurácia (0.771) e o menor erro MAE (0.163).

#### **8.6.12. Conteúdo Animal ((A) + (AD)): Percepções infantis, também presentes no mundo interno do adulto.**

Os conteúdos de animais são representantes do mundo infantil, sendo considerados como a parte da infância que ainda permanece no mundo adulto. As percepções sadias de adultos e crianças podem possuir conteúdos animais. Ao se desenvolver e amadurecer é esperado que o indivíduo diminua as percepções de animais, mas elas geralmente não se extinguem por completo. É interessante ressaltar que pessoas com um nível cultural mais elevado geralmente possuem menos percepções deste tipo [Vaz & Alchieri, pp. 101, 102].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 1$ ), Random Forest ( $\text{numIterations} = 1000$ ), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker  $\text{numToSelect} = 200$ ,  $\text{numIterations} = 1000$ ), Gradient Boost ( $\text{n\_estimators} = 1000$ ,  $\text{max\_depth} = 8$ ,  $\text{min\_samples\_split} = 2$ ,  $\text{min\_samples\_leaf} = 21$ ,  $\text{max\_features} = 60$ ). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 30 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Percepções Infantis, Também Presentes no Mundo Interno do Adulto*.

((A) + (Ad))	Distribuição de Classes: (low, 68), (mid, 235), high (60)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.647	0.000	0.489	0.346	0.415
<b>IBK</b>	0.212	0.162	0.509	0.515	0.686
<b>Bayes</b>	0.677	0.647	0.637	0.321	0.415
<b>SMO</b>	0.628	0.609	0.730	0.268	0.409
<b>Logistic</b>	0.636	<b>0.653</b>	0.765	0.244	0.475
<b>Random Forest</b>	0.647	0.000	0.772	0.323	0.393
<b>InfoGain RF</b>	0.650	0.534	0.764	0.308	<b>0.385</b>
<b>GradientBoost</b>	<b>0.677</b>	0.626	<b>0.773</b>	<b>0.220</b>	0.416

**Tabela 30.** *Percepções Infantis, Também Presentes no Mundo Interno do Adulto*.

Analisando a tabela 30, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.773. Este classificador também obteve a maior acurácia (0.667) e menor erro MAE (0.220). O classificador Logistic Regression obteve o maior F1Score (0.653). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.385).

### 8.6.13. Globais (G): Percepção de conjunto e capacidade de síntese.

Fazendo parte das localizações, as Globais são representações inerentes ao modo operacional perceptivo da realidade. É através das globais que o indivíduo expressa as condições intelectuais de percepção de conjunto, síntese e capacidade de planejamento. Podemos também entender as globais como a inteligência dirigida ao abstrato [Vaz & Alchieri, pp. 102, 103].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 29$ ), Random Forest ( $\text{numIterations} = 1000$ ,  $\text{maxFeatures} = 100$ ), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker  $\text{numToSelect} = 300$ ,  $\text{numIterations} = 1000$ ),

Gradient Boost (n\_estimators = 1000, max\_depth = 8, min\_samples\_split = 2, min\_samples\_leaf = 7, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 31 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Percepção de Conjunto e Capacidade de Síntese*.

(G)	Distribuição de Classes: (low, 15), (mid, 284), high (64)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.782	0.000	0.484	0.238	0.344
IBK	0.765	0.000	0.661	0.311	0.376
Bayes	0.782	0.000	0.562	0.279	0.361
SMO	<b>0.801</b>	<b>0.801</b>	0.798	0.155	0.320
Logistic	0.539	0.608	0.713	0.306	0.539
Random Forest	0.801	0.000	0.803	0.207	<b>0.312</b>
InfoGain RF	0.798	0.718	<b>0.829</b>	0.202	0.308
GradientBoost	0.796	0.720	0.812	<b>0.148</b>	0.348

**Tabela 31.** *Percepção de Conjunto e Capacidade de Síntese.*

Analizando a tabela 31, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, combinado com a técnica de seleção de características InfoGain, com uma AUC-ROC de 0.829. O classificador SMO obteve o melhor F1score (0.801) e a maior acurácia (0.801). O classificador Random Forest obteve o menor erro RMSE (0.312). Finalmente, o classificador Gradient Boost, obteve o menor erro MAE (0.148).

#### 8.6.14. Detalhes Comuns (D): Discernimento e Senso de Objetividade.

Assim como as Globais, os Detalhes Comuns também fazem parte das localizações, e são representações inerentes ao modo operacional perceptivo da realidade. Podemos entender os Detalhes Comuns como a visão objetiva da realidade e a inteligência voltada ao concreto e pragmático [Vaz & Alchieri, p. 102]. Os detalhes comuns são marcadores da inteligência prática e objetiva [Vaz & Alchieri, p. 104]. Este tipo de localização é o mais comum entre todas as localizações, atingindo as maiores contagens de localização, pois geralmente estas localizações são atreladas às respostas mais óbvias.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 27), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000, maxFeatures = 150), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 200, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 6, min\_samples\_split = 2, min\_samples\_leaf = 21, max\_features = 90). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 32 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Discernimento e Senso de Objetividade*.

(D)	Distribuição de Classes: (low, 47), (mid, 253), high (63)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.696	0.000	0.478	0.312	0.394
<b>IBK</b>	0.220	0.160	0.696	0.462	0.500
<b>Bayes</b>	0.724	0.679	0.635	0.300	0.390
<b>SMO</b>	0.696	0.669	0.782	0.228	0.370
<b>Logistic</b>	0.636	0.659	0.790	0.241	0.462
<b>Random Forest</b>	0.721	0.627	<b>0.804</b>	0.272	0.356
<b>InfoGain RF</b>	0.738	0.657	0.792	0.266	<b>0.355</b>
<b>GradientBoost</b>	<b>0.752</b>	<b>0.707</b>	0.795	<b>0.176</b>	0.377

**Tabela 32.** *Discernimento e Senso de Objetividade.*

Analizando a tabela 32, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, com uma AUC-ROC de 0.804. O classificador Gradient Boost obteve o maior F1score (0.707), a maior acurácia (0.752) e o menor erro MAE (0.176). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.335).

#### **8.6.15. Detalhes Incomuns (Dd): Capacidade de análise e senso de observação.**

Assim como as Globais e os Detalhes Comuns, os Detalhes Incomuns também fazem parte das localizações e são representações inerentes ao modo operacional perceptivo da realidade. Podemos entender os detalhes incomuns como a capacidade de análise, observação e bom senso [Vaz & Alchieri, p. 102]. Os detalhes incomuns são indicativos da capacidade de percepção que o examinando possui para a percepção das partes de um todo. Neste sentido, quanto mais cuidadoso e minucioso for o examinando, produzirá mais respostas com localização de detalhes incomuns [Vaz & Alchieri, pp. 104, 105]. Nesta localização são classificadas respostas em áreas de frequência indicadas inferiores à porcentagem de 0.045, ou seja, abaixo da razão de 1/22 [Vaz & Alchieri, p. 48].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 30), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000, maxFeatures = 50), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 200, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 6, min\_samples\_split = 2, min\_samples\_leaf = 11, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 33 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Capacidade de Análise e Senso de Observação*.

(Dd)	Distribuição de Classes: (low, 38), (mid, 277), high (48)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.763	0.000	0.481	0.261	0.360
IBK	0.385	0.431	0.708	0.432	0.464
Bayes	0.793	0.740	0.629	0.281	0.365
SMO	0.749	0.745	0.828	0.185	0.333
Logistic	0.790	<b>0.794</b>	0.816	0.150	0.354
Random Forest	0.768	0.000	<b>0.859</b>	0.227	0.323
InfoGain RF	0.774	0.000	0.841	0.222	<b>0.321</b>
GradientBoost	<b>0.801</b>	0.746	0.848	<b>0.139</b>	0.339

**Tabela 33.** *Capacidade de Análise e Senso de Observação.*

Analizando a tabela 33, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, com uma AUC-ROC de 0.859. O classificador Logistic Regression obteve o maior F1score (0.794). O classificador Gradient Boost obteve a maior acurácia (0.801) e o menor erro MAE (0.139). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.321).

#### 8.6.16. Espaço branco ( $\Sigma S$ ): Ansiedade Situacional.

O Espaço em Branco também faz parte das localizações. No Z-teste os espaços em branco podem ser combinados com as demais localizações (Globais (G), detalhes comuns (D), detalhes incomuns (Dd)), podendo ser enfatizado na resposta ou não (ex: Detalhe Comum combinado com espaço em branco (DS), Detalhe Comum combinado com espaço em branco enfatizado [SD]). O uso de espaços em branco nas combinações de respostas é interpretado como oposicionismo em relação a si mesmo ou ao mundo externo [Vaz & Alchieri, pp. 105, 106].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 26), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000, maxFeatures = 150),



Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 250, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 7, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 34 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Ansiedade Situacional*.

$(\Sigma S)$	<b>Distribuição de Classes: (low, 97), (mid, 210), high (56)</b>				
	<b>Acurácia</b>	<b>F1score</b>	<b>ROC</b>	<b>MAE</b>	<b>RMSE</b>
<b>ZeroR</b>	0.578	0.000	0.488	0.380	0.436
<b>IBK</b>	0.275	0.164	0.589	0.477	0.556
<b>Bayes</b>	0.581	0.559	0.600	0.351	0.450
<b>SMO</b>	0.597	<b>0.582</b>	0.689	0.321	0.428
<b>Logistic</b>	0.559	0.574	<b>0.747</b>	0.297	0.533
<b>Random Forest</b>	0.595	0.000	0.706	0.353	<b>0.414</b>
<b>InfoGain RF</b>	0.608	0.514	0.693	0.356	0.418
<b>GradientBoost</b>	<b>0.617</b>	0.558	0.682	<b>0.275</b>	0.454

**Tabela 34.** *Ansiedade Situacional.*

Analizando a tabela 34, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Logistic Regression, com uma AUC-ROC de 0.747. O classificador SMO obteve o maior F1score (0.582). O classificador Gradient Boost, obteve a maior acurácia (0.617) e o menor erro MAE (0.275). Finalmente, o classificador Random Forest, obteve o menor erro RMSE (0.414).

#### **8.6.17. Movimento Inanimado ((Fm), (mF), (m)): Conflito Intrapsíquico.**

O movimento inanimado possui uma relação com conflitos internos, difíceis de serem controlados. Estes conflitos são ocasionados entre afetos do mundo interno e valores socioculturais do mundo externo. Neste sentido, a necessidade de optar por um ou outro gera tensões que são projetadas nestes determinantes [Vaz & Alchieri, p. 110].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 1), Random Forest (numIterations = 1000, maxFeatures = 150), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 30, max\_features = 60). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 35 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Conflito Intrapsíquico*.

(Fm) ≥ ((mF) + (m))	Distribuição de Classes: (low, 50), (mid, 283), high (30)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.779	0.000	0.496	0.246	0.349
<b>IBK</b>	0.393	0.459	0.521	0.401	0.577
<b>Bayes</b>	0.754	0.683	0.520	0.289	0.375
<b>SMO</b>	0.749	0.743	0.758	0.188	0.349
<b>Logistic</b>	0.749	0.717	0.719	0.169	0.394
<b>Random Forest</b>	0.787	0.000	0.779	0.220	0.322
<b>InfoGain RF</b>	0.796	0.729	<b>0.791</b>	0.207	<b>0.318</b>
<b>GradientBoost</b>	<b>0.804</b>	<b>0.753</b>	0.770	<b>0.136</b>	0.334

**Tabela 35.** *Conflito Intrapsíquico*.

Analizando a tabela 35, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, combinado com a técnica de seleção de características InfoGain, com uma AUC-ROC de 0.791. Este classificador também obteve o menor erro RMSE (0.318). Finalmente, o classificador Gradient Boost, obteve o maior F1score (0.753), a melhor acurácia (0.804) e o menor erro MAE (0.136).

#### **8.6.18. Sombreado Radiológico ((Fk), (kF), (k)): Ansiedade e Adaptação Racional.**

O Sombreado Radiológico inclui percepções de conteúdos radiográficos, mapas geográficos ou negativos de fotos ou filmes. Estes determinantes têm relação com sentimentos desagradáveis da vida cotidiana das pessoas, possuindo uma sensibilidade mais específica para revelar como será o controle da ansiedade diante de acontecimentos novos, desconhecidos e que precisam ser superados [Vaz & Alchieri, pp. 65, 110, 111].

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 3), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 200, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 30, max\_features = 90). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 36 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Ansiedade e Adaptação Racional*.

(Fk) ≥ ([Kk) + (k))	Distribuição de Classes: (low, 14), (mid, 330), high (19)				
	Acurácia	F1score	ROC	MAE	RMSE
<b>ZeroR</b>	0.909	0.000	0.466	0.115	0.237
<b>IBK</b>	0.906	0.000	0.528	0.065	0.248
<b>Bayes</b>	<b>0.944</b>	0.943	0.910	0.237	0.297
<b>SMO</b>	0.939	0.939	0.996	0.038	0.161
<b>Logistic</b>	0.578	0.684	0.646	0.281	0.528
<b>Random Forest</b>	0.906	0.915	0.992	0.354	0.380
<b>InfoGain RF</b>	0.931	<b>0.936</b>	0.993	0.264	0.300
<b>GradientBoost</b>	0.936	0.923	<b>0.997</b>	<b>0.043</b>	<b>0.183</b>

**Tabela 36.** *Ansiedade e Adaptação Racional.*

Analizando a tabela 36, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Gradient Boost, com uma AUC-ROC de 0.997. Este classificador também obteve o menor erro MAE (0.043) e menor erro RMSE (0.183). O classificador Randm Forest, combinado com a técnica de seleção de características InfoGain, obteve o maior F1score (0.936). Finalmente, o classificador Bayes Net obteve a maior acurácia (0.944).

#### 8.6.19. Ressonância Interna (( $\Sigma M$ ) : ( $\Sigma C$ )).

A *ressonância interna* é um construto psicológico inferido através da relação entre percepções de movimento e cores. A *ressonância interna* utiliza fatores que eram valorizados por Hermann Rorschach [Rorschach, 1967] como fundamentais para a construção do seu método. No Z-Teste estas reduções fatoriais são chamadas de ressonância interna, que podem ser entendidas como a vivência do indivíduo [Vaz & Alchieri, 2016, p. 106 - 108]:

O movimento humano ( $\Sigma M$ ) é um determinante das funções integradoras da dimensão do mundo interno da personalidade. Já as cores em seu somatório ( $\Sigma C$ ) são os estímulos do impacto mobilizador do mundo interno da pessoa, provocando-lhe reações afetivo-emocionais, com as mais variadas repercussões na estrutura e funcionamento da personalidade. [Vaz & Alchieri, 2016, p. 107]

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 9), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 1000, maxFeatures = 200), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 300, numIterations = 1000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 11, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 37 descreve o balanceamento das classes e os resultados obtidos nos experimentos relativos à dimensão *Ressonância Interna*.

(( $\Sigma M$ ): ( $\Sigma C$ ))	<b>Distribuição de Classes: (Invovensivo, 149), (Extratensivo, 153), (Coartado, 22), (Coartativo, 25), (Ambigual, 14)</b>				
	<b>Acurácia</b>	<b>F1score</b>	<b>ROC</b>	<b>MAE</b>	<b>RMSE</b>
<b>ZeroR</b>	0.421	0.000	0.482	0.258	0.358
<b>IBK</b>	0.407	0.000	0.546	0.261	0.374
<b>Bayes</b>	0.495	0.000	0.562	0.272	0.364
<b>SMO</b>	0.440	0.440	0.669	0.222	0.359
<b>Logistic</b>	0.396	0.397	0.548	0.244	0.479
<b>Random Forest</b>	0.438	0.447	0.696	0.240	0.341
<b>InfoGain RF</b>	<b>0.495</b>	0.000	<b>0.700</b>	0.234	<b>0.340</b>
<b>GradientBoost</b>	0.493	<b>0.477</b>	0.691	<b>0.203</b>	0.375

**Tabela 37.** *Ressonância Interna.*

Analizando a tabela 37, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, combinado com a técnica de seleção de características InfoGain, com uma AUC-ROC de 0.70. Este classificador também obteve a melhor acurácia (0.495) e o menor erro RMSE (0.340). Finalmente, o classificador Gradient Boost, obteve o maior F1score (0.477) e o menor erro MAE (0.203).

#### **8.6.20. Discussão dos Resultados dos experimentos com o *corpus Z*-teste.**

Nesta seção iremos comparar todos os experimentos que realizamos com o corpus Z-teste. Para obter uma visão macro dos resultados, a tabela 38 ordena a avaliação dos resultados dos modelos detalhados nas seções de 8.3.1 até 8.3.19, em relação a métrica de avaliação de desempenho AUC-ROC. Utilizaremos nesta análise a curva ROC como medida principal de avaliação de desempenho, por ser uma medida mais adequada para avaliar dados desbalanceados, sendo este o caso de dados gerados por Z-scores. As outras medidas de avaliação de desempenho estão disponíveis como informação adicional, possibilitando verificar quais modelos convergiram melhor com base em cada medida.

Modelos Z-teste (19 Dimensões de Personalidade) - Ordenados por AUC-ROC											
Dimensão	Acurácia		F1score		AUC-ROC		MAE		RMSE		Classes
<b>(FK) ≥ ((KF) + (K))</b>	0.944	BN	0.936	IG+RF	0.997	GB	0.043	GB	0.183	GB	3
<b>(FM)</b>	0.936	RF	0.942	RF	0.990	RF	0.089	BN	0.247	GB	2
<b>(C)</b>	0.865	RF	0.858	BN	0.868	GB	0.135	BN	0.322	RF	2
<b>(ΣR)</b>	0.785	GB	0.740	GB	0.860	GB	0.156	GB	0.337	IG+RF	3
<b>(Dd)</b>	0.801	GB	0.794	LR	0.859	RF	0.139	GB	0.321	IG+RF	3
<b>(ΣF)</b>	0.782	IG+RF	0.731	IG+RF	0.852	GB	0.163	GB	0.330	IG+RF	3
<b>(G)</b>	0.801	SMO	0.801	SMO	0.829	IG+RF	0.148	GB	0.312	IG+RF	3
<b>(F+)</b>	0.746	GB	0.687	GB	0.823	GB	0.180	GB	0.359	IG+RF	3
<b>((H) + (Hd))</b>	0.771	GB	0.712	SMO	0.811	IG+RF	0.163	GB	0.335	IG+RF	3
<b>(FC) ≥ ((CF) + (C))</b>	0.732	GB	0.696	GB	0.810	GB	0.195	GB	0.377	IG+RF	3
<b>(D)</b>	0.752	GB	0.707	GB	0.804	RF	0.176	GB	0.355	IG+RF	3
<b>(Fc) ≥ ((cF) + (c))</b>	0.816	IG+RF	0.781	SMO	0.793	GB	0.142	GB	0.331	IG+RF	3
<b>(Fm) ≥ ((mF) + (m))</b>	0.804	GB	0.753	GB	0.791	IG+RF	0.136	GB	0.318	IG+RF	3
<b>(FC') ≥ ((CF') + (C'))</b>	0.793	RF	0.788	SMO	0.79	SMO	0.151	GB	0.322	IG+RF	3
<b>((A) + (Ad))</b>	0.677	GB	0.653	LR	0.773	GB	0.22	GB	0.385	IG+RF	3
<b>(FK) ≥ ((KF) + (K))</b>	0.719	IG+RF	0.659	LR	0.755	GB	0.194	GB	0.336	IG+RF	3
<b>(ΣS)</b>	0.617	GB	0.582	SMO	0.747	LR	0.275	GB	0.414	RF	3
<b>(ΣM)</b>	0.595	RF	0.567	LR	0.714	RF	0.279	GB	0.419	RF	3
<b>((ΣM): (ΣC))</b>	0.495	IG+RF	0.477	GB	0.7	IG+RF	0.203	GB	0.34	IG+RF	5
<b>Média / Moda</b>	0.760	GB	0.731	GB	0.809	GB	0.163	GB	0.329	IG+RF	2, 3, 5

**Tabela 38.** Modelos Z-teste (19 Dimensões de Personalidade). Ordenados por AUC-ROC.

Observando a tabela 38, verificamos os experimentos que produziram as melhores medidas de desempenho de acordo com as 19 dimensões de personalidade do Z-teste. Neste sentido os melhores modelos obtiveram uma média de 0.809, 0.731, 0.760, 0.163, 0.329 respectivamente para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE. Dentre os classificadores que os modelos utilizaram, de uma forma geral, os *ensembles* de classificadores Gradient Boost e Random Forest, foram os mais promissores. A técnica de seleção de características Information Gain combinada com o classificador Random Forest se mostrou promissora.

De acordo com a tabela 38, o modelo que obteve o melhor resultado utilizou o classificador Gradient Boost para prever a dimensão *Ansiedade e Adaptação Racional*  $(FK) \geq ((KF) + (K))$ , obtendo uma AUC-ROC de 0.997. É interessante ressaltar que na amostra do *corpus* Z-teste (n=363), este modelo possui 3 classes, sendo compatível com o padrão de Z-scores especificado no manual do Z-teste. Neste sentido, em relação aos Z-scores, das 19 dimensões de personalidade da amostra, apenas duas dimensões possuem redução de classes, devido ao bias da distribuição dos dados na amostra. Sendo assim, em uma amostra maior (n > 363) ou em uma amostra mais heterogênea (ex:

peças com diferentes níveis de escolaridade), possivelmente não ocorria este problema nestas dimensões.

Ainda de acordo com tabela 38, o modelo menos performático, foi o modelo que utilizou o classificador Random Forest para prever a dimensão Ressonância Interna, obtendo uma AUC-ROC de 0.70. Este é o único modelo que possui 5 classes, de acordo com o manual de aplicação do Z-teste, sendo que este modelo não teve classes suprimidas pela amostra. Neste sentido, para uma análise mais justa e detalhada, separamos os experimentos de acordo com o número de classes, ordenando todos eles através da métrica AUC-ROC em tabelas separadas. As tabelas 39, 40 e 41 separaram os experimentos de acordo com o número de classes.

EXPERIMENTOS COM 2 CLASSES – DIMENSÕES ENVIADAS PELA AMOSTRA											
Dimensão	Acurácia		F1score		AUC-ROC		MAE		RMSE		Classes
(FM)	0.936	RF	0.942	RF	0.990	RF	0.089	BN	0.247	GB	2
(C)	0.865	RF	0.858	BN	0.868	GB	0.135	BN	0.322	RF	2
<b>Média / Moda</b>	0.900	RF	0.858	*	0.868	*	0.135	BN	0.322	*	2

**Tabela 39.** Modelos Z-teste com dimensões enviesadas pela amostra. Ordenados por AUC-ROC.

Analisando a tabela 39, notamos que o modelo que utilizou o classificador Random Forest, com o objetivo de prever a dimensão *Impulsividade e Dinamismo* (FM), teve melhor performance entre os modelos de 2 classes, obtendo uma AUC-ROC de 0.990. Este é o segundo classificador com a melhor performance em geral de acordo com a tabela 38. Ainda segundo a tabela, o modelo que utilizou Gradient Boost para prever a dimensão *Tendência à Reação Emocional Intensa* (C), obteve uma performance um pouco menor, mas mesmo assim bastante satisfatória, obtendo um AUC-ROC de 0.868. De uma forma geral, este foi o terceiro modelo com a melhor performance segundo a tabela 38. Os modelos de 2 classes obtiveram uma AUC-ROC média de 0.868. Esta média está acima da média AUC-ROC relativa a todos experimentos (0.809) que pode ser observada na tabela 38. O fato mais significativo desta análise, é que um dos experimentos obteve uma AUC-ROC quase perfeita (0.990), confirmando os *insights* que tivemos em nossa motivação (seção 1.6), no sentido de que quando a técnica dos Z-Scores é aplicada em uma amostra que não possui todas as dimensões das escalas originais de personalidade, é possível que o modelo esteja com *overfitting*.

A tabela 40 descreve os melhores resultados do único conjunto de experimentos que realizamos com 5 classes (A *Ressonância Interna* é a única dimensão que possui 5 classes no z-teste).

EXPERIMENTO COM 5 CLASSES – ESCALA ORIGINAL DO Z-TESTE											
Dimensão	Acurácia		F1score		AUC-ROC		MAE		RMSE		Classes
(( $\Sigma$ M): ( $\Sigma$ C))	0.495	IG+RF	0.477	GB	0.700	IG+RF	0.203	GB	0.340	IG+RF	5

**Tabela 40.** Modelo Z-teste que possui 5 classes.

Analizando a tabela 40, notamos que o modelo que utilizou o classificador Random Forest, combinado com a técnica de seleção de características Information Gain, com o objetivo de prever a classe *Ressonância Interna*, obteve uma AUC-ROC de 0.70. Podemos verificar que neste experimento de 5 classes, que a AUC-ROC deste modelo é consideravelmente menor que os demais experimentos, confirmando os *insights* que tivemos na seção 1.6, no sentido de que quanto mais complexo for o problema da personalidade, no sentido de utilizar mais classes para descrever uma dimensão de personalidade, mais difícil será prever a personalidade automaticamente.

Finalmente a tabela 41 ordena os experimentos mais promissores de 3 e 5 classes, que não tiveram as escalas de personalidade enviesadas pela amostra.

EXPERIMENTOS COM 3 CLASSES E 5 CLASSES											
Dimensão	Acurácia		F1score		AUC-ROC		MAE		RMSE		Classes
((FK) $\geq$ ((KF) + (K)))	0.944	BN	0.936	IG+RF	0.997	GB	0.043	GB	0.183	GB	3
( $\Sigma$ R)	0.785	GB	0.740	GB	0.860	GB	0.156	GB	0.337	IG+RF	3
(Dd)	0.801	GB	0.794	LR	0.859	RF	0.139	GB	0.321	IG+RF	3
( $\Sigma$ F)	0.782	IG+RF	0.731	IG+RF	0.852	GB	0.163	GB	0.330	IG+RF	3
(G)	0.801	SMO	0.801	SMO	0.829	IG+RF	0.148	GB	0.312	IG+RF	3
(F+)	0.746	GB	0.687	GB	0.823	GB	0.180	GB	0.359	IG+RF	3
((H) + (Hd))	0.771	GB	0.712	SMO	0.811	IG+RF	0.163	GB	0.335	IG+RF	3
((FC) $\geq$ ((CF) + (C)))	0.732	GB	0.696	GB	0.810	GB	0.195	GB	0.377	IG+RF	3
(D)	0.752	GB	0.707	GB	0.804	RF	0.176	GB	0.355	IG+RF	3
((Fc) $\geq$ ((cF) + (c)))	0.816	IG+RF	0.781	SMO	0.793	GB	0.142	GB	0.331	IG+RF	3
((Fm) $\geq$ ((mF) + (m)))	0.804	GB	0.753	GB	0.791	IG+RF	0.136	GB	0.318	IG+RF	3
((FC') $\geq$ ((CF') + (C'))	0.793	RF	0.788	SMO	0.79	SMO	0.151	GB	0.322	IG+RF	3
((A) + (Ad))	0.677	GB	0.653	LR	0.773	GB	0.22	GB	0.385	IG+RF	3
((FK) $\geq$ ((KF) + (K)))	0.719	IG+RF	0.659	LR	0.755	GB	0.194	GB	0.336	IG+RF	3
( $\Sigma$ S)	0.617	GB	0.582	SMO	0.747	LR	0.275	GB	0.414	RF	3
( $\Sigma$ M)	0.595	RF	0.567	LR	0.714	RF	0.279	GB	0.419	RF	3
(( $\Sigma$ M): ( $\Sigma$ C))	0.495	IG+RF	0.477	GB	0.700	IG+RF	0.203	GB	0.340	IG+RF	5
Média / Moda	0.748	GB	0.720	GB	0.804	GB	0.166	GB	0.329	IG+RF	3, 5
Média / Moda (3)	0.769	GB	0.742	GB	0.814	GB	0.162	GB	0.328	IG+RF	3

**Tabela 41.** Modelos Z-teste que não tiveram as dimensões enviesadas pela amostra. Ordenados por AUC-ROC.

Analisando a tabela 41, podemos comparar o desempenho dos modelos com 3 e com 5 classes que não tiveram as escalas de personalidade enviesadas, totalizando 17 dimensões que são compatíveis com as escalas das dimensões de personalidade inferidas por Z-scores. Os modelos de 3 classes obtiveram um desempenho médio relativo as 16 dimensões de personalidade de 0.814, 0.742, 0.769, 0.162, 0.328, respectivamente para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE. Já o conjunto de todos os modelos que não foram enviesados pela amostra possuindo 3 e 5 classes, obtiveram um desempenho médio relativo às 17 dimensões de personalidade de 0.804, 0.720, 0.748, 0.166 e 0.329, respectivamente para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE. A próxima seção irá relatar os experimentos com o corpus TAT.

## 8.7 Experimentos com o Corpus TAT.

Nesta seção iremos comentar os experimentos realizados com o corpus TAT. Os detalhes do processo de coleta textual, extração de características textuais e coleta dos scores de personalidade deste *corpus* está detalhado nas seções 7.2, 8.1, 8.2. A tabela 42 resume os detalhes deste corpus.

CORPUS TAT	
Total de participantes	100
Masculino	50
Feminino	50
Idades min – max	25 - 44 anos
Tipo de texto / quantidade	Histórias / 2000
Número de palavras	266.578
Número de dimensões (traços de personalidade)	6
Número de classes por (dimensão)	3(todas as dimensões)

**Tabela 42.** Detalhes do corpus TAT.

A seção 7.2.1 descreve com detalhes a metodologia utilizada para definir as 3 classes por dimensão. Esta metodologia foi necessária porque no sistema de quitação MS [Sacuduto, 2016] para o TAT são utilizados 20 cartões, que funcionam como estímulo para que o examinando conte histórias. Sendo assim cada examinando conta uma história por cartão, totalizando 20 histórias, que depois serão avaliadas individualmente e cotadas no sistema de escalas de personalidade MS. Neste sentido, para obter uma escala única, mais significativa da personalidade em cada dimensão e para



obter uma quantidade adequada de textos para os modelos de TB-APR (apenas uma história seria insuficiente), utilizamos a moda das escalas de personalidade nos 20 cartões. Neste sentido a moda capturou a tendência geral da personalidade de cada indivíduo em cada escala, sendo possível concatenar todas as histórias para cada indivíduo, obtendo uma quantidade de textos adequada.

A metodologia que propomos permitiu utilizar este *corpus* para o reconhecimento automático de personalidade, mas ela também introduziu diversos problemas em relação as escalas de personalidade. Neste sentido, todas as 17 escalas originais de personalidade do sistema MS ficaram enviesadas, porque após aplicar a moda, a amostra não contém todas as classes referentes as escalas de personalidade que o sistema MS descreve. O balanceamento do corpus após a aplicação da moda, em relação as escalas de personalidade, está detalhado na seção 7.2.1. Para endereçar o problema do desbalanceamento de classes, foi utilizada uma metodologia de seleção de dimensões, onde foram adicionados critérios de exclusão. Após a aplicação destes critérios, restaram 6 dimensões com 3 classes cada. A próximas seções vão comentar os experimentos com o TAT.

### 8.7.1 Autonomia Para a Tarefa

A dimensão *Autonomia para a Tarefa*, o sistema MS considera que quanto menor for o número de intervenções do aplicador, melhor é a capacidade de autonomia do examinando para realizar tarefas de forma geral. Neste sentido, a escala desta dimensão verifica a autonomia do examinando em relação as intervenções realizadas pelo aplicador. A dimensão *Autonomia Para a Tarefa* possui a seguinte escala de avaliação da personalidade:

- (0) O examinando recusou o cartão / não contou história.
- (1) Muitas intervenções foram necessárias (>3).
- (2) Poucas intervenções foram necessárias (<=3).
- (3) Nenhuma intervenção foi necessária.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 15), Random Forest (numIterations = 2000, maxFeatures = 300), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 350, numIterations = 2000, maxFeatures = 200), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 10, max\_features = 300). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 43 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Autonomia para a Tarefa*.

Autonomia para a tarefa	Distribuição de Classes: (1, 26), (2, 51), (3, 23)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.510	0.000	0.461	0.414	0.454
IBK	0.490	0.478	0.659	0.385	0.444
Bayes	0.670	0.669	0.819	<b>0.217</b>	0.452
SMO	0.710	0.707	0.797	0.288	0.375
Logistic	0.610	0.604	0.781	0.266	0.505
Random Forest	0.760	0.756	<b>0.888</b>	0.305	0.364
InfoGain RF	<b>0.770</b>	<b>0.768</b>	0.886	0.280	<b>0.352</b>
GradientBoost	0.710	0.705	0.838	0.226	0.391

**Tabela 43.** Autonomia para a Tarefa.

Analizando a tabela 43, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Random Forest, obtendo uma curva AUC-ROC de 0.888. Este classificador, ao ser combinado com a técnica de seleção de características Info Gain, obteve o maior F1score (0.768), a maior acurácia (0.770) e o menor erro RMSE (0.352). Finalmente, o classificador Bayes Net, obteve o menor erro MAE (0.217).

### 8.7.2 Atendimento às Instruções

A dimensão *Atendimento às Intruções*, verifica se todos os elementos estão presentes na história, desta maneira, quanto mais elementos estiverem presentes, mais favorável é a capacidade de concentração do examinando, em relação a seguir instruções de uma forma geral. Neste sentido a escala desta dimensão verifica se os elementos solicitados, tais como, passado, presente, desfecho, pensamento e sentimentos do herói estão presentes na história. A dimensão *Atendimento às Instruções* possui a seguinte escala de avaliação da personalidade:

- (0) Faltam todos os elementos (ex: mera descrição do cartão, recusa do cartão).
- (1) Foram suprimidos quatro elementos solicitados.
- (2) Foram suprimidos três elementos solicitados.
- (3) Foram suprimidos dois elementos solcicitados.
- (4) Foi suprimido um elemento solicitado.
- (5) A história possui todos os elementos solicitados.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 3$ ), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 2000, maxFeatures = 200), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 75, numIterations = 2000), Gradient Boost (n\_estimators = 1000, max\_depth = 3,

min\_samples\_split = 2, min\_samples\_leaf = 30, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 44 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Atendimento às Instruções*.

Atendimento às Instruções	Distribuição de Classes: (3, 3), (4, 38), (5, 59)				
	Acurácia	F1score	ROC	MAE	RMSE
ZeroR	0.590	0.000	0.465	0.341	0.411
IBK	0.600	0.583	0.672	0.285	0.397
Bayes	<b>0.710</b>	<b>0.715</b>	<b>0.807</b>	<b>0.206</b>	0.385
SMO	0.710	0.000	0.700	0.293	0.381
Logistic	0.660	0.652	0.670	0.266	0.427
Random Forest	0.700	0.000	0.786	0.284	0.370
InfoGain RF	0.700	0.695	0.781	0.266	<b>0.366</b>
GradientBoost	0.690	0.000	0.781	0.211	0.408

**Tabela 44.** *Atendimento às Instruções.*

Analizando a tabela 44, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o Bayes Net, obtendo uma curva AUC-ROC de 0.807. Este classificador também obteve o maior F1score (0.715), a maior acurácia (0.710) e o menor erro MAE (0.206). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.366).

### 8.7.3 Complexidade do Herói

A dimensão *Complexidade do Herói* fornece pistas de como a percepção do examinando funciona em relação a si mesmo e às outras pessoas. Quanto maior a *Complexidade do Herói*, mais desenvolvida é a capacidade de percepção, relacionada a cognição e afetos. Neste sentido a escala desta dimensão verifica o grau de presença com que características do herói aparecem. A dimensão *Complexidade do Herói* possui a seguinte escala de avaliação da personalidade:

- (0) Sem descrição, nenhuma característica.
- (1) Descrição superficial, apenas uma característica, do pensamento ou sentimento do herói.
- (2) Descrição pouco articulada, poucas características, com apenas um pensamento ou sentimento do herói.
- (3) Descrição dinâmica, diversas características, dos pensamentos e sentimentos do herói.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 4), Random Forest (numIterations = 2000, maxFeatures = 140), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 400, numIterations = 2000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 11, max\_features = 30). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 45 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Complexidade do Herói*.

Complexidade Do Herói	Distribuição de Classes: (1, 3), (2, 52), (3, 45)				
	ACC	F1Score	ROC	MAE	RMSE
<b>ZeroR</b>	0.532	0.000	0.450	0.354	0.419
<b>IBK</b>	<b>0.650</b>	<b>0.643</b>	<b>0.703</b>	0.284	0.412
<b>Bayes</b>	0.620	0.621	0.666	0.262	0.470
<b>SMO</b>	0.620	0.000	0.623	0.315	0.409
<b>Logistic</b>	0.530	0.519	0.584	0.303	0.521
<b>Random Forest</b>	0.630	0.000	0.701	0.317	0.396
<b>InfoGain RF</b>	0.640	0.000	0.699	0.315	<b>0.396</b>
<b>GradientBoost</b>	0.620	0.000	0.680	<b>0.261</b>	0.461

**Tabela 45.** *Complexidade do Herói.*

Analizando a tabela 45, verificamos que todos os classificadores obtiveram uma AUC-ROC melhor que o baseline ZeroR. O classificador que obteve o melhor resultado foi o IBK, obtendo uma curva AUC-ROC de 0.703. Este classificador também obteve a maior acurácia (0.650) e o maior F1score (0.643). O classificador Gradient Boost obteve o menor erro MAE (0.261). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características InfoGain, obteve o menor erro RMSE (0.396).

#### 8.7.4 Complexidade Temporal

A *Complexidade Temporal* é uma dimensão relacionanda à ordem de tempo dos acontecimentos das histórias, permitindo acesso à dimensão lógica e ao controle do processo criativo e perceptivo. Neste sentido, os indivíduos irão contar histórias organizadas ou desorganizadas, de acordo com a organização ou desorganização de seus estados internos, permitindo verificar o nível de funcionamento cognitivo, ou seja, a forma com que a realidade é percebida. Neste sentido a escala desta dimensão verifica se os elementos da história estão arranjados, em termos da ordem de apresentação e a lógica de suas interrelações. A dimensão *Complexidade Temporal* possui a seguinte escala de personalidade:

- (0) Sem ordem temporal ou recusa do cartão.
- (1) Ilógica, ausência de interrelação entre os eventos ou relação confusa.
- (2) Incompleta, ausência de um dos elementos temporais (início, meio e fim da história).
- (3) Literal às instruções, os acontecimentos são narrados de acordo com as instruções do TAT. Esta classe é marcada quando muitas intervenções são realizadas pelo examinador.
- (4) Lógica, inclui a escala (3); mas apresentando oscilações de ordem, ou seja, ocorrendo explicações casuais no meio da história, remetendo ao começo da mesma, sem alterar a ordem lógica dos eventos.
- (5) Lógica e Dinâmica, inclui a escala (4); adiciona novos acontecimentos, sentimentos e pensamentos dos personagens em relação aos mesmos e suas mudanças ao longo dos eventos, tornando a história mais complexa e interligada.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 22), Bayes Net (estimator = BMAEstimator), Random Forest (numIterations = 2000, maxFeatures = 450), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 25, numIterations = 2000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 11, max\_features = 300). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 46 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Complexidade Temporal*.

Complexidade Temporal	Distribuição de Classes: (2, 6), (3, 33), (4, 61)				
	ACC	F1Score	ROC	MAE	RMSE
<b>ZeroR</b>	0.610	0.000	0.460	0.347	0.415
<b>IBK</b>	0.770	0.767	0.873	0.236	0.334
<b>Bayes</b>	0.80	0.801	0.896	0.125	0.332
<b>SMO</b>	0.760	0.742	0.756	0.286	0.372
<b>Logistic</b>	0.730	0.000	0.804	0.184	0.418
<b>Random Forest</b>	0.830	0.826	0.914	0.204	0.295
<b>InfoGain RF</b>	<b>0.880</b>	<b>0.880</b>	<b>0.933</b>	0.167	<b>0.266</b>
<b>GradientBoost</b>	0.840	0.841	0.916	<b>0.121</b>	0.288

**Tabela 46.** *Complexidade Temporal.*

Analisando a tabela 46, notamos que todos os classificadores obtiveram uma AUC-ROC maior que o baseline (ZeroR). O melhor classificador foi o Random Forest, quando combinado com a técnica de seleção de características InfoGain, obtendo uma AUC-ROC de 0.933. Este classificador também obteve a maior acurácia (0.880), o maior F1score (0.880) e o menor erro RMSE (0.266). Finalmente, o classificador Gradient Boost obteve o menor erro MAE (0.121).

### 8.7.5 Pressão do Ambiente

A dimensão *Pressão do Ambiente* está relacionada com a expectativa do examinando. O ambiente nas histórias pode ser entendido como um processo de projeção, referente às pessoas e às condições externas do ambiente em que o examinando está inserido. Em outras palavras, o ambiente da história possibilita uma interpretação, em relação ao otimismo ou pessimismo, referente a situações gerais, envolvendo os outros e as diversas circunstâncias. Neste sentido, esta dimensão verifica se o ambiente facilita ou dificulta o cumprimento da necessidade do herói. A dimensão *Pressão do Ambiente* possui a seguinte escala de personalidade:

- (-1) Pressão negativa do ambiente sobre a necessidade do herói.
- (0) Nenhuma pressão do ambiente sobre a necessidade do herói.
- (1) Pressão positiva do ambiente sobre a necessidade do herói.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK ( $k = 4$ ), Random Forest ( $\text{numIterations} = 2000$ ,  $\text{maxFeatures} = 300$ ), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker  $\text{numToSelect} = 50$ ,  $\text{numIterations} = 2000$ ), Gradient Boost ( $\text{n\_estimators} = 1000$ ,  $\text{max\_depth} = 5$ ,  $\text{min\_samples\_split} = 2$ ,  $\text{min\_samples\_leaf} = 11$ ,  $\text{max\_features} = 100$ ). Os demais classificadores utilizaram os parâmetros padrão do Weka.

A tabela 47 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Pressão do Ambiente*.

Pressão do Ambiente	Distribuição de Classes: (-1, 80), (0, 1), (1, 19)				
	ACC	F1Score	ROC	MAE	RMSE
ZeroR	0.800	0.000	0.490	0.223	0.328
IBK	0.780	0.000	0.797	0.271	0.344
Bayes	0.810	<b>0.816</b>	0.869	0.143	0.347
SMO	0.800	0.000	0.538	0.268	0.347
Logistic	0.820	0.000	0.619	0.125	0.344
Random Forest	<b>0.860</b>	0.000	<b>0.902</b>	0.164	0.274
InfoGain RF	0.860	0.000	0.889	0.142	<b>0.273</b>
GradientBoost	0.820	0.000	0.896	<b>0.111</b>	0.306

**Tabela 47.** Pressão do Ambiente.

Analisando a tabela 47, notamos que todos os classificadores obtiveram uma AUC-ROC maior que o baseline (ZeroR). O melhor classificador foi o Random Forest, quando combinado com a técnica de seleção de características InfoGain, obtendo uma AUC-ROC de 0.902. Este classificador também obteve a maior acurácia (0.860). O Classificador Bayes Net obteve o maior F1score (0.816). O classificador Gradient Boost obteve o menor erro RMSE (0.273). Finalmente, o classificador Random Forest, combinado com a técnica de seleção de características Info Gain, obteve o menor erro MAE (0.111).

### 8.7.6 Qualidade Geral da História

A dimensão *Qualidade Geral da História* se refere a um julgamento de três dimensões agregadas: (i) *Qualidade da Linguagem*, (ii) *Complexidade Temporal* e (iii) *Integração Narrativa*. Neste sentido, esta dimensão avalia a capacidade do examinando em produzir uma história com qualidade literária. A dimensão *Qualidade Geral da História* possui a seguinte escala de personalidade:

- (1) História Confusa ou Desordenada; possui presença de falhas lógicas ou pouca integração entre os elementos. Narrativas de difícil compreensão ou de baixa organização.
- (2) História Superficial; apesar da presença de todos ou quase todos os elementos e de uma certa organização, o nível de detalhamento é baixo.
- (3) História organizada; narrativa com coerência e interligação entre os elementos, incluindo detalhes sobre os personagens e suas reações.

(4) História rica; grande quantidade de detalhes com suas interrelações, lembrando uma narrativa literária tal como um conto ou fábula.

Neste modelo, os seguintes classificadores tiveram ajustes de parâmetros: IBK (k = 21), Random Forest (numIterations = 2000, maxFeatures = 150), Random Forest combinado com a técnica de seleção de características InfoGain (IG Ranker numToSelect = 50, numIterations = 2000), Gradient Boost (n\_estimators = 1000, max\_depth = 5, min\_samples\_split = 2, min\_samples\_leaf = 11, max\_features = 400). Os demais classificadores utilizaram os parâmetros padrão do weka.

A tabela 48 mostra o balanceamento das classes e os experimentos realizados para a dimensão *Qualidade Geral da História*.

Qualidade Geral Da História	Distribuição de Classes: (2, 46), (3, 48), (4, 6)				
	ACC	F1Score	ROC	MAE	RMSE
<b>ZeroR</b>	0.480	0.000	0.450	0.372	0.430
<b>IBK</b>	0.720	0.701	0.842	0.289	0.361
<b>Bayes</b>	<b>0.810</b>	<b>0.809</b>	0.875	<b>0.126</b>	0.353
<b>SMO</b>	0.730	0.712	0.780	0.284	0.369
<b>Logistic</b>	0.660	0.661	0.749	0.228	0.465
<b>Random Forest</b>	0.780	0.780	0.887	0.247	0.327
<b>InfoGain RF</b>	0.800	0.800	<b>0.890</b>	0.211	<b>0.309</b>
<b>GradientBoost</b>	0.780	0.780	0.890	0.142	0.334

**Tabela 48.** *Qualidade Geral da História.*

Analisando a tabela 48, notamos que todos os classificadores obtiveram uma AUC-ROC maior que o baseline (ZeroR). O melhor classificador foi o Random Forest, quando combinado com a técnica de seleção de características InfoGain, obtendo uma AUC-ROC de 0.890. O Classificador Bayes Net obteve o maior F1score (0.816), a maior acurácia (0.810) e o menor erro MAE (0.126). Finalmente, o classificador Gradient Boost obteve o menor erro RMSE (0.309).

### 8.7.7 Discussão dos experimentos com o corpus TAT.

Nesta seção, iremos comparar todos os experimentos que realizamos com o *corpus* TAT. Para obter uma visão macro destes experimentos, a tabela 49 detalha o desbalanceamento das classes do *corpus* TAT.



Dimensão TAT	Desbalanceamento	Escala MS
Complexidade Temporal	(2, 6), (3, 33), (4, 61)	"0,1,2,3,4,5"
Pressão do Ambiente	(-1, 80), (0, 1), (1, 19)	"-1, 0, 1"
Qualidade Geral da História	(2, 46), (3, 48), (4, 6)	"1,2,3, 4"
Autonomia para a Tarefa	(1, 26), (2, 51), (3, 23)	"0, 1, 2, 3"
Atendimento às Instruções	(3, 3), (4, 38), (5, 59)	"0,1,2,3,4,5"
Complexidade do Herói	(1, 3), (2, 52), (3, 45)	"0,1,2,3"

**Tabela 49.** Desbalanceamento de classes do corpus TAT.

A metodologia que propomos para construir o *corpus* TAT utilizou a moda das escalas. Neste sentido, obteve-se, para cada dimensão, a classe que possui a maior frequência entre a avaliação de cada uma das 20 histórias no sistema MS. Esta metodologia agravou o problema do desbalanceamento de escalas em várias dimensões da personalidade. Como a amostra deste corpus é muito pequena (n=100), foi necessário estabelecer um critério de exclusão para dimensões com um desbalanceamento severo. O critério de exclusão de dimensões está detalhado na seção 7.2.1. Analisando a tabela 49, entre todas as dimensões, a única que manteve o mesmo número de classes em relação às escalas originais, foi a dimensão *Pressão do Ambiente*, entretanto ela possui um desbalanceamento severo em relação a uma das classes, com apenas 1 instância para a classe 0.

A tabela 50 detalha os resultados dos modelos do corpus TAT mais promissores para cada dimensão de personalidade, ordenados pela métrica AUC-ROC, que é a métrica mais adequada para avaliar dados desbalanceados.

EXPERIMENTOS CORPUS TAT COM DIMENSÕES DE 3 CLASSES										
Dimensão TAT	ACC		F1Score		ROC		MAE		RMSE	
Complexidade Temporal	0.880	IF+RF	0.880	IF+RF	0.933	IF+RF	0.121	GB	0.266	IG+RF
Pressão do Ambiente	0.860	RF	0.816	BN	0.902	RF	0.111	GB	0.273	IG+RF
Qualidade Geral da História	0.810	BN	0.809	BN	0.890	IF+RF	0.126	BN	0.309	IG+RF
Autonomia para a Tarefa	0.770	IF+RF	0.768	IF+RF	0.888	RF	0.217	BN	0.353	IG+RF
Atendimento às Instruções	0.710	BN	0.715	BN	0.807	BN	0.206	BN	0.336	IG+RF
Complexidade do Herói	0.650	IBK	0.643	IBK	0.703	IBK	0.261	GB	0.396	IG+RF
Média / Moda	0.780	IF+RF	0.772	BN	0.854	IF+RF	0.174	GB	0.322	IG+RF

**Tabela 50.** Experimentos do corpus TAT com dimensões de 3 classes.

Ressaltamos que todos os experimentos relatados nessa discussão possuem 3 classes. Analisando a tabela 50, podemos verificar que o modelo mais performático, foi o que utilizou o

classificador Random Forest, em conjunto com a técnica de seleção de características InfoGain, para prever a dimensão *Complexidade Temporal*, obtendo uma AUC-ROC de 0.933. É relevante ressaltar que esse modelo também obteve o maior F1score (0.880), maior acurácia e o menor erro RMSE (0.266) entre todos os modelos mais performáticos. Os modelos obtiveram um desempenho médio relativo as 6 dimensões de personalidade de 0.854, 0.772, 0.780, 0.174 e 0.322, respectivamente para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE. A próxima seção apresenta uma discussão geral dos experimentos.

## 8.8. Discussão Geral de todos os Experimentos.

Reservamos essa seção para apresentar uma discussão final dos experimentos. Observando as tabelas dos experimentos específicos de cada dimensão de personalidade, notamos que todas as dimensões possuem desbalanceamentos de classes. As escalas dimensionais das técnicas projetivas não foram concebidas para serem balanceadas, pois elas foram formuladas para quantificar e qualificar a personalidade humana em cada dimensão. Sendo assim, é esperado que nestas dimensões existam classes minoritárias, que normalmente representam os limites inferiores e superiores das dimensões. Neste sentido, podemos fazer as seguintes observações em relação aos *corpora* construídos nesta tese:

1. Corpus Z-teste: A avaliação dos scores de personalidade do Z-teste [Vaz & Alchieri, 2016] utilizou em 18 dimensões a escala de Z-scores. A Ressonância Interna utilizou outra metodologia. Sendo assim, é natural que para estas escalas (baseadas em Z-scores), a classe mid possua tendência a ser a classe majoritária, e que as classes low e high, possuam a tendência de serem as classes minoritárias. Neste *corpus*, foi possível trabalhar com todas as 19 dimensões de personalidade, sendo que em relação a amostra (n=363), apenas 2 dimensões tiveram algum enviesamento, no sentido de ter uma classe suprimida.
2. Corpus TAT: A avaliação dos scores de personalidade utilizou uma escala derivada da metodologia poposta por Alessandro Scaduto (2016). Para ser possível trabalhar com este *corpus*, foi necessário fazer o cálculo da moda, que agravou o problema de desbalanceamento de classes. Como este *corpus* possui um número muito pequeno de exemplos (n=100), foi estabelecido um critério de exclusão de dimensões. Neste sentido, das 17 dimensões do sistema MS, foram descartadas 11 dimensões, restando 6 dimensões para a construção dos

modelos. Destas dimensões, apenas uma não teve o enviesamento de ter alguma classe suprimida.

Na revisão da literatura sobre TB-APR, encontramos apenas trabalhos que utilizam inventários de personalidade [Vinciarelli & Mohammadi, 2014]; [Celli et al, 2016]; [Karanatsiou et. al, 2020]. Estes trabalhos constroem modelos de TB-APR que utilizam regressão e classificação. Os modelos de regressão possuem correlações fracas, que raramente excedem 0.4 [Golbeck et. al, 2011]; [Park et. al, 2015] ou coeficientes de determinação que não passam de 0.15 [Gill et. al, 2002]; [Oberlander & Gill, 2004]. Alguns trabalhos de regressão mais antigos possuíam erros relativos acima entre 0.93 e 1.00 [Mairesse et. al, 2007], entretanto, alguns modelos parecem ter evoluído em relação a esta métrica, com os mais recentes obtendo erros de RMSE menores 0.20 [Karanatsiou et. al, 2020]; [Celli et al, 2016], entretanto, estes trabalhos não informam outra métrica além do erro, não sendo possível comparar os resultados com trabalhos que utilizam outras métricas de desempenho, como a correlação de Pearson. Trabalhos de classificação podem possuir overfitting, conforme explicado na motivação desta tese [Oberlander & Nowson, 2006]; [Minamikawa & Yokoyama, 2011], produzindo acurácias de até 100%. Este enviesamento ocorre devido ao fato do modelo tratar as escalas de personalidade de forma ingênua, utilizando o paradigma da classificação binária. Finalmente, trabalhos de classificação com uma década de diferença, utilizando um mesmo corpus e a mesma medida de avaliação de desempenho, não possuem ganhos significativos de desempenho, mesmo com o trabalho mais recente, utilizando o estado da arte em classificadores (*deep learning*) [Mairesse, 2007]; [Majumder et. al, 2017].

Em geral, os modelos produzidos nesse trabalho obtiveram um desempenho médio relativo às 25 dimensões de personalidade de 0.831, 0.726, 0.770, 0.167 e 0.325, respectivamente, para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE. Apesar das medidas de erro serem baixas, notamos o erro RMSE foi maior que o erro MAE em nossos experimentos, isso pode ser devido ao fato de termos algum *outlier* em nossas amostras. De forma geral, os *ensembles* de classificadores Gradient Boost e Random Forest foram os mais efetivos. A técnica de seleção de características Info Gain se mostrou bastante útil, quando combinada com o classificador Random Forest. Os experimentos realizados neste capítulo produziram resultados promissores, não apenas em relação às métricas de avaliação de desempenho, mas também no sentido de serem modelos que exploram técnicas projetivas de acesso personalidade e possuem dimensões inéditas que ainda não foram analisadas pela comunidade de TB-APR.

É interessante ressaltar que estes modelos foram construídos utilizando uma quantidade pequena de textos, mas mesmo assim, foi possível reconhecer a personalidade com uma AUC-ROC

média acima de 83% em relação às 25 dimensões de personalidade analisadas. Neste sentido, acreditamos que a metodologia que propomos na seção 7.1.5 para a coleta textual, teve uma importância fundamental para a generalização dos modelos. O resultado mais gratificante destes experimentos, certamente é em relação aos 17 modelos do Z-teste que não tiveram enviesamento de dimensões, obtendo um desempenho médio de 0.809, 0.731, 0.760, 0.163 e 0.329 para as métricas AUC-ROC, F1score, Acurácia, MAE e RMSE respectivamente.

Apesar dos resultados serem animadores, comparar diretamente nossos modelos com os modelos do estado da arte de TB-APR não é possível, pois além de utilizarmos dois *corpus* inéditos construídos através da metodologia detalhada no capítulo 7, inferimos automaticamente dimensões de personalidade ainda não exploradas. Neste sentido, estudamos formas de anonimizar os *corpora* utilizados nesta tese, para que a comunidade científica desenvolva experimentos de TB-APR no futuro. Na próxima seção a conclusão geral desta tese será apresentada.

## 9 Conclusão geral

Ao nosso conhecimento, todos trabalhos que constroem modelos de TB-APR utilizam inventários de personalidade (Capítulo 7). Pennebaker e King, em 1999, marcaram historicamente a computação afetiva [Pennebaker & King, 1999]. Estes autores não se propuseram a construir modelos de TB-APR, mas procuravam aferir a confiabilidade do léxico LIWC [Pennebaker & King, 2015], sendo esta uma das ferramentas mais comuns de acesso à linguagem que os trabalhos de TB-APR utilizam [Vinciarelli & Mohammadi, 2014]. Neste sentido, os autores utilizaram diversas métricas, além de técnicas de aferição da personalidade para correlacionar separadamente com cada dimensão proposta pelo LIWC. É interessante ressaltar que, para verificar a confiabilidade de cada dimensão do léxico, além de utilizar inventários de personalidade, os autores utilizaram um pequeno *corpus* de histórias rotuladas pela técnica projetiva TAT [Murray, 1943/2005] (n=79), utilizando um sistema de avaliação da personalidade chamado de “*Scores Motives*”, que possui 3 dimensões de personalidade: “(i) *Need for Achievement*, *Need for Affiliation* (ii), *Need for Power*(iii)” [Winter,1989]. Na análise individual das dimensões do LIWC, apenas correlações fracas foram obtidas, com o melhor resultado sendo uma correlação de -0.33, referente à correlação da dimensão *Need for Achievement* do TAT em relação à dimensão *Immediacy* do LIWC. Analisando as 4 melhores correlações de dimensões do LIWC com *Need for Achievement* do TAT, os autores fatorizaram uma nova dimensão composta,

chamada de “*Achievement Motive*”, específica para se correlacionar com *Need for Achievement* do TAT, obtendo uma correlação de 0.44 (fraca).

Apesar deste trabalho [Pennebaker e King, 1999] utilizar uma técnica projetiva para medir a confiabilidade de um léxico e permitir *insights* para sua melhoria, e mesmo com este léxico sendo amplamente utilizado em TB-APR, nenhum trabalho de TB-APR utiliza técnicas projetivas. O principal motivo para isso, é que as técnicas projetivas demandam um conhecimento maior do aplicador da técnica, necessitando ser um psicólogo que se especializou na técnica projetiva específica que será aplicada. Apesar de não construir modelos de TB-APR, o trabalho de Pennebaker e King (1999) foi extremamente importante para esta tese, possibilitando o *insight* de pesquisar sobre as técnicas projetivas e aprofundar as pesquisas em teorias psicológicas, não para aumentar a confiabilidade de léxicos, mas sim para construir modelos eficientes de TB-APR. Neste sentido, a concepção do léxico LIWC pressupõe a hipótese projetiva:

*“Certamente a ideia da forma com que as pessoas se expressam na linguagem provém de importantes informações psicológicas, este é o princípio central do LIWC”* [Pennebaker & King, 1999].

*“O uso da linguagem como uma diferença individual confiável é relacionado a características da personalidade. De acordo com a hipótese projetiva, assumimos que a forma como as pessoas falam ou escrevem é uma expressão de processos psicológicos”* [Pennebaker & King, 1999].

A hipótese projetiva é verdadeira, pois as correlações dos modelos de TB-APR geralmente estão acima dos baselines. Entretanto, estas correlações são sempre baixas (Seção 7.3). Refletindo sobre estas correlações, podemos inferir três hipóteses:

- 1) As técnicas de extração de características textuais e as técnicas de ML existentes não são adequadas para os modelos de TB-APR. Esta hipótese pode ser validada comparando um trabalho que utilizou um mesmo *corpus*, mas com técnicas de extração de textos ou técnicas de *machine learning* mais avançadas.
- 2) Os textos utilizados para a construção dos modelos de TB-APR não são adequados. Esta hipótese pode ser validada comparando a performance de modelos de TB-APR com diferentes tipos de textos.
- 3) O método de cálculo da personalidade nos modelos de TB-APR não é adequado. Esta hipótese pode ser validada utilizando diferentes instrumentos de aferição da personalidade. Os instrumentos projetivos ainda não foram explorados pela comunidade de TB-APR.

Esta tese parte do princípio que a primeira hipótese é falsa, e a segunda e terceira hipóteses são verdadeiras. O estado da arte de *machine learning* tem evoluído continuamente e, nos dias de hoje, colhemos frutos dessa envolução em praticamente todos os segmentos da humanidade. Quanto à segunda hipótese, uma metodologia de coleta textual que utilize o conhecimento das teorias psicológicas poderia melhorar significativamente a performance dos modelos, tendo em vista que nem sempre é possível coletar uma grande quantidade de textos. Quanto à terceira hipótese, se o estado da arte em léxicos psicolinguísticos LIWC [Pennebaker et. al., 1999]; [Pennebaker, 2015] parte do princípio que a personalidade é expressa através da projeção de características pessoais em um texto. Ao utilizar um instrumento com respostas prontas em uma escala *likert* para calcular os *scores* de personalidade é introduzida uma série de *bias* no modelo de TB-APR:

- 1) Ao ler a resposta o indivíduo pode ter repugnância a uma determinada característica que é identificada em relação a ele, escolhendo outra resposta propositalmente.
- 2) A relação de transparência dos itens nos inventários de personalidade certamente é um fator de enviesamento dos modelos de TB-APR. Esta transparência torna os inventários de personalidade suscetíveis a adulterações ou falsificações das respostas [Scheefer, 1962]. Adicionalmente, os mecanismos de defesa do Ego [Freud, 1940] (ex: negação, formação reativa, etc) podem reprimir ou interferir em certas respostas.
- 3) Dependendo do número de itens, preencher o inventário pode ser uma tarefa maçante. Neste sentido a fadiga pode levar a respostas imprevisíveis.
- 4) Inventários com menos itens (10, 20 descritos na seção 4.1) são menos cansativos, mas também são menos confiáveis. Estes inventários podem não ter perguntas suficientes para correlacionar as dimensões com a personalidade do indivíduo.
- 5) O humor do examinando pode variar durante a aplicação do protocolo [Scheefer, 1962], esgotando o seu limite de tolerância. Neste sentido, em uma situação mais extrema, o examinando pode preencher as respostas do inventário de forma aleatória, para se livrar da tarefa que irá conduzir a investigação de sua personalidade.

Podemos entender a personalidade como “*uma abstração ingênua das diferenças individuais complexas*” [Newman, 2016]. Grande parte dos inventários de personalidade é baseada nas teorias disposicionais (seção 3.3), pressupondo que as dimensões de personalidade são um *conjunto de traços comuns*, sendo assim faz sentido utilizar um questionário com perguntas e respostas pré-definidas. Por outro lado, utilizar um modelo de cálculo da personalidade que não utilize respostas pré-elaboradas, é muito menos enviesante, pois além de capturar pistas de personalidade comuns, a liberdade oferecida pela técnica permite capturar pistas que somente aquele indivíduo poderia deixar.

Neste sentido, uma técnica projetiva também permite capturar o diferente, deixando tudo aquilo que é mais marcante no indivíduo ser exposto, mesmo que, sobre a vigilância da consciência, o indivíduo não queira revelar estas marcas.

Estudos sobre a psicanálise posteriores a Freud aproximam o inconsciente da linguística, afirmando que “o inconsciente é estruturado como uma linguagem” [Nasio, 1992]. Jaques Lacan, guiado pelas formações do inconsciente (sonhos, atos falhos, chistes etc), emprestou os conceitos da linguística de Saussure (1996) que afirmava que a linguagem era constituída primariamente de significantes (ex: palavras nos textos, sons no discurso oral) e não de signos (ideia, sentido). Sendo assim, o significado é um conceito efêmero, podendo desaparecer à medida que interage com a cadeia de significantes. Neste sentido, podemos aproximar o conceito de significante com a psicanálise, entendendo que os significantes são marcas e traços de tudo aquilo que um dia foi amado, odiado e esquecido [Freud, 1923 / 1961a]. As relações de significados e significantes são dependentes dos contextos, para entender esta dependência podemos utilizar uma metáfora, como se os significantes fossem o fundo do mar e os significados fossem as ondas. A metáfora das ondas nos remete à ideia que os significados são formações efêmeras, pois nesta analogia as ondas são moldadas conforme deslizam sobre o fundo do mar, que representa a cadeia de significantes. Partindo desse princípio, não somos o que achamos que somos, e para mudar como somos, não depende de nós, mas sim do Outro [Lacan, 1998] (terminologia utilizada por Jacques Lacan (1901 - 1981), que faz uma referência ao inconsciente e a a linguagem como algo do campo do grande Outro). Neste sentido, a própria linguagem é do campo do Outro, pois ela existe *a priori* e fomos inseridos nela. Sendo assim, quando falamos (ou escrevemos), falamos mais do que deveríamos, pois é justamente no discurso do Outro que os significantes formam as cadeias que nos determinam, permitindo nos expressarmos.

A lógica lacaniana expõe os objetivos desta tese. O Z-teste [Vaz & Alchieri, 2016] e o TAT [Murray, 1943/2005]; [Scaduto, 2016] são capazes de capturar pistas de personalidade de uma forma discreta e contundente [Urbina, 2007], podendo capturar inclusive afetos inconscientes, utilizando o mecanismo da projeção como motor de inferência. Estas técnicas projetivas são instrumentos complexos de aferição quantitativa e qualitativa da personalidade. Neste sentido, os experimentos desenvolvidos nesta tese permitem capturar além daquilo que o sujeito escreveu, mas também as pistas de personalidade que ele deixou nos textos sem, conscientemente, tê-las revelado pela escrita. As técnicas projetivas vem no sentido de garantir que as pistas de personalidade selecionadas para constituir o modelo dimensional sejam mais verdadeiras, escondendo do indivíduo o método de captura destas pistas.

Os modelos de TB-APR, desenvolvidos a partir da metodologia proposta por esta tese, permitem que os indutores associem os elementos textuais do sujeito a cada porção dimensional de suas diferenças mais significativas, sendo estas capturadas pelos determinantes das técnicas projetivas. Se o inconsciente escapa pela projeção [Freud, 1946] e se manifesta na linguagem [Nasio, 1992] [Pennebaker & King, 1999], possibilitamos, pela primeira vez na computação, que modelos de TB-APR possam aferir dimensões de personalidade neste sentido. Sendo assim, os modelos propostos nesta tese correlacionaram pistas deixadas em nível de LBA, com as dimensões de personalidade das técnicas projetivas que são sensíveis a este tipo de conteúdo. Os experimentos desta tese mostram que os indutores conseguiram capturar padrões neste sentido, obtendo uma média de AUC-ROC acima de 83% para 25 dimensões de personalidade.

Finalmente retornando as hipóteses formuladas no início desta tese (seção 1.5), podemos concluir que: (1) Estudar as teorias de personalidade se mostrou necessário ao longo desta tese, para melhor compreender o processo de avaliação psicológica, permitindo os insights que tivemos para escolher com maior segurança os instrumentos de avaliação da personalidade (Z-teste e TAT) e direcionar mais seguramente o tema dos tópicos textuais que foram coletados. (2) A técnica projetiva se mostrou adequada para a tarefa de TB-APR, produzindo correlações fortes entre os LBA e as dimensões de personalidade. (3) A investigação automática da personalidade realizada pelo modelo é fiel as escalas originais de personalidade, pois não fizemos simplificações nestas escalas. Sendo assim, podemos afirmar com segurança que todas as hipóteses se confirmaram.

A próxima seção irá comentar sobre trabalhos futuros.

## 9.1 Trabalhos Futuros

Dedicamos essa seção para comentar sobre trabalhos futuros. Uma primeira direção neste sentido é em relação às medidas de avaliação de desempenho. As escalas de personalidade não foram concebidas para serem balanceadas, mas sim para mensurar o espectro da personalidade humana. Neste sentido, tendo em vista que geralmente os *corpus* de TB-APR possuem um número de participantes limitado (capítulo 6), é natural que existam muitos modelos com desbalanceamento de classes nas dimensões de personalidade. Via de regra, modelos com desbalanceamento de classes podem ter uma acurácia maior, mas por outro lado, estes modelos podem errar quase todos os exemplos da classe minoritária. Observado a Tabela 11, na seção 6.2, além de notarmos que muitos modelos utilizam a acurácia como métrica de avaliação de desempenho, notamos também que nenhum modelo utiliza métricas mais adequadas a bases de dados desbalanceadas, como a métrica



AUC-ROC ou a métrica AUC-PRC. Neste sentido, seria de grande valia que a comunidade de TB-APR padronizasse um conjunto de medidas de avaliação de desempenho. Os modelos de regressão também poderiam se beneficiar de uma padronização neste sentido, pois ao passo que alguns utilizam métricas de correlação, outros empregam métricas de erro.

Ainda sobre os desbalanceamentos de classes, seria interessante que os trabalhos utilizassem técnicas de *sampling* para mitigar este problema. O único trabalho que conhecemos, o qual faz uso destas técnicas, é o de Santos e Paraboni (2019). Uma das dificuldades para a aplicação de técnicas de *sampling* para modelos de TB-APR está relacionada ao pequeno tamanho das bases, que são típicas destes modelos. Neste sentido, utilizar uma técnica de *undersampling* poderia acabar com a representividade da classe majoritária. Este problema pode ser mitigado utilizando uma técnica de *oversampling*. Além de utilizar técnicas de *sampling*, também seria possível endereçar este problema ao alterar o peso do erro da classe minoritária em classificadores com o *Gradient Boosting*, possibilitando ao modelo dar uma importância maior ao erro da classe minoritária.

Em relação a amostra populacional do Z-teste, ela foi formada por estudantes, sendo que a maioria deles eram do curso de psicologia e do sexo feminino. Embora estes estudantes não conhecessem o Z-teste a priori, uma amostra mais estratificada é sempre preferível. Neste sentido, seria interessante realizar novos experimentos com o Z-teste, aumentando a amostra dos indivíduos dos demais cursos superiores. Pensando de maneira mais audaciosa, este trabalho também poderia abranger populações de diversos níveis de escolaridade e também de diversas classes sociais, incluindo pessoas de diferentes localizações do país.

Quanto aos *corpora* desenvolvidos nesta tese, ambos possuem dados sensíveis. Acreditamos que é possível elaborar uma metodologia para anonimizar estes dados. Estes *corpora* possuem uma grande valia para a comunidade científica, para o desenvolvimento de novos modelos de TB-APR. Entretanto, esta metodologia teria que ser aprovada pelo comitê de ética da PUCPR. Ainda em relação aos *corpora*, seria possível aumentar o número de participantes, obtendo uma amostra mais representativa. Trabalhos futuros também poderiam utilizar estes *corpora*, propondo modelos com diferentes técnicas de extração de características e diferentes paradigmas de aprendizagem de máquina. Em seguida, poderia ser realizada uma comparação destes modelos com os modelos desenvolvidos nesta tese, utilizando os resultados dos experimentos desta tese como *baseline*. Em nossos experimentos, utilizamos uma técnica *bottom-down* (TF-IDF) em conjunto com o paradigma de classificação multi-classe. Existem diversas outras combinações de técnicas de LBA e paradigmas de ML que podem ser utilizadas para construção de modelos de TB-APR. Além disso, devido ao fato de trabalhar com diversas dimensões de personalidade, optamos por não fazer a análise de relevância

de palavras para cada modelo proposto. Trabalhos futuros poderiam contemplar estas análises, que poderiam contribuir para o desenvolvimento de ferramentas léxicas de extração de características textuais para TB-APR.

Finalmente, esperamos que as dimensões de personalidade exploradas de forma inédita através dos modelos de TB-APR propostos nesta tese, permitam a construção de sistemas informatizados mais eficientes e humanos. Neste sentido, aplicações construídas a partir dos modelos desenvolvidos nesta tese, poderiam envolver sistemas de reputação [Yang & Huang, 2019], compra e venda, autônomos, robóticos, bancários, recrutamento e seleção, redes sociais, didáticos, auditoria de líderes organizacionais [Wang & Chen, 2019], entre outros. O próximo capítulo é o anexo 1, que irá descrever os experimentos preliminares, que permitiram alguns *insights* para esta tese.

## Anexo 1. Experimentos preliminaries

Este anexo é reservado para mostrar alguns experimentos preliminares. O foco destes experimentos foi uma tentativa de inovar modelos de TB-APR que utilizam inventários de personalidade, explorando a capacidade dos modelos de prever características de mais baixo nível que os traços de personalidade, sendo assim nestes experimentos trabalhamos na previsão das facetas dos traços de personalidade, utilizando o paradigma de regressão multi-target, sendo este o primeiro experimento da literatura que temos conhecimento que aborda o problema de previsão das facetas de personalidade, sem fazer a decomposição do problema multi-target a priori.

Dividimos este capítulo da seguinte forma: a primeira seção descreve os detalhes do corpus utilizado nos experimentos, a segunda seção descreve como foi feita a extração de características textuais, a terceira seção é dedicada ao processo de construção de modelos por aprendizagem e a última seção faz uma conclusão sobre os resultados encontrados, discutindo novas possibilidades de trabalhos futuros.

### Anexo 1.1 O corpus do facebook-BR [Paim, 2016]

O corpus utilizado nestes experimentos foi o mesmo utilizado em um trabalho desenvolvido anteriormente [Paim, 2016], que investigou a correlação de scores de personalidade com textos do facebook utilizando o paradigma da regressão, a Tabela 51 mostra alguns dados sobre este corpus.

Usuários do facebook	256
Número de publicações	187.488
Número médio de publicações por usuário	732
Número total de palavras	2.590.034
Número médio de palavras por usuário	10.117

**Tabela 51.** O corpus utilizado nos experimentos preliminaries [Paim, 2016].

O inventário de personalidade utilizando por este corpus para rotular os usuários com os atributos meta foi um inventário do BigFive com 120 itens [Johnson, 2014]. Este inventário além de fornecer os 5 traços de personalidade, possui os scores referente as escalas de 6 facetas por traço de personalidade (este inventário está detalhado no capítulo 3 desta s). A distribuição dos scores de personalidade para os 5 traços de personalidade do BigFive do corpus se encontra na seção 3.2.1 da dissertação de mestrado de Aldo Marcelo Paim [Paim, 2016, pp 53-55].

## **Anexo 1.2 Extração de características**

O procedimento de extração de características ocorreu em quatro etapas, produzindo seis espaços de características distintos que posteriormente foram combinados:

- 1) Foi realizado o pré-processamento.
- 2) O TF-IDF foi aplicado por bottom-up.
- 3) O léxico LIWC [Pennebaker, 2015] foi aplicado por top-down.
- 4) Os léxicos afetivos foram aplicados em conjunto termos do TF-IDF, em uma abordagem híbrida.
  - a. SentiStrength [Theleall et. al., 2010].
  - b. AnewBr [Kristensen et.al., 2011].
  - c. SentiLex-PT [Silva & Carvalho; Sarmiento, 2012] [Carvallho & Silva, 2015].
  - d. OpLexicon [Souza, 2011].

Antes de fazer a extração de características, um pré-processamento foi necessário.

### **Anexo 1.2.1 Pré-processamento**

O pré-processamento ocorreu em duas fases distintas, as fases estão enumeradas abaixo [Paim, 2016]:

- 1) Análise léxica: caracteres irrelevantes foram eliminados, foi feito o isolamento dos termos por tokenização, as letras foram todas transformadas em *lower case*, adicionalmente palavras informais foram trocadas por palavras formais quando possível [Han & Baldwin, 2011].
- 2) Eliminação dos *tokens* irrelevantes, chamados de *stopwords*.

Como utilizamos diversos léxicos não foi feita a etapa da normalização morfológica. Este processo é conhecido como *stemming* [Frakes, 1992]. Após o pré-processamento, os dados

tokenizados foram submetidos a extração de características, iniciando este processo com a aplicação da técnica *bottom-up* TF-IDF.

### Anexo 1.2.2 Aplicação do TF-IDF

O texto pré-processado foi submetido a ferramenta WEKA, onde o filtro StringToWordsVector foi aplicado, extraindo um espaço de 1000 características textuais referentes a 1000 termos TF-IDF, em seguida iniciamos o processo de extração de características léxicas.

### Anexo 1.2.3 Aplicação do léxico LIWC

A versão do LIWC utilizada foi derivada do estudo de Balage filho et. al (2013). O léxico LIWC na versão em português-br possui 127 mil palavras catalogadas em 64 categorias, divididas em 4 dimensões:

- 1) Linguística: contém categorias como artigos, preposições, advérbios, etc.
- 2) Psicológica: contém categorias de valência emocional (positiva e negativa), categorias relacionadas a processos cognitivos, entre outras.
- 3) Relatividade: categorias referentes ao tempo, espaço, modos verbais entre outras.
- 4) Pessoal: categorias de palavras referente a laser, trabalho, entre outras.

No que diz respeito ao léxico, uma mesma palavra pode constar em mais de uma categoria no LIWC, e se detectamos que isso ocorreu nós a contabilizamos novamente na nova categoria. O léxico LIWC foi aplicado fazendo contagens de categorias por top-down, utilizando a fórmula 48 especificada por Mairesse e seus colegas [Mairesse, 2007].

$LIWC_{t,d} = \frac{(tf_{t,d} * 100)}{tt_d}$	(48)
--	------

Onde  $tf_{t,d}$  corresponde a ocorrência de um termo  $t$  em um document  $d$  e  $tt_d$  é o total de palavras empregadas no document  $d$ .

Depois de aplicar o LIWC, cada atributo do espaço de características referente à esta aplicação contém a porcentagem que corresponde ao número de palavras em cada categoria. Após aplicar o léxico LIWC, aplicamos os léxicos afetivos.

#### Anexo 1.2.4 Fórmula de aplicação dos léxicos afetivos

Todos os léxicos afetivos foram aplicados em conjunto com a extração de 1000 termos TF-IDF (subseção 7.2.2), produzindo novos espaços de características. Esta abordagem híbrida utiliza a fórmula 49 [Paim, 2016], em um processo de aplicação simples compreendo três passos:

1. Os termos (palavras) dos léxicos e os 1000 termos TF-IDF são carregados em memória e verificados um a um.
2. Caso o termo do léxico não esteja presente nos termos TF-IDF, o termo do léxico será descartado.
3. Caso o termo do léxico esteja presente também nos termos TF-IDF, o termo será contabilizado na forma de uma nova característica, para isso o valor de contagem do TF-IDF será multiplicado pelo valor afetivo especificado por aquele termo no léxico, produzindo um novo atributo no espaço de características.

$w_{t,d,l} = tf - idf(t, d) * P_{t,l}$	(49)
--	------

Onde  $w_{t,d,l}$  é o valor ponderado colocado no espaço de características referente a aplicação do léxico afetivo em conjunto com o TF-IDF,  $tf - idf(t, d)$  é o valor de contagem de um termo  $t$  obtido em um documento  $d$  referente a um participante da pesquisa e  $P_{t,l}$  é o peso de um termo, compreendo o valor afetivo de uma palavra especificado por um léxico.

#### Anexo 1.2.5 Aplicação do léxico afetivo SentiStrenght

A versão português-br do Senti-Strenght [Theleall et. al., 2010] utilizada em nossos experimentos, possui palavras de carga emocional catalogadas em uma escala de emoções que varia de 1 a 5 para palavras com polaridade positiva e -1 a -5 para palavras com polaridade negativa. A aplicação das polaridades especificadas no léxico foi aplicada em conjunto com TF-IDF em uma abordagem híbrida utilizando a fórmula detalhada na subseção 8.2.4.

Um exemplo de aplicação pode ser dado ao encontrar a palavra “amor” categorizada no léxico. O espaço das 1000 características tf-idf é então carregado em memória. Supondo que exista esta palavra no espaço tf-idf com um valor de 0.10. O Senti-Strenght reporta que a palavra amor tem uma

polaridade +3, sendo assim depois da aplicação do léxico uma nova característica será adicionada ao espaço de características, com o valor 0.30.

### Anexo 1.2.6 Aplicação do léxico afetivo AnewBR

A versão do Anew para o português-br possui 1046 palavras catalogadas caracterizada por um modelo de emoções ortogonal em duas dimensões [Kristensen et al., 2011]:

- 1) Dimensão valência em uma escala de 1 a 9 que vai do desagradável (1) ao agradável (9).
- 2) Dimensão alerta em uma escala de 1 a 9 que vai do relaxado (1) ao estimulado (9).

O processo de aplicação deste léxico produziu quatro espaços de características diferentes. O primeiro e o segundo espaços de características utilizaram a fórmula de aplicação descrita na subseção 7.2.4, utilizando a abordagem híbrida. Para cada palavra do léxico presente no espaço TF-IFD, uma característica ponderada referente à dimensão valência e outra característica ponderada referente à dimensão alerta foram adicionadas ao espaço de características, formando dois espaços de características independentes.

Além do processo de aplicação descrito no parágrafo acima, adicionalmente foram elaboradas mais duas fórmulas (Fórmula 50) de aplicação exclusivas para este léxico, realizando uma abordagem de contagem ponderada top-down pura, a primeira fórmula foi utilizada para construir um atributo de valência e a segunda fórmula para construir um atributo de alerta [Paim 2016].

$m_v = \frac{\sum_{i=1}^n (q_i * v_i)}{\sum_{i=1}^n q_i} \qquad m_a = \frac{\sum_{i=1}^n (q_i * a_i)}{\sum_{i=1}^n q_i}$	(50)
--	------

Onde  $q_i$  corresponde quantas vezes a palavra  $i$  pertencente ao léxico foi achada,  $v_i$  corresponde ao valor da escala valência de uma palavra  $i$  encontrada no corpus e  $a_i$  corresponde o valor da escala alerta de uma palavra  $i$  encontrada no corpus.

Após a aplicação das fórmulas os 4 espaços de características referentes ao léxico AnewBr podem ser representados pela tupla (vetor TF-IDF Alerta, vetor TF-IDF Valência, atributo contagem Alerta, atributo contagem Valência).

### **Anexo 1.2.7 Aplicação do léxico afetivo SentiLexPT**

O SentiLexPT [Silva & Carvalho; Sarmiento, 2012] [Carvallho & Silva, 2015] é um léxico afetivo que possui 7014 palavras em português-br. Estas palavras estão catalogadas de acordo com suas polaridades emocionais em uma escala de três posições que vai do -1 indicando palavras com polaridades negativas, 0 indicando palavras sem polaridade (neutras) e 1 indicando palavras com polaridades positivas. Para aplica-lo utilizamos a abordagem híbrida com TF-IDF especificada na seção 7.2.4, mas reformulamos a escala para 1 indicando palavras negativas, 2 indicando palavras neutras e 3 indicando palavras positivas.

Adicionalmente a metodologia descrita no parágrafo acima, três novos atributos foram adicionados no espaço de características, para isso foi utilizada uma abordagem simples de contagem top-down de cada uma das três categorias de polaridade especificadas pelo léxico.

### **Anexo 1.2.8 Aplicação do léxico afetivo OpLexicon**

O OpLexicon [Souza, 2011] é muito utilizado no processo de mineração de opiniões, este léxico em sua versão para o português possui 32.000 palavras catalogadas utilizando a mesma escala de polaridades do SentiLexPt [Carvallho & Silva, 2015], sendo assim metodologia de aplicação deste léxico foi idêntica a metodologia de aplicação SentiLex-PT.

### **Anexo 1.2.9 Merge de todos espaços de características**

O espaço de característica total foi resultante da combinação de todas as etapas de extração de características, sendo representado pela tupla (vetor TF-IDF 1000 termos, vetor TF-IDF SentiStrenght, vetor TF-IDF AnewBr alerta, vetor TF-IDF AnewBr valência, atributo contagem ponderada alerta, atributo contagem podenderada valência, vetor TF-IDF SentiLexPT, contagem SentiLexPT positivas, contagem SentiLexPT negativas, contagem SentiLexPT neutras, vetor TF-IDF OpLexicon, conatagem OpLexicon positivas, contagem OpLexicon negativas, Contagem OpLexicon neutras).

No total, o espaço de características combinado ficou com 2392 atributos. A próxima seção descreve o processo de aprendizagem de máquina utilizado em nossos experimentos.



## Anexo 1.3 Aprendizagem de máquina

Este trabalho utilizou o paradigma de regressão multi-target (subseção 5.2.5) utilizando indutores classicamente utilizados para resolver este problema e também utilizando um indutor lazy (não constrói modelo, baseado em instâncias) com um processo interno de seleção de características em uma abordagem multi-target, concebido de forma original. Todos experimentos foram submetidos à técnica de amostragem por validação cruzada em 10 folds.

Dividimos esta seção em três subseções, a primeira especifica a medida de avaliação de desempenho utilizada por todos indutores, a segunda especifica os indutores que utilizamos baseado na literatura do problema de regressão multi-target, e a terceira especifica o novo utilizado.

### Anexo 1.3.1 Medida de avaliação de performance.

Escolhemos o *average relative root mean squared error* aRRMSE [Bocharni et al, 2015] para utilizamos em uma função de fitness referente a um processo de seleção de características interno em um novo indutor que concebemos.

Em todos os experimentos a medida RRMSE foi utilizada para medir a performance. Esta medida é considerada o padrão para problemas de regressão multi-target [Bocharni et al, 2015], sendo assim desejamos que o valor de RRMSE seja o menor possível cada faceta ( $n=30$ ). As medidas de erro aRRMSE e RRMSE são especificadas pela fórmula 51 [Bocharni et al, 2015]:

$$aRRMSE = \frac{1}{d} \sum_{i=1}^d RRMSE = \frac{1}{d} \sum_{i=1}^d \sqrt{\frac{\sum_{k=1}^{n_{test}} (py_i^k - y_i^k)^2}{\sum_{k=1}^{n_{test}} (ay - y_i^k)^2}} \quad (51)$$

Onde  $d$  representa o total de variáveis a serem previstas,  $n_{test}$  representa o número de instâncias de testes,  $py$  é o valor previsto de uma faceta e  $y$  é o valor atual de uma faceta.

### Anexo 1.3.2 Métodos de transformação do problema (MULAN)

Existem 2 principais grupos de indutores para o paradigma multi-target. Estes grupos estão especificados no capítulo 5, subsecção 5.2.5. Nestes experimentos utilizamos indutores do grupo técnicas de transformação do problema (*problem trasformation methods*) do paradigma multi-target. Estes indutores são algoritmos que necessitam de um regressor base, possuindo a flexibilidade de utilização de regressores e meta-regressores usados classicamente na regressão single-target, permitindo que modelos especializados sejam construídos para cada dimensão da personalidade (neste caso facetas,  $n = 30$ ), com a vantagem de possibilitar que a informação de previsão de cada dimensão (py) seja utilizada na construção dos próximos modelos especializados e também a vantagem de ser possível utilizar a informação de previsão de todos modelos na construção de um modelo final. Todos os algoritmos de regressão multi-target citados nesta subsecção utilizaram a API em java do MULAN [Tsoumakas et. al., 2011]. Como baseline para fins de comparação, fizemos decomposição do problema de regressão multi-target em múltiplos problemas single target. A este indutor nos referimos nos experimentos como single target (ST). Este indutor utilizou o mesmo regressor base que os demais algoritmos multi-target (exceto o algoritmo MORF explicado nos próximos parágrafos).

Como regressor base utilizamos a técnica de ensembles bagging ou bootstrapping bagging [Breiman, 1996] que utiliza ensembles de regressores homogêneos, sendo assim escolhemos o regressor baseado em árvores RepTree [Kalmegh, 2015]. O RepTree (*reduced error pruning tree*) é um regressor baseado em árvores de decisão, que constrói múltiplas árvores simultâneas nas diferentes interações e depois escolhe a melhor árvore para o modelo. Como o problema que estamos tratando é de regressão, os nodes das árvores de decisão são construídos utilizando a redução de variância como critério de divisão da árvore. A poda da árvore de decisão foi realizada utilizando o critério de redução do erro médio quadrático (MSE mean squared error). O RepTree é considerado um regressor fraco e bastante rápido, sendo assim ele é apropriado para ser utilizado com técnicas de ensembles. Utilizando o RepTree em conjunto com técnica de bagging esta última gera múltiplos modelos de árvores de decisão. Desta forma, cada modelo é construído a partir de diferentes amostras dos folds de treinamento com reposição ( $n\_bags = 100$ ). Depois de cada modelo ser construído e testado, um consenso de regressão é proclamado, produzindo a previsão final.

Utilizando o bagging, comparamos o desempenho de diversos algoritmos do grupo de métodos de transformação de problema, todos estes algoritmos são soluções clássicas utilizadas no paradigma de regressão multi-target [Fernandi et. al, 2014]:

- 1) Multi-Target Stacking (MTS): O algoritmo constrói o modelo em duas etapas distintas. Na primeira etapa,  $n$  modelos são construídos decompondo o problema multi-target. Na segunda etapa os modelos são novamente construídos mas a informação de cada variável prevista na etapa anterior expande os espaços de características construindo novos  $n$  modelos utilizando também como características os valores previstos das  $(n - 1)$  variáveis.
- 2) Multi-Target Stacking Corrected (MTSC): Este algoritmo é similar ao MTS, mas possui um mecanismo interno de validação cruzada, evitando sobre-estimar o conjunto de treinamento, este algoritmo efetua uma nova validação cruzada para cada modelo construído além da validação cruzada original de 10 folds, utilizada em todos os nossos experimentos.
- 3) Ensemble of Regressor Chains (ERC): Este algoritmo usa uma analogia de correntes de regressores. Para entender como isto funciona, ordens variadas de variáveis alvo (target variables) são escolhidas e os modelos começam a ser construídos sequencialmente, com cada modelo incorporando o valor de previsão de todos os modelos anteriores em seu espaço de características. Neste algoritmo escolhemos um valor referente ao número de correntes, sendo assim diferentes ordens de previsão das variáveis são selecionadas em cada corrente. Dessa forma  $n$  modelos são construídos múltiplas vezes dependendo do número de correntes. Em nossos experimentos utilizamos 10 correntes.
- 4) Ensemble of Regressor Chains Corrected (ERCC): Funciona de forma similar ao MTSC, mas utilizando o conceito das correntes ao invés do modelo das duas etapas.

Além dos indutores que utilizaram o bagging, também utilizamos o algoritmo de regressão multi-target Multi-Objective Random Forests (MORF). Este algoritmo é uma adaptação do algoritmo clássico de Random Forests para o problema de regressão multi-target, explorando diferentes espaços de características randomicamente e construindo uma árvore de decisão para cada um deles. Este algoritmo também utiliza o conceito de ensembles homogêneos de árvores de decisão. No bagging a ideia principal é mitigar ruídos e modelos imparciais, criando um modelo final com variância baixa, o algoritmo de Random Forests funciona conceitualmente de forma análoga, mas também explora o espaço de características de forma randômica, concebendo novos modelos de árvore de decisão.

Adicionalmente ao baseline e os algoritmos tradicionalmente utilizados no problema de regressão multi-target, um novo algoritmo regressor foi proposto para podermos comparar ensembles

baseados em instâncias, ensembles baseados em espaços de características randômicos, com um algoritmo que utiliza uma técnica de seleção de características supervisionada internamente, este algoritmo é especificado na próxima subseção.

### **Anexo 1.3.3 Indutor Multi-target genético**

Os algoritmos de regressão multi-target especificados pela API do MULAN em conjunto com a técnica bagging teoricamente devem explorar melhor o espaço de características do que algoritmos que não utilizam a técnica do bagging. Adicionalmente estes algoritmos tem a vantagem de utilizar os valores de previsão das 30 variáveis (facetas) para gerar o modelo final, entretanto não é possível afirmarmos que estes algoritmos tem mais performance que algoritmos mais simples que não constroem modelos (lazy), mas utilizam técnicas refinadas de seleção de características.

Para testar a hipótese acima construímos um novo algoritmo regressor utilizando a API do Weka e a biblioteca Jenetics para a linguagem Java. Este regressor utiliza a distância euclidiana para encontrar as 3 instâncias mais próximas e utiliza como critério de regressão o centróide (média) das facetas destas instâncias, prevendo o valor das 30 facetas. A técnica de amostragem utilizada foi a validação cruzada em 10 *fold*s. Para cada *fold* de treinamento e teste, as características foram selecionadas utilizando o *fold* de treinamento, para isso, cada *fold* de treinamento foi submetido à técnica de amostragem *leave one out*, utilizando um algoritmo genético para construir fenótipos de atributos, utilizando a medida de erro aRMSE (erro relativo as 30 facetas) como função de *fitness*. Após *n* gerações o melhor fenótipo é selecionado no *fold* de treinamento e em seguida é feito o *match* do fenótipo no *fold* de testes, deixando o *fold* de treinamento e o *fold* de testes com os mesmos atributos. Finalmente é calculado o erro aRMSE final para o *fold* em questão, repetindo este procedimento todo 10 vezes devido a validação cruzada.

A Figura 22 detalha este algoritmo, e também detalha os parâmetros escolhidos para executar o algoritmo genético utilizando a biblioteca Jenetics.

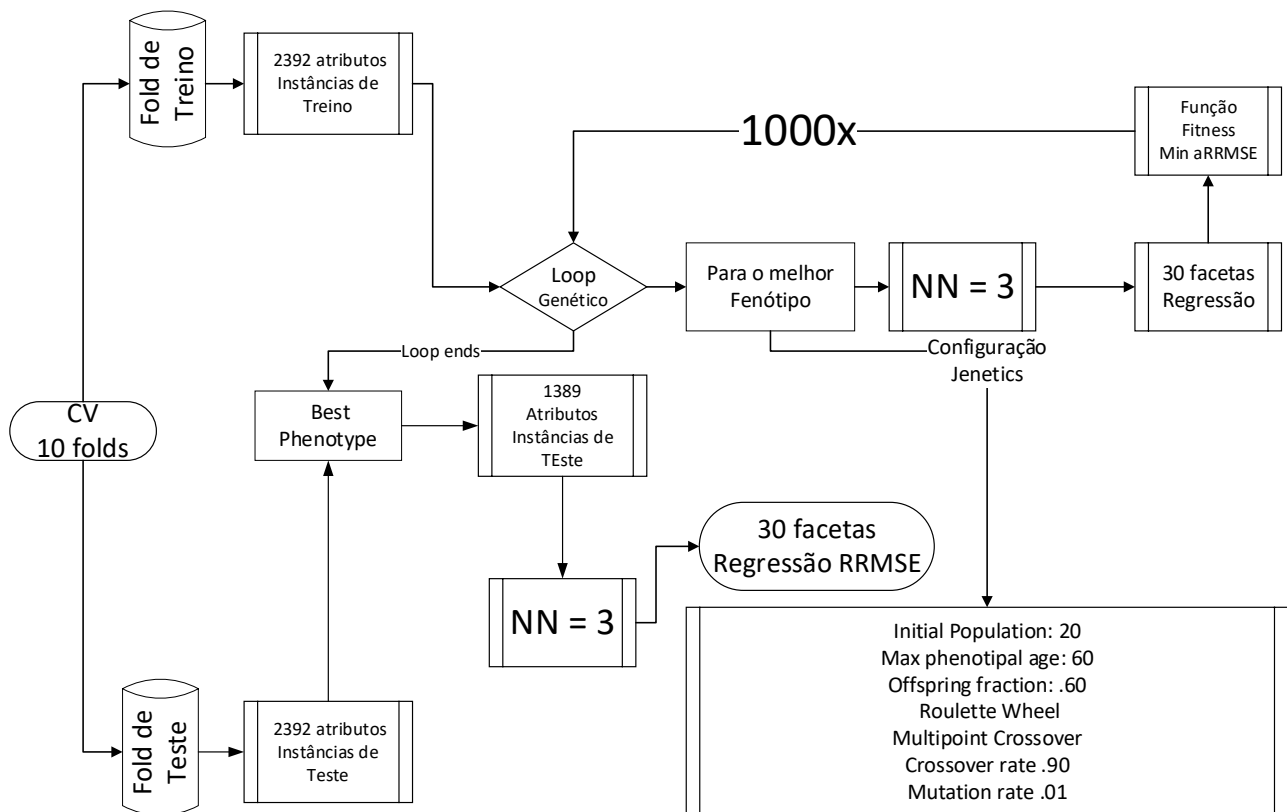


Figura 22. Fluxograma do Indutor Multi-target Genético.

A próxima seção expõe os resultados referentes a todos os experimentos detalhados neste trabalho.

## Anexo 1.4 Resultados obtidos

Separamos em subseções os resultados obtidos para 6 facetas referentes a cada um dos 5 traços do BigFive. Nestas subseções, para cada traço de personalidade uma tabela mostra o erro RRMSE referente a cada faceta, com isso desejamos obter *insights* no que diz respeito a performance dos algoritmos de regressão multi-target na previsão das facetas.

Todos os resultados de cada tabela foram submetidos ao teste não paramétrico de Friedman, a significância de  $\alpha = 0.05$  e depois os algoritmos foram comparados, para isso utilizamos o teste *post-hoc* de Nemenyi. Este último fornece o valor de distância crítica (CD) permitindo por *forecast* (utilizando o *software* R) plotar um gráfico mostrando se existem algoritmos ou grupos de algoritmos mais significativamente eficientes para prever as facetas.

### Anexo 1.4.1 Facetas de Openess to Experience (O)

Nestes experimentos utilizamos as seguintes siglas para referências as facetas de *Openess to Experience* (O):

- 1) *Imagination* (O1)
- 2) *Artistic interests* (O2)
- 3) *Emotionality* (O3)
- 4) *Adventurousness* (O4)
- 5) *Intellect* (O5)
- 6) *Liberalism* (O6)

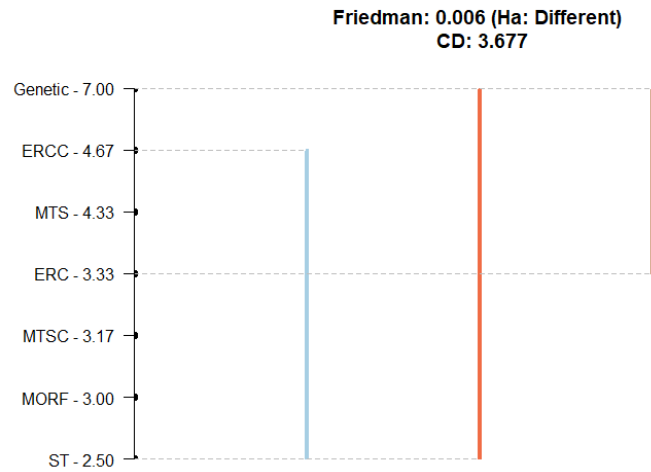
A Tabela 52 mostra o erro RRMSE para 6 facetas ou sub-traços de personalidade referentes ao traço *Openess to Experience*:

O	O1	O2	O3	O4	O5	O6
ST	1.00352	1.00575	1.01812	0.97092	0.99398	0.92871
MTS	1.00544	1.00070	1.03420	0.97427	1.00554	0.93294
MTSC	<b>1.00030</b>	1.00677	1.02051	<b>0.96964</b>	0.99833	0.94089
MORF	1.00662	<b>0.99024</b>	<b>1.01592</b>	0.98128	<b>0.98865</b>	0.98337
ERC	1.00787	0.99614	1.03225	0.97377	0.99877	<b>0.92781</b>
ERCC	1.01275	0.99673	1.01985	0.98681	1.00244	0.94495
G	1.14609	1.14905	1.15004	1.14829	1.14687	1.14640

**Tabela 52.** RRMSE para as facetas de *Openess to Experience*.

Analisando a quantidade de erro de cada faceta, notamos que o algoritmo MORF é o mais eficiente de todos, obtendo os menores erros na previsão das facetas *Artistic Interests* (O2), *Emotionality* (O3) e *Intellect* (O5), seguido MTSC que foi o melhor para prever as facetas *Imagination* (O1) e *Adventurousness* (O4). O algoritmo ERC foi o mais adequado para prever *Liberalism* (O6). O algoritmo genético teve desempenho muito ruim, produzindo mais erro que os demais algoritmos.

Aplicando o teste de Friedman obteve-se um p-value de 0.006, sendo assim existe diferença significativa entre os algoritmos com significância de  $\alpha = 0.05$  (p-value <  $\alpha$ ). Abaixo encontra-se o gráfico com os *mean ranks*, obtido por *forecast* após a aplicação do teste Nemenyi (Figura 23.).



**Figura 23.** Ranqueamento dos indutores para *Openness to Experience* [api R, 2018].

A Figura 23 mostra que o algoritmo baseline ST é o melhor de todos, mas que ele não possui diferenças significativas comparado ao algoritmos MORF, MTSC, ERC e ERCC, mas possui diferenças significativas em relação ao Genetic. Por outro lado, o algoritmo Genetic é o pior de todos, mas não possui diferenças significativas ao ser comparado com o ERCC, MTS e ERC.

O algoritmo eleito como melhor para prever facetas do traço *Openness to experience* (O) neste experimento foi o baseline *Single Target* (ST).

#### Anexo 1.4.2 Facetas de Conscientiousness (C)

Nestes experimentos utilizamos as seguintes siglas para referenciar as facetas de *Conscientiousness* (C):

- 1) *Self-efficacy* (C1)
- 2) *Orderliness* (C2)
- 3) *Dutifulness* (C3)
- 4) *Achivement-striving* (C4)
- 5) *Self-discipline* (C5)
- 6) *Cautiousness* (C6)

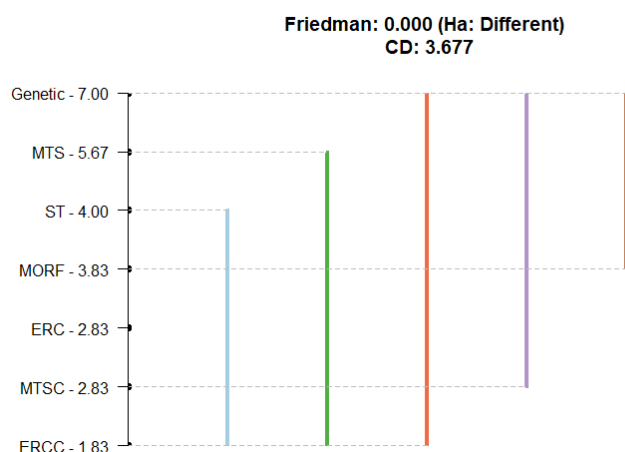
As Tabela 53 mostra o erro RRMSE para 6 facetas ou sub-traços de personalidade referentes ao traço *Conscientiousness*:

C	C1	C2	C3	C4	C5	C6
ST	1.00771	1.00709	0.99351	1.01265	0.99156	1.00645
MTS	1.04753	1.00869	1.00534	1.04018	1.05148	1.01078
MTSC	1.00487	1.00490	0.99701	1.00953	0.98568	1.00536
MORF	1.01046	1.01699	0.99827	1.01066	0.98784	<b>0.99512</b>
ERC	1.02510	<b>0.99908</b>	0.99331	1.00542	0.98855	1.00312
ERCC	<b>0.99915</b>	1.01072	<b>0.98866</b>	<b>1.00434</b>	<b>0.97890</b>	0.99656
G	1.13704	1.14045	1.14050	1.14545	1.14127	1.14512

**Tabela 53.** RRMSE para as facetas de *Conscientiousness*.

Analisando a quantidade de erro de cada faceta, notamos que o algoritmo ERCC é o mais eficaz de todos, obtendo os menores erros na previsão das facetas *Self-efficacy* (C1), *Dutifulness* (C3), *Achievement-striving*(C4) e *Self-discipline*(C5). Em segundo lugar empataram os algoritmos ERC obtendo o menor erro na precisão da faceta *Orderliness* (C2) e MORF obtendo o menor erro na precisão da faceta *Self-discipline*(C6). Novamente o algoritmo genético teve desempenho muito ruim, produzindo mais erro que os demais algoritmos.

Aplicando o teste de Friedman obteve-se um p-value de 0.000, sendo assim existe diferença significativa entre os algoritmos a significância de  $\alpha = 0.05$  (p-value <  $\alpha$ ). Abaixo encontra-se o gráfico com os *mean ranks*, obtido por *forecast* após a aplicação do teste Nemenyi.



**Figura 24.** Ranqueamento dos indutores para *Conscientiousness* [api R, 2018].



A Figura 24 mostra que o algoritmo ERCC é o melhor de todos, mas que ele não possui diferenças significativas comparado ao algoritmos MTSC, ERC, MORF e ST, mas possui diferenças significativas em relação ao MTS e Genetic. Por outro lado, o algoritmo Genetic é o menos performático, entretanto não existem diferenças significativas em relação aos algoritmos MTS, ST, e MORF.

O algoritmo eleito como melhor para prever facetas do traço *Conscientiousness* (C) neste experimento foi o *Ensemble of Regressor Chains Corrected* (ERCC).

### Anexo 1.4.3 Facetas de Extraversion (E)

Nestes experimentos utilizamos as seguintes siglas para referenciar as facetas de *Extraversion* (E):

- 1) *Friendliness* (E1)
- 2) *Gregariououness* (E2)
- 3) *Assertivenes* (E3)
- 4) *Activity level* (E4)
- 5) *Excitement-seeking* (E5)
- 6) *Cheerfulness* (E6)

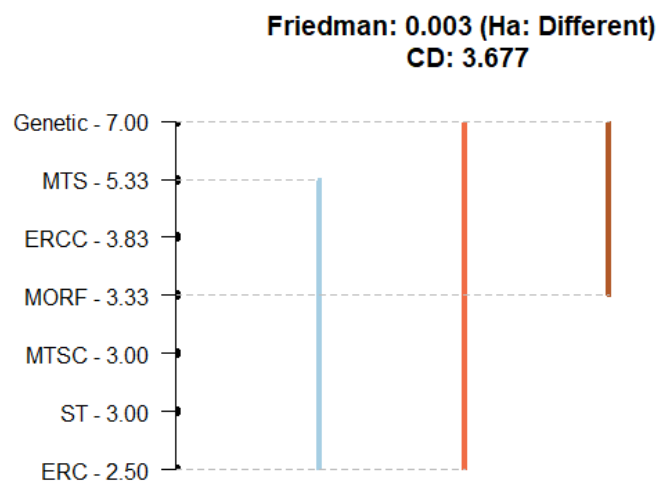
As Tabela 54 mostra o erro RRMSE para 6 facetas ou sub-traços de personalidade referentes ao traço *Extraversion*:

E	E1	E2	E3	E4	E5	E6
ST	0.98814	1.00085	<b>1.00626</b>	0.99581	0.97919	0.95990
MTS	1.01018	1.00053	1.01598	1.00369	1.02375	0.97888
MTSC	0.99013	1.00070	1.00847	0.99016	0.98256	<b>0.95789</b>
MORF	<b>0.98586</b>	0.99162	1.01584	<b>0.98774</b>	0.98560	0.98917
ERC	0.98744	<b>0.99005</b>	1.01192	0.99566	0.97545	0.96462
ERCC	0.9997	1.0016	1.0071	1.0036	<b>0.9743</b>	0.9715
G	1.12670	1.16146	1.1347	1.13407	1.1693	1.1339

**Tabela 54.** RRMSE para as facetas de *Extraversion*.

Analisando a quantidade de erro em cada faceta, notamos que o algoritmo MORF é o mais eficiente de todos, obtendo os menores erros na previsão das facetas *Friendliness* (E1) e *Activity level* (E4). O algoritmo genético foi o pior de todos e todos os outros algoritmos ficaram empatados em segundo lugar.

Aplicando o teste de Friedman obteve-se um p-value de 0.003, sendo assim existe diferença significativa entre os algoritmos com significância de  $\alpha = 0.05$  (p-value <  $\alpha$ ). Abaixo encontra-se o gráfico com os *mean ranks*, obtido por *forecast* após a aplicação do teste Nemenyi.



**Figura 25.** Ranqueamento dos indutores para *Extraversion* [api R, 2018].

A Figura 25 mostra que o algoritmo ERC é o melhor de todos, mas que ele não possui diferenças significativas comparado aos algoritmos ST, MTSC, ERC, MORF, ERCC e MTS. Por outro lado o algoritmo Genetic é o pior de todos, mas ele não possui diferenças significativas quando comparado aos algoritmos MTS, ERCC e MORF.

O algoritmo eleito como melhor para prever facetas do traço *Extraversion* (E) neste experimento foi o *Ensemble of Regressor Chains* (ERC).

#### Anexo 1.4.4 Facetas de Agreeableness (A)

Nestes experimentos utilizamos as seguintes siglas para referenciar as facetas de *Agreeableness* (A):

- 1) *Trust* (A1)
- 2) *Morality* (A2)

- 3) *Altruism* (A3)
- 4) *Cooperation* (A4)
- 5) *Modesty* (A5)
- 6) *Sympathy* (A6)

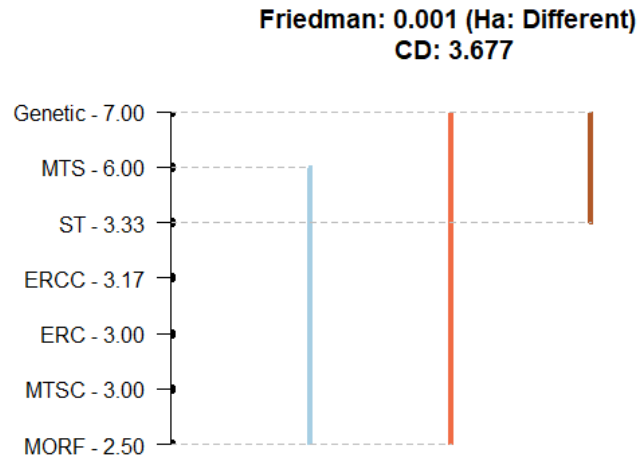
A Tabela 55 mostra o erro RRMSE para 6 facetas ou sub-traços de personalidade referentes ao traço *Agreeableness*:

A	A1	A2	A3	A4	A5	A6
ST	1.00247	0.99146	1.00779	0.98382	1.01363	0.98204
MTS	1.01699	1.00418	1.04399	0.98754	1.01978	1.02011
MTSC	<b>0.99857</b>	0.99519	1.01033	<b>0.98067</b>	1.01247	0.99246
MORF	1.00846	<b>0.98459</b>	<b>1.00573</b>	0.98172	<b>1.00375</b>	0.99347
ERC	1.00005	0.98761	1.02426	0.98200	1.00948	0.98343
ERCC	1.00117	0.99517	1.01085	0.98383	1.00872	<b>0.98129</b>
G	1.13072	1.12793	1.12533	1.13077	1.12799	1.12715

**Tabela 55.** RRMSE para as facetas de *Agreeableness* [api R, 2018].

Analisando a quantidade de erro de cada faceta, notamos que o algoritmo MORF é o mais eficaz de todos, obtendo os menores erros na previsão das facetas *Morality* (A2), *Altruism* (A3) e *Modesty* (A5). Em segundo lugar o melhor algoritmo foi o MTSC, obtendo os menores erros para prever *Trust* (A1) e *Cooperation* (A4). O algoritmo ERCC ficou na terceira posição, sendo o melhor para prever *Sympathy* (A6).

Aplicando o teste de Friedman obteve-se um p-value de 0.001, sendo assim existe diferença significativa entre os algoritmos com significância de  $\alpha = 0.05$  (p-value <  $\alpha$ ). Abaixo encontra-se o gráfico com os *mean ranks*, obtido por *forecast* após a aplicação do teste Nemenyi.



**Figura 26.** Ranqueamento dos indutores para *Agreeableness* [api R, 2018].

A Figura 26 mostra que o algoritmo MORF é o melhor de todos, mas que ele não possui diferenças significativas comparado aos algoritmos MTSC, ERC, ERCC, ST e MTS. Por outro lado o algoritmo *Genetic* é o pior de todos, mas ele não possui diferenças significativas quando comparado aos algoritmos MTS e ST.

O algoritmo eleito como melhor para prever facetas do traço *Agreeableness* (A) neste experimento foi o *Multi Objective Random Forests* (MORF).

#### **Anexo 1.4.5 Facetas de Neuroticism (N)**

Nestes experimentos utilizamos as seguintes siglas para referenciar as facetas de *Neuroticism* (N):

- 1) *Trust* (N1)
- 2) *Morality* (N2)
- 3) *Altruism* (N3)
- 4) *Cooperation* (N4)
- 5) *Modesty* (N5)
- 6) *Sympathy* (N6)

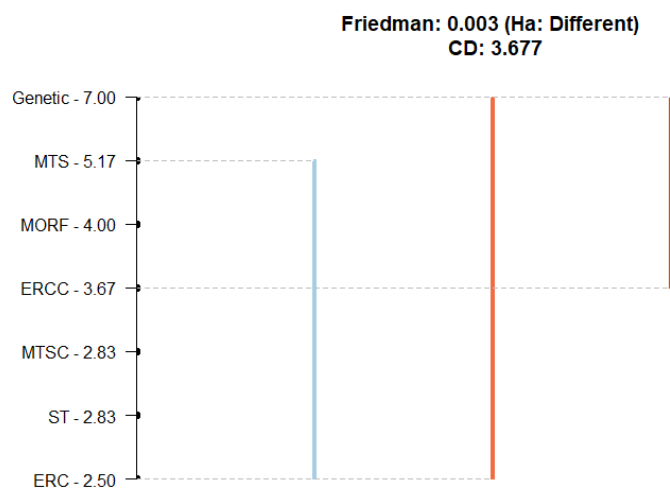
As Tabela 56 mostra o erro RRMSE para 6 facetas ou sub-traços de personalidade referentes ao traço *Neuroticism*:

N	N1	N2	N3	N4	N5	N6
ST	<b>0.99428</b>	1.00249	0.99647	0.98876	<b>0.95932</b>	1.01250
MTS	1.06058	1.04883	1.05429	<b>0.98395</b>	0.99134	1.04816
MTSC	1.00953	1.00245	<b>0.99117</b>	0.98818	0.96270	1.01226
MORF	1.01026	1.00169	0.99691	1.00321	0.98992	1.01136
ERC	1.00316	1.00032	1.00346	0.98867	0.96087	1.00634
ERCC	1.00131	<b>0.99639</b>	1.00633	0.98944	0.97942	<b>0.99656</b>
G	1.14606	1.14293	1.14305	1.14254	1.13702	1.14099

**Tabela 56.** RRMSE para as facetas de *Neuroticism* [api R, 2018].

Analisando a quantidade de erro de cada faceta, notamos que o algoritmo ERCC foi o melhor a prever as facetas *Morality* (N2) e *Sympathy* (N6) e o algoritmo ST foi o melhor para prever as facetas *Trust* (N1) e *Modesty* (N5) e aparentemente são os mais confiáveis. Os algoritmos MTS e MTSC empataram em segundo lugar, sendo os melhores para prever as facetas *Cooperation* (N4) e *Altruism* (N3) respectivamente. Mais uma vez o algoritmo Genético produziu muito erro comparado aos demais.

Aplicando o teste de Friedman obteve-se um p-value de 0.003, sendo assim existe diferença significativa entre os algoritmos com significância de  $\alpha = 0.05$  (p-value <  $\alpha$ ). Abaixo encontra-se o gráfico com os *mean ranks*, obtido por *forecast* após a aplicação do teste Nemenyi.



**Figura 27.** Ranqueamento dos indutores para *Neuroticism* [api R, 2018].

A Figura 27 mostra que o algoritmo ERC é o melhor de todos, mas que ele não possui diferenças significativas comparado ao algoritmos ST, MTSC, ERCC, MORF e MTS. Por outro lado o algoritmo Genetic é o pior de todos, mas ele não possui diferenças significativas quando comparado aos algoritmos MTS e MORF e ERCC.

O algoritmo eleito como melhor para prever facetas do traço *Neuroticism* (N) neste experimento foi o *Ensemble Regressor Chains* (ERC).

## **Anexo 1.5 Análise dos resultados preliminares**

As facetas são os sub-traços das dimensões de personalidade calculadas por um instrumento psicométrico. Estudar as capacidades dos indutores de preverem facetas é uma forma de melhorar a utilidade dos modelos de TB-APR, podendo abordar diversos aspectos da personalidade não se limitando apenas aos traços principais. As facetas podem ser úteis para os mais diversos sistemas computacionais incluindo sistemas de reputação, direcionamento de anúncios, customização de interfaces, seleção de recursos humanos, entre outros.

Outra vantagem de se trabalhar com as facetas é que como elas representam a fração de um traço de personalidade, elas também podem ser utilizadas para melhorar a capacidade de previsão do um traço de personalidade, sendo assim as facetas fornecem pistas de mais baixo nível da personalidade, utilizando um conjunto menor de variáveis no modelo de redução fatorial, sendo assim esperamos que algum trabalho futuro tire proveito dos modelos de previsão de facetas para ajudar a prever os traços.

Após verificar diversos trabalhos da literatura, encontramos três trabalhos que mencionam facetas da personalidade [Park et. al., 2015]; [Santos e Paraboni, 2019]; [Karanatsiou et al, 2020]. Destes trabalhos apenas os dois últimos mencionam modelos de previsão de facetas. Neste sentido, os experimentos de previsão de facetas desta tese, são os únicos, até onde temos conhecimento, que utilizam uma combinação expressiva de diferentes técnicas *top-down*, em conjunto com técnica *bottom-up* TF-IDF. Também são os únicos experimentos neste sentido para a língua portuguesa do Brasil.

Neste trabalho consideramos em experimentar o paradigma que mais se aproxima do problema real n-dimensional da personalidade, ou seja, a regressão multi-target, sem realizar simplificações de dados e a decomposição explícita deles antes de executar o indutor. Apesar dos algoritmos de regressão multi-target que utilizamos, utilizarem técnicas de decomposição do

problema internamente, a informação de previsão de cada modelo decomposto é sempre usada posteriormente para desenvolver um modelo final, sendo assim o modelo construído pelo algoritmo continua considerando o problema de personalidade em sua forma original, e como o espaço de previsão é bastante grande ( $Y' = 30$ ), abre um precedente de possibilidades de melhoria de performance utilizando este paradigma. Apesar do trabalho de Karanatsiou e seus colegas (2020) também utilizar este paradigma para prever facetas, o nosso trabalho utilizou uma quantidade muito maior de facetas ( $Y' = 30$  contra  $Y' = 2$ ) e também comparou a performance de 6 indutores multi-target, ao invés de utilizar apenas um indutor (ERC) como no trabalho citado [Karanatsiou, 2020].

Como este trabalho possui alguns pioneirismos nas abordagens utilizadas, não temos como dizer se nossos resultados foram melhores ou piores que aqueles encontrados na literatura, mas por outro lado podemos analisar nossos resultados para obter alguns *insights*. Os melhores algoritmos eleitos para prever as facetas de cada traço foram:

- 1) *Openness to experience (O)*: baseline *Single Target (ST)*.
- 2) *Conscientiousness (C)*: *Ensemble of Regressor Chains Corrected (ERCC)*
- 3) *Extraversion (E)*: *Ensemble of Regressor Chains (ERC)*
- 4) *Agreeableness (A)*: *Multi Objective Random Forests (MORF)*
- 5) *Neuroticism (N)*: *Ensemble Regressor Chains (ERC)*.

Notamos também em todos os experimentos uma performance significativamente baixa do algoritmo genético que propomos para fins de comparação, acreditamos que isto acontece devido ao próprio processo de evolução genética, que em algum momento se torna mais agressivo, fazendo um sobre ajuste do modelo sobre os folds de treinamento, não generalizando bem nos folds de testes (problema de overfitting). Tentamos corrigir este problema sem sucesso, utilizando diferentes parâmetros genéticos no que diz respeito às taxas de mutação e cruzamento, inclusive utilizamos diversos algoritmos internos de cruzamento (roleta, torneio, etc), adicionalmente fizemos outros ajustes como taxa de offspring, seleção de elitismo, número de gerações, número de população inicial, entre outros, mas infelizmente não obtivemos sucesso. As facetas do traço *Agreeableness* foram melhor previstas utilizando o algoritmo MORF, que possui um processo interno de seleção de características, sendo assim existem isto confirma a hipótese que existem outras possibilidades de indutores que fazem a seleção de características sem ocorrer o problema de overfitting.

Verificamos ainda nestes estudos que, para prever as facetas do traço *Openness to Experience* é melhor utilizar regressores single target, sendo assim utilizar as correlações de facetas já previstas parece prejudicar a capacidade de previsão do modelo.

As facetas referentes a três traços de personalidade, respectivamente *Extraversion*, *Neuroticism* e *Conscientiousness* tiveram de forma geral os melhores valores de previsão utilizando algoritmos baseados em correntes de regressores (ERC, ERCC), sendo assim futuramente novos experimentos poderão ser conduzidos testando diferentes tamanhos de correntes. Por outro lado, descobrimos que os regressores multi-target baseados em correntes necessitam de um tempo muito grande para construção de um modelo, utilizando uma corpus textual de pequeno porte (256 registros) a construção de um modelo pode levar uma semana (utilizando ERCC). Sendo assim, um estudo referente ao tempo de execução de cada regressor multi-target pode ser útil, comparando os prós e contras de cada abordagem.

Finalmente, devido ao grande espaço de características, sabemos que isto introduz alguns *bias* referentes a “maldição da dimensionalidade”. Sendo assim, esperávamos uma performance maior do algoritmo MORF e do algoritmo Genético, que exploram o espaço de características, e isto que não ocorreu. Apesar de tudo, não vemos isto com pessimismo, estas falhas permitiram *insights* no sentido de inovar a metodologia proposta por esta tese, deixando os inventários de personalidade em um segundo plano para explorar as técnicas projetivas. A bibliografia desta tese será comentada a seguir.



## BIBLIOGRAFIA

- [Adler, 1964] Adler, A. (1964). “Superiority and social interest: A collection of later writings.” (H. L. Ansbacher & R. R. Ansbacher). New York: Norton.
- [Aha, Kibler & Albert, 1991] Aha D. W., Kibler D., Albert M. K. (1991). “Instance-based learning algorithms”, *Machine Learning*, 6, 37-66, (1991). <https://doi.org/10.1023/A1022689900470>.
- [Almeida, 2017] Adriano, A. W. (2017). “Sentiment Analysis of Short Messages Using Affective Lexicons”, *Dissertação de Mestrado, PPGIA, PUCPR*.
- [Appel, 2010] Appel, A. (2010). “Métodos para o pré-processamento e mineração de grandes volumes de dados multidimensionais e redes complexas.” Tese de doutorado, Instituto de Ciências Matemáticas e de Computação – ICMS-USP, São Carlos, 2010.
- [Appel, 2010] Appel A. (2010). “Métodos para o pré-processamento e mineração de grandes volumes de dados multidimensionais e redes complexas.” Tese de doutorado, Instituto de Ciências Matemáticas e de Computação – ICMS-USP, São Carlos, 2010.
- [Ardic & Ozsoy, 2016] Ardic, K. Ozsoy, E. (2016). “Examining the Relationship between the Dark Triad Traits and Big Five Personality Dimensions” In *Proceeding of the Fifth European Academic Research Conference on Global Business, Economics, Finance and Banking (EAR16Turkey Conference)*, December, 2016, ISBNÇ978-1-943579-44-0.
- [Argamon et. al, 2005] Argamon, S. Dhawle, S. Koppel, M. Pennbaker, J. (2005) “Lexical predictors of personality type,” In *Proceedings of Interface and the Classification Society of North America*, 2005.
- [Arroju, Hassan & Fernadi, 2015] Arroju, M. Hassan, A. & Farnadi, G. (2015) “Age, Gender and Personality Recognition using Tweets in a Multilingual Setting,” in *6th Conference and Labs of the Evaluation Forum (CLEF 2015): Experimental IR meets multilinguality, multimodality and interaction*, 2015.
- [Barcaccia & Milioni; Vecchio, 2015] Barcaccia, B. Milioni, M. Pallini, S. Vecchio, G. M. (2015). “The validation of the Trait Forgivingness Scale (TFS).”
- [Barreiro, 2010] Barreiro, A. (2010). “Port4NooJ: An open source, ontology-driven Portuguese linguistic system with applications in machine translation.” In *Proceedings of the 2008 International NooJ Conference (NooJ’08)*, Budapest, Hungaria, 8–10 June 2008; Cambridge Scholars Publishing: Newcastle upon Tyne, UK, 2010.

- [Beck, 1952] Beck, S.J. (1952). "Rorschach's test." New York: Grune & Straton.
- [Benedetto et. al., 2002] Benedetto, D. Caglioti, E. Loreto, V. (2002). "Language trees and zipping." *Physical Review Letters*, 88(4), 04870.
- [Ben-Porath & Tellgen, 2008] Ben-Porath, Y. S. Tellegen, A. (2008). "MMPI-2-RF (Minnesota Multiphasic Personality Inventory-2 Restructured Form): Manual for administration, scoring, and interpretation." Minneapolis: University of Minnesota Press.
- [Bernstein, 1980] Bernstein, J. (1980). "Tests proyectivos lúdicos, verbales y gráficos." Em Bell, J.E. (Org.) *Técnicas proyectivas* (pp. 251-285). (G.A. Maci, Trad.). Buenos Aires: Paidós (Trabalho original publicado em 1948).
- [Black, 2004] Black P. E. (2004), "Euclidean distance", in *Dictionary of Algorithms and Data Structures* [online], Paul E. Black, ed., U.S. National Institute of Standards and Technology. 17 December 2004. Available from: <http://www.nist.gov/dads/HTML/euclidndstnc.html>.
- [Blei et. al., 2003] Blei, D. M. Andrew, Y. Ng. Jordan, M. I. (2003). "Latent dirichlet allocation." *Journal of Machine Learning Research*, 3, 993–1022.
- [Borchani et. al., 2015] Borchani, H. Varando, G. Bielza, C. Larrañga, P. (2015). "A survey on multi-output regression", *Journal Wiley Interdisciplinary Reviews*, Volume 5, Issue 5, p. 216-233. [44]
- Tsoumakas G, Spyromitros-Xioufis E, Vilcek J, Vlahavas I. (2011) "Mulan: A Java library for multi-label learning". *J. Mach. Learn. Res.* 2011, 12:2411–2414.
- [Bouckaert, 2004] Bouckaert, R. R. (2004). "Bayesian Network Classifiers in Weka".
- [Boyd, 2015] Boyd, R. L. (2015). "MEH: Meaning Extraction Helper [Software]." Available from <http://meh.ryanb.cc>.
- [Bradley & Lang, 1994] Bradley, M. Lang, P. (1994). "Measuring Emotion: The Self-Assessment Semantic Differential Manikin and the", *Journal of Behavior Therapy and Experimental Psychiatry*, 25(I), pp. 49–59. doi: 10.1016/0005-7916(94)90063-9.
- [Bradley & Lang, 1999] Bradley, M. Lang, P. (1999). "Affective Norms for English Words ( ANEW): Instruction Manual and Affective Ratings", *Psychology, Technical(C-1)*, p. 0. doi: 10.1109/MIC.2008.114.
- [Bandura, 1944] Bandura, A. (1994). "Social cognitive theory and mass communication." In: J. Bryant & D. Zillmann (Eds.). *Media effects: Advances in theory and research* (p. 61-90). Hillsdala, NJ: Earlbaum.

- [Bhamare & Kumar, 2019] Bhamare, M. Kumar, K. A. (2019) “Personality Prediction from Social Networks text using Machine Learning”, *International Journal of Recent Technology and Engineering (IJRTE)*, Volume 8, Issue 4, ISSN: 2277-3878, November, 2019.
- [Breiman, 2001] Breiman L. (2001), “Random Forests”, *Machine Learning*, 45(1), 5-32, <https://doi.org/10.1023/A:1010933404324>.
- [Breiman, 1996] Breiman L. (1996), “Bagging predictors,” *Machine Learning*, 24(2), 123-140.
- [Brunswik, 1952] Brunswik, E. (1952). “The conceptual framework of psychology.” (*International Encyclopedia of Unified Science*, Volume 1, Number 10.) Chicago: The University of Chicago Press.
- [Brunswik, 1955a] Brunswik, E. (1955a). “Representative design and probabilistic theory in a functional psychology.” *Psychological Review*, 62, 193-217.
- [Brunswik, 1955b] Brunswik, E. (1955b). “In defense of probabilistic functionalism: a reply. *Psychological Review*”, 62, 236-242.
- [Burisch & Matthias, 1984] Burisch, Matthias. (1984). “Approaches to personality inventory construction: A comparison of merits.” *American Psychologist*. 39. 214-227. 10.1037/0003-066X.39.3.214.
- [Buss, 1999] Buss, D. M. (1999). “Evolutionary psychology: The new science of the mind.” New York: Allyn and Bacon.
- [Cambria & Olsher; Rajagopal, 2014] Cambria, E. Olsher, D. Rajagopal, D. (2014). “SenticNet 3: A common and common-sense knowledge base for cognition-driven sentiment analysis.” In: *AAAI*, pp. 1515-1521, Quebec City, 2014.
- [Caprara, 1993] Caprara, G. V. Barbaranelli, I. C. Borgogni, L. Perugini, M. (1993). “The Big Five Questionnaire”: A new questionnaire to assess the Five Factor Model, In *Personality and Individual Differences*, vol. 3, p. 281-288, 1993.
- [Carvalho & Silva, 2015] Carvalho, P. Silva M. J. (2015) “Sentilex-PT: Principais características e potencialidades” *Oslo Studies in Language* 7(1) 2015. 425-438.
- [Celli et. al., 2013] Celli, F. Piaseni, F. Stillwell, D. Kosinsky, M. (2013), “Workshop on Computational Personality Recognition: Shared Task,” In *Proceedings of the Workshop on Computational Personality Recognition*. Boston, MA: AAAI Press.
- [Celli et. al., 2014] Celli, F. Lepri, B. Biel J. (2014) “The Workshop on Computational Personality Recognition 2014”.

- [Celli et al., 2016] Celli, F. Ghosh, A. Alam, F. Giuseppe R “In the mood for sharing contents: Emotions, personality and interaction styles in the diffusion of news,” *Information Processing and Management*, vol. 52, Issue1, pp. 93-98, January, 2016.
- [Celli & Lepri, 2018] Celli F & Lepri. B (2018) “Is Big Five Better than MBTI? A Personality Computing Challenge Using Twitter Data” in *CLiC-it*, 2018.
- [Cerny and Kaiser, 1977] Cerny, C.A. Kaiser, H.F. (1977). “A study of measure of sampling adequacy for factor- analytic correlation matrices.” *Multivariate Behavioral Research*, 12(1), 43-47. Kaiser, Hh. 1974. An index of factor simplicity. *Psychometrika* 39: 31-36.
- [Cessie & Houwelingen, 1992] Cessie S, Houwelingen J.C. (1992), “Ridge Estimators in Logistic Regression. *Applied Statistics*,” 41(1), 191-201, 1992.
- [Church & Hanks, 1990] Church, K. W. Hanks, P. (1990), “Word association norms, mutual information, and lexicography,” *Computational Linguistics*, 16, 22–29.
- [CLiPS, 2018] Link do corpus CLiPS: <https://www.clips.uantwerpen.be/datasets>.
- [Clore & Ortony, 2013] Clore, G. L. Ortony, A. (2013). “Psychological Construction in the OCC Model of Emotion. *Emotion Review*” *Journal of the International Society for Research on Emotion*, 5(4), 335–343. <http://doi.org/10.1177/1754073913489751>.
- [Cohn et al., 2004] Cohn, M.A. Mehl, M.R. Pennebaker, J.W. (2004) “Linguistic markers of psychological change surround September, 11, 2001”, *Psychological Science*, Vol 15, pages 687-693, doi: 10.1111/j.0956-7976.2004.00741.x
- [Coltheart, 1981] Coltheart, M., “The MRC psycholinguistic database. *Quarterly Journal of Experimental Psychology*”, 33A, 497–505.
- [Córdoba & Piagem, 1946] Córdoba, J. Piagem, J.M. (1946). “La expresión desiderativa como manifestación de la personalidad” *Medicina Clínica*, 4(3), 2023.
- [Costa & McCrae, 1992] Costa, P. T. Jr. McCrae, R. R. (1992). “Revised NEO personality inventory (NEO PI-R) and NEO five -factor inventory (NEO-FFI):Professional manual.” Odessa, FL: Psychological Assessment Resources
- [Crowne, 2007] Crowne, D. P. (2007). “*Personality Theory*.” Don Mills, ON, Canada: Oxford University Press. ISBN 978-0-19-542218-4.
- [Daelemans et al.,1999] Daelemans, W. Bucholz, S. Veenstra, J. (1999) “Memory-Based Shallow Parsing.”, In *Proceedings of the Third Conference on Computational Natural Language Learning (CoNLL)*, pages 53–60.

- [Runes, 1972] Runes, D. D. (1972) “Dictionary of Philosophy”, Littlefield, Adams and Company, Totowa, 1972.
- [Davis, 1980] Davis, M. H. (1980). “A multidimensional approach to individual differences in empathy.” *JSAS Catalog of Selected Documents in Psychology*, 10, 85.
- [Dias-da-Silva, 2006] Dias-da-Silva, B.C. (2006) “Wordnet.Br: An exercise of human language technology research.” In *Proceedings of the 3rd International WordNet Conference (GWC)*, Jeju Island, Korea, 22–26 January 2006; pp. 301–303.
- [DSM-IV, 1994] American Psychiatric Association. (1994) “Diagnostic and statistical manual of mental disorders. 4th ed.” Washington: American Psychiatric Association; 1994.
- [DSM-V, 2014] APA, (2014), “Diagnostic and Statistical Manual of Mental Disorders”, fifth edition, American Psychiatric Association, Washington, 5th Ed., 2014.
- [Dumais, Heckerman & Shami, 1988] Dumais, S. Platt, J. Heckerman D. Sahami M. (1988) “Inductive learning algorithms and representations for text categorization,” in *Proceedings of the International Conference on Information and Knowledge Management*, pp. 148–155, 1998.
- [Dusey, 1972] Dusey, J.M. (1972) “Egograms and the constancy hypothesis.” *Transactional Analysis Journal*, 2, 37-42.
- [Erickson, 1968] Erikson, E. H. (1968). “Identity: Youth and crisis.” New York: Norton.
- [Esuli & Sebastiani, 2006] Esuli, A. Sebastiani, F. (2006). “Sentiwordnet: A publicly available lexical resource for opinion mining.” In: *Proceedings of LREC*, p. 417-422, 2006.
- [Exner, 1974] Exner. J.E. (1974). “The Rorschach: A comprehensive system: Vol, 1.”, New York: Wiley.
- [Eysenck et, al., 1991] Eysenck, S. Eysenck, H. and Barrett, P. (1991) “Personality Questionnaire-Revised.” Hodder, London.
- [Eysenk, 1959] Eysenck, H.J. (1959). “The Rorschach Inkblot Test.” In O.K. Buros (Ed.), *The fifth mental measurements yearbook* (pp. 276-278). Highland Park. NJ: Gryphon Press.
- [Fayyad, Irani, 1992] Fayyad, U. M. and Irani, K. B. “Multi-interval discretisation of continuous-valued attributes,” in *Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence*, p. 1022–1027, Morgan Kaufmann, (1993).
- [Feist & Feist; Roberts, 2015] Feist, J. Feist; G. J. Roberts, T. (2015). “Teorias da personalidade.” 8<sup>a</sup> ed. Tradução Sandra Maria Mallmann da Rosa. 8<sup>a</sup> ed. Porto Alegre: AMGH.

- [Fernandi et. al., 2014] Fernandi G. Sushmita S. Sitaraman G. Ton N. Cock M. Davalos S. (2014). “A Multivariate Regression Approach to the Personality Impression Recognition of Vloggers”.
- [Forsyth & Holmes, 1996] Forsyth, R. Holmes, D. (1996). “Feature-finding for text classification. *Literary and Linguistic Computing*”, 11(4), 163-174.
- [Fragoso, Bertoli & Louzada, 2018] Fragoso T. M., Bertoli W., Louzada F. (2018), “Bayesian Model Averaging: A Systematic Review and Conceptual Classification”, *International Statistical Review*, 86(1), 1-28, DOI: 10.1111/insr.12243.
- [Freud, 1905/1953b] Freud, S. (1905/1953b). “Three essays on the theory of sexuality.” In *Standart edition (Vol 7.)*
- [Freud, 1911/1958] Freud, S. (1911/1958). “Formulations on the two principles of mental functioning. ” In *Standart edition (Vol. 12).*
- [Freud, 1915/1957a] Freud, S. (1915/1957a). “Insticts and their vicissitudes.” In *Standart edition (Vol. 14).*
- [Freud, 1915/1957b] Freud, S. (1915/1957b). “The unconscious.” In *standart edition (Vol.14).*
- [Freud, 1915] Freud, S. (1915). “O recalque”. In: *Edição Standard Brasileira das Obras Psicológicas Completas de Sigmund Freud. Rio de Janeiro: Imago, 2007. v.I.*
- [Freud, 1917/1963] Freud, S. (1917/1911). “Intrdoctory lectures on psychoanalysis. In *Standart edition (Vols. 15 & 16).*
- [Freud, 1920/1955a] Freud, S. (1920/1955) “Beyond the pleasure principle.” In *Standart edition (vol. 18).*
- [Freud, 1923/1961a] Freud, S. (1923/1961a) “The ego and the id.” In *Standart edition (Vol. 19).*
- [Freud, 1924/1961] Freud, S. (1924/1961) “The dissolution of the Oedipus Complex.” In *Standart edition (Vol. 19).*
- [Freud, 1924] Freud, S. (1924). “A perda da realidade na neurose e na psicose” In: *Edição Standart Brasileira das Obras Psicológicas Completas de Sigmound Freud. Rio de Janeiro: Imago, 2007. V. III.*
- [Freud, 1924a] Freud, S. (1924). “Neurose e psicose” In: *Edição Standart Brasileira das Obras Psicológicas Completas de Sigmound Freud. Rio de Janeiro: Imago, 2007. V. III.*
- [Freud, 1933/1964] “New Introductory Lectures on psychoanalysis” In *Standart Edition. (Vol. 22).*

[Freud, 1936] Freud, A. (1936). "O Ego e Seus Mecanismos de Defesa." New York, Fawcett Books, Rio de Janeiro.

[Freud, 1946] Freud, A. (1946). "The ego and the mechanisms of defense". New York: International Universities Press.

[Friedman, 2001] Friedman, J. H. (2001), "Greedy function approximation: A gradient boosting machine," *Ann. Statist.* 29 (5), 1189 - 1232, October, 2001, <https://doi.org/10.1214/aos/1013203451>.

[Fromm, 1963] Fromm, E. (1963). "The dogma of Christ and other essays on religion, psychology and culture." New York: Holt, Rinehart and Winston.

[Geng & Hou, 2015] X. Geng. P. Hou. (2015). "Pre-release prediction of crowd opinion on movies by label distribution learning" in *Proceedings of the 24th International Joint Conference on Artificial Intelligence*, Buenos Aires, Argentina, 2015, pp. 3511-3517.

[Geng, 2016] Geng, X. "Label distribution learning." *IEEE Transactions on Knowledge and Data Engineering*, 2016.

[Gentile et. al., 2013] Gentile, B. Miller, J. Hoffman, B. Reidy, D. Zeichner, A. Campbell, K. W. (2013). "A Test of Two Brief Measures of Grandiose Narcissism: The Narcissistic Personality Inventory-13 and the Narcissistic Personality Inventory-16." *Psychological assessment*. 25. 10.1037/a0033192.

[Gill et. al., 2002] Gill, J. A. Oberlander, J. Place, B. Uk, Eh. Lw. (2002). "Taking Care of the Linguistic Features of Extraversion."

[Gill et. al., 2009] Gill, A. J. Nowson, S. Oberlander, J. (2009) "What Are They Blogging About? Personality, Topic and Motivation in Blogs.", ICWSM. ed. Eytan Adar; Matthew Hurst; Tim Finin; Natalie S. Glance; Nicolas Nicolov; Belle L. Tseng. The AAAI Press, 2009. p. 18-25.

[Goldbeck et. al., 2011] Golbeck, J. Robles, C. Edmondson, M. Turner, K. (2011) "Predicting personality from Twitter", in *IEEE international conference on privacy, security, risk and trust, and IEEE international conference on social computin*, pp. 149–156, 2011.

[Goldberg et, al., 2006] Goldberg, L. R. Johnson, J. A. Eber, H. W. Hogan, R. Ashton, M. C. Cloninger, C. R. Gough, H. G. (2006). "The international personality item pool and the future of public domain personality measures." *Journal of Research in Personality*, 40, 84–96. <http://dx.doi.org/10.1016/j.jrp.2005.08.0>.

[Goldberg, 1999] Goldberg L. R. (1999) "A broad-bandwidth, public domain, personality inventory measuring the lower-level facets of several five-factor models". In. I. Mervielde, I.; Deary, F.; De

Freuyt & F. Ostendorf (Eds). *Personality Psychology in Europe*. Tilburg, The Netherlands, Tilburg University Press, vol 7, p. 7-28.

[Gonçalo et. al., 2008] Gonçalo Oliveira, H. Santos, D. Gomes, P. Seco, N. “PAPEL: A Dictionary-Based Lexical Ontology for Portuguese.” In Proceedings of 8th International Conference on Computational Processing of the Portuguese Language (PROPOR 2008); Lecture Notes in Computer Science; Springer. Berlin, Germany, 2008; Volume 5190, pp. 31-40.

[Gonçalo, 2018] Gonçalo Oliveira, H. (2018) “A Survey on Portuguese Lexical Knowledge Bases: Contents, Comparison and Combination.” *Information* 2018, 9, 34.

[Gorter & Pennebaker, 2003] Gortner E. M. Pennebaker. J. W. (2003) “The anatomy of a disaster: Media coverage and community-wide health effects of the Texas A&M bonfire tragedy.” *Journal of Social and Clinical Psychology*, in press.

[Gosling, 2003] Gosling, S. D. Rentfrow, P. J. Swann Jr, W. B. “A very brief measure of the Bigfive personality domains.” *Journal of Research in Personality*, p. 504–528, 2003.

[Green & Swets, 1989] Green, D. Swets J. A. (1989) “Signal Detection Theory and Psychophysics”, Los Altos, Usa: Peninsula Publishing, 1989.

[Guardian, 2018] link: <https://www.theguardian.com/world/2015/mar/27/germanwings-co-pilot-andreas-lubitzs-background-under-scrutiny>, acesso em março, 2018.

[Gurevych et al, 2012] Gurevych I. Eckle-Kohler J. Hartmann S. Matuschek M. Meyer C. M. Wirth. C. (2012). “Uby - a largescale unified lexical-semantic resource based on lmf.” In Proceedings of the 13th Conference of the European Chapter of the Association for Computational Linguistics (EACL 2012), pages 580–590.

[Guyon & Elisseff, 2003] Guyon, I. Elisseeff, A. (2003). “An introduction to variable and feature selection.” *Journal of Machine Learning Research*, 3, 1157–1182.

[Hall & Holmes, 2003] Hall, M. A. Holmes, G. H. (2003) “Benchmarking Attribute Selection Techniques for Discrete Class Data Mining”, *IEEE Transactions on Knowledge and Data Engineering*, vol. 15, no. 3, may/june, 2003.

[Hare, 1999] Hare, R. D. (1999). “Psychopathy as a Risk Factor for Violence.” *The Psychiatric quarterly*. 70. 181-97. 10.1023/A:1022094925150.

[Hartley, 1928] Hartley, R. V. L. (1928), “Transmission of Information”, *Bell System Technical Journal*, 1928.



[Hendin & Cheek, 2013] Hendin, H. M. Chack, J.M. (2013). “The Hypersensitive Narcissism Scale (HSNS)” Measurement Instrument for the Social Science.

[Hendriks, 1997] Hendriks, A. A. J. “The construction of the Five-Factor Personality Inventory (FFPI).” University of Groningen, Holanda, 1997.

[Ho et. al., 2002] Ho, R. ForsterLee, L. Forsterlee, R. Crofts, N. (2002). “Justice versus vengeance: Motives underlying punitive judgements.” *Personality and Individual Differences*. 33. 365-377. 10.1016/S0191-8869(01)00161-1.

[Hoerl & Kennard, 1970] Hoerl, A. E. Kennard, R. W. (1970). “Ridge regression: Biased estimation for nonorthogonal problems.” *Technometrics*, 12, 55–67.

[Hollander & Wolfe; Chiken, 2013] Hollander, M. Wolfe, D A. Chicken, E. (2013) “Nonparametric Statistical Methods” John Wiley & Sons. ISBN 9781118553299.

[Hora & Monteiro; Arica, 2010] Hora, H. R. M. Monteiro, G. T. R. Arica, J. “Confiabilidade em Questionários para Qualidade: Um Estudo com o Coeficiente Alfa de Cronbach.” *Produto & Produção*, v. 11, n. 2, p. 85-103, 2010.

[Horney, 1917/1968] Horney, K. “The technique of psychoanalytic therapy.” *American Journal of psychoanalysis*, 28, 3-12.

[Horney, 1994] Horney, K. (1994). “Woman’s fear of action.” In: B. J. Paris, Karen Horney: A psychoanalyst’s search for self-understanding (p. 233-238). New Haven, CT: Yale University Press.

[Horsmann & Torsen, 2016] Horsmann, T. Zesch, T. (2016). “Assigning Fine – Grained PoS Tags based on High-precision Coarse-grained Tagging.” *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*, pages 328–336, Osaka, Japan, December (11-17 2016).

[Yang & Huang, 2019] Yang h, Huang Z. (2019) “Mining personality traits from social messages for game recommender systems”, *Knowledge-Based Systems*, Volume 165, Pages 157-168, 2019, ISSN 0950-7051.

[Iacobelli & Cullota, 2013] Iacobelli, F.; Cullota, A. (2013). “Too Neurotic not too Friendly: Structured Personality Classification on Textual data”, *Workshop on Personality recognition (shared task)*, 2013.

[Iacobelli et. al, 2013] Iacobelli, F. Cullota, A. (2013). “Too Neurotic not too Friendly: Structured Personality Classification on Textual data”, *Workshop on Personality recognition (shared task)*, 2013.

- [ICD-10, 2004] WHO. (2004). “International Statistical Classification of Diseases and Related Health Problems”, Tenth Revision, Volume 2, Second Edition, World Health Organization, Geneva.
- [IDC-10-CM, 2017] WHO. CMS. NCHS. (2017). “ICD-10-CM Official Guidelines for Coding and Reporting FY 2017”, Tenth Revision, Clinical Modification, FY2017, World Health Organization, The Centers for Medicare and Medicaid Services, National Center for Health Statistics, 2017.
- [Jackson, 1974] Jackson, D. N. (1974). “Manual for the Personality Research Form.” Goshen, NY: Research Psychology Press.
- [Jacquemin et. al, 2003], Jacquemin, A. Barbieri, V. Okino, E. T. (2003) “Manual prático do teste de apercepção temática (T.A.T.)”, revisão por Valéria Barbieri, Mimeo, 41p.
- [Jelodar et. al, 2017] Hamed, J. Wang, Y. Yuan, C. Feng, X. (2017). “Latent Dirichlet Allocation (LDA) and Topic modeling: models, applications, a survey”.
- [Jenkins, 2008], Jenkins, S. R. (2008). “A handbook of Clinical Scoring Systems for Thematic Apperceptive Techniques,” Mahwah, NJ: Erlbaum, 2008.
- [Jensen, 1965] Jensen, A.R. (1965). “The Rorschach Inkblot Test.” In O.K. Buros (Ed.), The sixth mental measurements yearbook (pp. 501-509). Highland Park, NJ: Gryphon Press.
- [Joaquim, 2010] Joaquim N. (2010), “Inferência Bayesiana”, Universidade Federal de Juíz de Fora (UFJF), consultado em fevereiro de 2021, link: [https://www.ufjf.br/joaquim\\_netto/files/2009/09/IB-Slides-v1.1.pdf](https://www.ufjf.br/joaquim_netto/files/2009/09/IB-Slides-v1.1.pdf).
- [Johnson, 2000] Johnson, J. A. “Web-based personality assessment.” In: *71st Annual Meeting of the Eastern Psychological Association*, Baltimore, USA, 2000
- [Johnson, 2014] Johnson, J. A. (2014) “Measuring Thirty Facets of the Five Factor Model with a 120-item Public Domain Inventory: Development of the IPIP-NEO-120”, In *Journal of Research in Personality*, c. 51, p. 78-89.
- [Johnson, 2014] Johnson, J. A. “Measuring thirty facets of the Five Factor Model with a 120-item public domain inventory:” Development of the IPIP-NEO-120. *Journal of Research in Personality*, p. 78-89, 2014.
- [Jones & Paulhus, 2013] Jones, D. & Paulhus, D. (2013). “Introducing the Short Dark Triad (SD3): A Brief Measure of Dark Personality Traits.” *Assessment*. 21. 10.1177/1073191113514105.
- [Platt, 1998] Platt, J. “Fast Training Support Vector Machines using Sequential Minimal Optimization,” In B. Schoelkopf and C. Burges and A. Smola, editors, *Advances in Kernel Methods – Support Vector Learning*, 1998.

- [Jung, 1948/1960b] Jung, C.G.(1954/1959a). "On the nature of dreams". In *Collected works* (Vol.8).
- [Jung, 1954/1959a] Jung, C.G.(1954/1959a). "Archetypes and the collective unconscious". In *Collected works* (Vol.9, Pt.1).
- [Jung, 1954/1959b] Jung, C.G.(1954/1959b). "Concerning the archetypes, with special reference to the anima concept.". In *Collected works* (Vol.9, Pt.1).
- [Jung, 1975] Jung, C.G. (1975). "Letters II: 1951-1961." (G. Adler e A. Jaffé, Eds.) (Transl. R. D. C. Hull). Princeton, NJ: Princeton University Press.
- [Jung, 2002] Jung, C. G. (2002). "Os arquétipos e o inconsciente coletivo", 2ª. ed, Petrópolis, Editora
- [kalmegh, 2015] Kalmegh, S. (2015). "Analysis of Weka Data Mining Algorithm REPTree, Simple Cart, and RandomTree for classification of Indian News." *IJISET- International Journal of Innovative Science, Engineering & Technology*, Vol 2, Issue 2, February, 2015, ISSN 2348-7968, India.
- [Karanatsiou et al, 2020] Karanatsiou, D. Sermpezis, P. Gruda, J. Kafetsios, K. Dimitriadis, I. Vakali, A. (2020), "My tweets bring all the traits to the yard: Predicting personality and relational traits in Online Social Networks," Cornell University, arXiv2009.10802, 2020.
- Keerthi, S. S. Shevade, S. K. Bhattacharyya, C. Murthy, K.R.K. (2001). "Improvements to Platt's SMO Algorithm for SVM Classifier Design." *Neural Computation*, 13(3), p. 637-649.
- [Kelly, 1955] Kelly, G. A. (1955). "The psychology of personal constructs." v. 1 & 2. New York: Norton.
- [Klein & Benjamin, 1996] Klein, M. H. Benjamin, L. S. (1996). "The Wisconsin Personality Disorders Inventory-IV." Madison, WI: University of Wisconsin, unpublished test. Available from Dr. M. H. Klein, Department of Psychiatry, Wisconsin Psychiatric Institute and Clinic, 6001 Research Park Blvd., Madison, WI 53719-1179.
- [Klein, 1946/ 1975] Klein, M. (1991). "Notes on some schizoid mechanism" In M. Klein, *Envy and gratitude and other works, 1946-1963* (pp. 1-24). New York: Delta books.
- [Klein, 1959/ 1984] Klein, M. (1991). "Our adult world and its roots in infancy" In M. Klein, *Envy and gratitude and other works, 1946-1963* (pp. 247-263). New York: Macmillan.
- [Klein, 1991] Klein, M. (1991). "The emotional life and ego development of the infant with special reference to the depressive position." In: P. King and R. Steiner (Eds.). *The Freud-Klein controversies: 1941-45* (p. 752-797). London: Tavistock/ Routledge.

- [Klein, 1993] Klein, M. H. (1993). "Issues in the assessment of personality disorders." *Journal of Personality Disorders, Supplement*, 18–33.
- [Klopfer, 1974] Klopfer, B. Kelley, D. (1974). "Técnica del psicodiagnóstico de Rorschach" (V.L.S. de Campo, Trad.) Buenos Aires: Paidós (Trabalho original publicado em 1946).
- [Kohavi, 1995] Kohavi, R. (1995) "A study of cross-validation and bootstrap for accuracy estimation and model selection. In: International joint Conference on artificial intelligence." [S.l.: s.n.], 1995. v. 14, p. 1137–1145.
- [Kosinski & Stillwell, 2011] Kosinski, M. Stillwell, D. J. (2011). "myPersonality Research Wiki. myPersonality Project." Retrieved from <http://mypersonality.org/wiki>.
- [Kramer et. al., 2006] Kramer, A.D.I. Oh, L.M. Fussell, S.R. (2006). "Using linguistic features to measure presence in computermediated communication." *CHI 2006 Notes* (pp. 913-916). NY: ACM Press.
- [Lacan, 1998] Lacan, J. (1998). "Escritos.". Campo Freudiano no Brasil, Jorge Zahar Editor. ISBN 85-7110-443-3.
- [Lacoste-Julien, 2007] Lacoste-julien, S. (2007). "Slides de apresentação." *Machine Learning Workshop*:  
<https://pdfs.semanticscholar.org/presentation/4c3c/fce46abebbb808b172a088cdb0386f40272f1.pdf>, disponível em março, 2018.
- [Lafferty et. al, 2001] Lafferty, J. McCallum, A. Pereira, F. (2001) "Conditional random fields: Probabilistic models for segmenting and labeling sequence data.", In *Proc. 18th International Conf. on Machine Learning*, 282–289.
- [Lahaye, 1992] Lahaye, T. (1992). "Spirit-Controlled Temperament." Tyndale House Publishers, Inc, Carol Stream, Illinois.
- [Likert, 1932] Likert, R. "A technique for the measurement of attitudes." *Archives of psychology*, 1932.
- [Lima & Castro, 2013] Lima, A.C.E.S. Castro, L.N. (2013) "Multi-label Semi-supervised Classification Applied to Personality Prediction in Tweets," in *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*, 2013, pp. 195–203.

- [Luyckx and Daelemans, 2008] Luckx, K. Daelemans, W. (2008). "Personae, a Corpus for Author and Personality Prediction from Text.". In: Proceedings of the Sixth International Conference on Language Resources and Evaluation (LREC 2008), Marrakech, Morocco.
- [Madjarov, 2012] Madjarov, G. Kocev, D. Gjorgjevikj, D. Džeroski, S. (2012). "An extensive experimental comparison of methods for multi-label learning". *Pattern Recognition*. 45 (9): 3084–3104. doi:10.1016/j.patcog.2012.03.004.
- [Mairesse, 2007] Mairesse, F. Walker, M. A. Mehl, M. R. Moore, R. K. (2007). "Using linguistic cues for the automatic recognition of personality in conversation and text." *Journal of Artificial Intelligence Research*, 30(1), 457–500.
- [Majumder, 2017] Majumder N. Poria, S Gelbukh A. Cambria E. (2017) "Deep learning-based document modeling for personality detection from text. *IEEE Intelligent Systems*", pages 74–79.
- [Bhamare & Kumar, 2019] Bhamare M & Kumar K. A. (2019) "Personality Prediction from Social Networks Text using Machine Learning", *International Journal of Recent Technology and Engineering (IJRTE)*, Vol. 8, Issue 4, 2019.
- [Manuzero et. al., 2014] Munezero, M. (2014). "Are they different? affect, feeling, emotion, sentiment, and opinion detection in text", *IEEE Transactions on Affective Computing*, 5(2), pp. 101–111. doi: 10.1109/TAFFC.2014.2317187.
- [Maquiavel, 2011] Maquiavel, N. "O Príncipe" Tradução de Antonio Cauccio-Caporale, L&PM Pocket:Porto Alegre, 2011.
- [Markon et. al., 2013] Markon, K.E. Quilty, L.C. Bagby, R.M. Krueger, R.F. (2013). "The development and psychometric properties of an informant-report form of the Personality Inventory for DSM-5 (PID-5)" *Assessment*. 2013;20:370–383. doi: 10.1177/1073191113486513.
- [Martinsson et al., 2011] Martinsson, P. G. Rokhlin, V. Tygert, M. (2011). "A randomized algorithm for the decomposition of matrices." *Applied and Computational Harmonic Analysis*, 30, 47–68. <http://dx.doi.org/10.1016/j.acha.2010.02.00>.
- [Marton et. al., 2005] Marton, Y. Wu, N. Hellerstein, L. (2005). "On compression-based text classification." In *Proceedings of the European Conference on Information Retrieval* (pp. 300–314) Springer.
- [Matthiessen and Bateman, 1991] Matthiessen, C. Bateman, J. A. (1991) "Text generation and systemic-functional linguistics: experiences from English and Japanese", Frances Pinter Publishers and St. Martin's Press, London and New York, 1991.

- [Maziero et. al., 2008] Maziero, E.G. Pardo, T.A.S. Felippo, A.D. Dias-da-Silva, B.C. A. (2008) “A base de dados Lexical e a Interface Web do TeP 2.0” Thesaurus Eletrônico para o Português do Brasil. In Proceedings of the Companion Proceedings of the XIV Brazilian Symposium on Multimedia and the Web, Vila Velha, Brazil, 26–29 October 2008; ACM: New York, NY, USA, 2008; pp. 390–392.
- [McClelland, 1985] McClelland, D. C. (1985). “Human motivation.” Glenview, IL: Scott, Foresman.
- [McClure, 1987] McClure, G (1987). "Readability formulas: Useful or useless. (an interview with J. Peter Kincaid.)". IEEE Transactions on Professional Communications.
- [McCrae & Costa, 1999] McCrae, R. R. Costa, P. T. (1999) “A five-factor theory of personality.” *Handbook of Personality: Theory and Research*, v. 2, p. 139-153, 1999.
- [McCrae & John, 1992] McCrae, R. R. John, O. P. (1992) “An Introduction to the Five-factor Model and its Applications”, *Journal of Personality*, v. 60, n. 2, p. 175-215.
- [McDougall, 1932] McDougall, W. (1932) “Of the Words Character and Personality”, In *Character Personality*, v. 1, n. 1, p. 3-16.
- [Mehl et. al., 2001] Mehl, M. Pennebaker, J. Crow, M. Dabbs, J. Price, J. (2001). “The Electronically Activated Recorder (EAR): A device for sampling naturalistic daily activities and conversations.” *Behavior Research Methods, Instruments, and Computers*, 33, 517– 523.
- [Miller et. al., 2013] Miller, T. Erbs, N. Zorn, H; Zesch, T. Gurevych I. (2013). “DKPro WSD: A generalized UIMA-based framework for word sense disambiguation.” In Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (System Demonstrations) (ACL 2013), pages 37–42.
- [Minamikawa & Yokoyama, 2011] Minamikawa, A. Yokoyama, H. (2011). "Blog tells what kind of personality you have: Egogram estimation from Japanese weblog", *Proc. ACM Conf. Comput. Supported Cooperative Work*, pp. 217-220, 2011. Access at ACM.
- [Mohammad, Kritchenco; Zhu, 2013] Mohammad, S. M. Kiritchenko, S. Zhu, X. (2013) “NRC-Canada: Building the State-of-the-Art in Sentiment Analysis of Tweets.” Proceedings of the seventh international workshop on Semantic Evaluation Exercises (SemEval-2013), 2(SemEval), pp. 321–327.
- [Morgan & Murray, 1935] Morgan, C. Murray, H. A. (1935). A method for investigating fantasies: The Thematic Apperception Test. *Archives of Neurology and Psychiatry*, 34, 289-306.

[Murray, 1943] Murray, H. A. (1943). "Analysis of The Personality of Adolf Hitler. With Predictions of His Future Behavior and Suggestions for Dealing with Him Now and After Germany's Surrender", Harvard Psychological Clinic, O.S.S Confidential, October, 1943.

Murray, H. A. (1938). "Explorations in personality: A clinical and experimental study of fifty men of college age," New York: Oxford University Press, 1938.

[Murray, 2005] Murray, H. A. (1943). "T.A.T.: Teste de apercepção temática. Henry A. Murray e colaboradores da Clínica Psicológica de Harvard (adaptação e padronização brasileira: Maria Cecília Vilhena da Silva)," 3ª Ed. adaptada e ampliada. São Paulo: Casa do Psicólogo. (Original publicado em 1943), 2005.

Morval M. V. G. (1982) "Le T.A.T. et le fonctions du moi: Propédeutique à l'usage du psychologue clinicien", 2e Ed., Montréal: Les Presses de l'Université de Montréal, 1982.

[Myers & Myers, 1980] Myers, I. B. and Myers, P.B. (1980). "Gifts differing: Understanding personality type.", Mountain View, CA: Davies-Black Publishing.

[Nardi, 2018] Instituto Cibeli Nardi, disponível em: <http://www.institutocibelenardi.com.br/wp-content/uploads/2017/09/EGOGRAMA-COMPLETO-ICN.pdf>, acesso em março, 2018.

[Nasio, 1992] Nasio, J. D. (1992). "Cinco lições sobre a teoria de Jacques Lacan", Rio de Janeiro, Zahar.

[Neumann, 2016] Neumann, Y. (2016). "Personality Comnputacional Analysis – Introduction, Pratical Applications and Novel Directions." Springer, 2016.

[Nowson & Gill, 2014] Nowson S. Gill J. (2014). "Look! Who's Talking? Projection of Extraversion Across Different Social Contexts" The workshop on Computacional Personality Recognition, 2014.

[Nowson & Oberlander 2007] Nowson, S. Oberlander, J. (2007). "Identifying more bloggers: Towards large scale personality classification of personal weblogs." International Conference on Weblogs and Social Media 2007. Boulder, Colorado.

[Nowson & oberlander, 2006c] Nowson, S. Oberlander, J. "The Indentity of Bloggers: Openness and gender in personal weblogs.", School of Informatics, Univercity of Edinburg.

[Oberlander & Gill, 2004] Oberlander, J. Gill, A. (2004) "Language generation and personality: two dimensions, two stages, two hemispheres?" School of Informatics, University of Edinburgh.

[Oberlander & Nowson, 2006] Oberlander, J. Nowson, S. (2006). "Whose thumb is it away? Classifying author personality from weblog text." Proceedings of the COLING/ACL 2006 Main

Conference Poster Sessions, pages 627–634, Sydney, July 2006. Association for Computational Linguistics.

[Oberlander et. al., 2006b] Oberlander, J. & Gill, J. A. (2006). “A stratified corpus comparison in e-mail communication.”. Academic work.

[Ocampo et al, 1999] Ocampo, M. L. S. Arzeno, M. E. G. Piccolo, E. G. (1999). “O processo psicodiagnóstico e as técnicas projetivas.” 9ª. ed, São Paulo, Martin Fontes.

[Oldham, 2015] Oldham, J. M. (2015). “The alternative DSM-V model for personality disorders”, *World Psychiatry* 2015, pp.14(2):234-236, doi:10.1002/wps.20232.

[Ortony & Clore; Foss, 1987] Ortony, A. Clore, G. L. Foss, M. A. (1987). “The Referential Structure of the Affective Lexicon”, 1987.

[OT.PT, 2018] Léxico OT-PT disponível em:

<http://paginas.fe.up.pt/~arocha/AED1/0607/trabalhos/thesaurus.txt>, janeiro, 2018.

[Paiva et. al., 2012] De Paiva, V. Rademaker, A. De Melo, G. “OpenWordNet-PT: An Open Brazilian WordNet for Reasoning.” In Proceedings of the 24th International Conference on Computational Linguistics (COLING), Mumbai, India, 8–15 December 2012.

[Park et. al., 2015] Park, G. Schwartz, H. A. Eichstaedt, J. C. Kern, M. L. Kosinski, M. Stillwell, D. J. Ungar, L. H. Seligman, M. E. P. (2015). “Automatic Personality Assessment Through Social Media Language.” *Journal of Personality and Social Psychology*. Advance online publication. <http://dx.doi.org/10.1037/pspp0000020>.

[Pasian, 1988], Pasian S. R. (1988). “O psicodiagnóstico de Rorschach: Um estudo normativo em adultos,” Tese de doutorado, Faculdade de Medicina de Riberão Preto, Universidade de São Paulo, Riberão Preto.

[Pasqualotti & Vieira, 2008] Pasqualotti, P. R. Vieira, R. (2008). “WordnetAffectBR: uma base lexical de palavras de emoções para a língua portuguesa”, 2008.

[Paulhus & Williams, 2002] Paulhus, D. L. Williams, K. M. (2002). “The Dark Triad of personality: Narcissism, Machiavellianism, and Psychopathy.” *Journal of Research in Personality*, 36, 556–563.

[Pedregosa et al, 2011] Pedregosa, F. Varoquaux, G. Gramfort, A. Michel, V. Thirion, B. Grisel, O. Blondel, M. Prettenhofer, P. Weiss, R. Doubnourg, V. Vanderplas, J. Passos, A. Cournapeau, D. Brucher, M. Perrot, M. Duchesnay E. (2011), “Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, p. 2825 – 2830, 2011.



- [Pennebaker & Francis, 1999] Pennebaker, J. W. Francis, M. E. (1999). "Linguistic Inquiry and Word Count: LIWC." Mahwah, NJ: Erlbaum.
- [Pennebaker & King, 1999] Pennabaker, J. W. King, L. (1999). "Linguistic styles: Language use as an individual difference." *Journal of Personality and Social Psychology*. 77(6), 1296-1312.
- [Pennebaker et. al, 2001] Pennebaker, J. W., Francis, M. E. Booth, R.J. (2001). "Linguistic Inquiry and Word Count (LIWC): LIWC2001", Mahwah: Lawrance Erlbaum Associates.
- [Pennebaker et. al, 2007] Pennebaker, J. W. Booth, R.J. Francis, M. E. (2007). "Linguistic Inquiry and Word Count (LIWC): LIWC2007", Austin, TX: LIWC.net.
- [Pennebaker et. al, 2015] Pennebaker, J. W. Boyd, R. L. Jordan, K. Blackburn K. (2015) "The development and Psychometric Proprieties of LIWC2015", Austin, TX: University of Texas at Austin.
- [Pickard, 1995] Pickard, R.W. (1995). "Affective Computing." MIT Media Laboratory Perceptual Computing Section Technical Report No. 321.
- [Pigem, 1949] Pigem, J.M. (1949). "La prueba de la expresión desiderativa." *Libreria de Ciências Médicas*: Barcelona.
- [Poria et. al., 2013] Poria, S. Gelbukh, A. Hussain, A. Das, D. Bandyopadhyay, S. (2013). "EnhancedSenticNet with Affective Labels for Concept-based Opinion Mining" *Intelligent Systems, IEEE*, v. 28, n. 2, p. 31–38, 2013. Disponível em: <<http://doi: 10.1109/MIS.2013.4>>.
- [Poria et. al., 2014] Poria, S. Gelbukh, A. Cambria, E. Hussain, A. Huang, G. B. (2014). "EmoSenticSpace: A novel framework for affective common-sense reasoning." In: *Knowledge-Based Systems*, p108-123, 2014. Disponível em:<<http://dx.doi.org/10.1016/j.knosys.2014.06.011>>.
- [Potts, 2001] Potts, C. (2011). "happyfuntokenizer (Version 10). [Computer software]." Disponível em: <http://sentiment.christopherpotts.net/code-data/happyfuntokenizing.py>.
- [Prati, Batista & Monard, 2008] Prati, R. C. Batista, G. E. A. P. A. Monard, M. C. (2008) "Curvas Roc para a Avaliação de Classificadores," *IEEE Latin America Transactions*, v. 6, n. 2, p. 215-222, 2008, ISSN: 1548-0992.
- [Quercia et. al., 2011] Quercia, M. Kosinski, S., D. Crowcroft, J. (2011). "Our Twitter profiles, our selves: predicting personality with Twitter", in *IEEE international conference on privacy, security, risk, and trust, and IEEE international conference on social computing*, pp. 180–185, 2011.

- [Rorchach, 1974] Rorschach, H. (1974). “Psicodiagnóstico” (M.S. de Villemor Amaral, Trad.) São Paulo: Mestre Jou. (Trabalho original publicado em 1921)
- [Rorschach, 1967] Rorschach H. (1967). “Psicodiagnóstico.” (1ª Edición 1922). São Paulo: Editora Mestre Jou.
- [Rossi, 2018] Rossi, R. J. (2018), “An Introduction to Likelihood Based Inference,” New York: John Wiley & Sons, p.277, 2018, ISBN 978-0-691-13128-3.
- [Runes, 1972] Runes, D. D. (1972), “Dictionary of Philosophy”, Littlefield, Adams, and Company, Totowa, NJ, 1972.
- [Santos et. al., 2017] dos Santos V.G. Paraboni I. Silva B.B.C. (2017) “Big Five Personality Recognition from Multiple Text Genres.” In: Ekštejn K., Matoušek V. (eds) Text, Speech, and Dialogue. TSD 2017. Lecture Notes in Computer Science, vol 10415. Springer, Cham.
- [Santos & Paraboni, 2019] Santos, W. R. Paraboni, I. (2019) “Personality Facets Recognition from text,” In: Crestani F. et al. (eds) Experimental IR Meets Multilinguality, Multimodality, and Interaction. CLEF 2019. Lecture Notes in Computer Science, vol 11696. Springer, Cham, 2019.
- [Sassure, 1996] Sassure, F. (1996) “Curso de Linguística Geral,” Tradução Antônio Chelini et al., 25ª edição, São Paulo, Cultrix, 1996.
- [Scaduto & Barbieri, 2013] Scaduto A. A, Barbieri V. (2013), “Em defesa do TAT: uma revisão crítica das pesquisas sobre o teste no Brasil,” *Avaliação Psicológica*, 12(3), pp. 299–305, 2013.
- [Scaduto, 2016] Scaduto A. A. (2016). “O Teste de Apercepção Temática (TAT) em adultos: Dados normativos para o sistema morvaliano,” Phd Thesis, Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2016.
- [Scheffer, 1962] Scheffer R. (1962). “Introdução Aos Testes Psicológicos,” Escola Brasileira de Administração Pública, Fundação Getúlio Vargas, Rio de Janeiro, p. 99, 1962.
- [Schmidt et, al., 2002] Schmidt, M. J. Kihm, J. A. Robie, C. “The Global Personality Inventory (GPI). In: B. de Raad and M. Perugini.” *Big Five Assessment*, p. 195–236, Alemanha, 2002.
- [Schultz & Schultz, 2003] Schultz, D. P. Schultz, S. E. (2003). “Theories of Personality.” 8th ed., Belmont, CA, Wadsworth.
- [Schust & Picolo, 1976] Schust, M.C. Picolo, E.G. (1976). “Índices diagnósticos y pronósticos em el Test desiderativo a partir del estudio de las defensas.” Em Ocampo, M.L.S. (Org.). *Las técnicas projectivas y el processo psicodiagnóstico* (pp. 83-90). Buenos Aires: Nueva Visión.

- [Stajner & Yenikent, 2020] Stajner, S. Yenikent S. “A Survey of Automatic Personality Detection from texts”, Proceedings of the 28th International Conference on Computational Linguistics, International Committee on Computational Linguistics, pp 6284 – 6925, Barcelona, Spain, 2020.
- [Wang & Chen, 2019] Wang, S Chen, X. (2019) “Recognizing CEO personality and its impact on business performance: Mining linguistic cues from social media,”, Information Management, Vol. 57, Issue 5, 2020.
- [Silva, 1984] Silva, E. F. (1984). “O Teste de Apercepção Temática de Murray (TAT) na cultura brasileira,” Rio de Janeiro, Ed. Da Fundação Getúlio Vargas / ISOP, 1984.
- [Silva & Carvalho; Sarmiento, 2012] Silva, M. J. Carvalho, P. Sarmiento, L. (2012).“Building a sentiment lexicon for social judgement mining. In: Computational Processing of the Portuguese Language”, Springer Heidelberg, p. 218-228, 2012.
- [Simões et. al., 2012] Simões, A. Sanromán, Á.I. Almeida, J.J. (2012) “Dicionário-Aberto: A Source of Resources for the Portuguese Language Processing.” In Proceedings of 10th International Conference on Computational Processing of the Portuguese Language (PROPOR 2012); Lecture Notes in Computer Science; Springer: Berlin, Germany, 2012; Volume 7243, pp. 121–127.
- [Simões et. al., 2014] Simões, A. Guinovart, X.G. (2014) “Bootstrapping a Portuguese WordNet from Galician, Spanish and English Wordnets.” In Advances in Speech and Language Technologies for Iberian Languages, Proceedings of the 2nd International Conference on IberSPEECH 2014, Las Palmas de Gran Canaria, Spain, 19–22 November 2014; Lecture Notes in Computer Science; Springer: Berlin, Germany, 2014; Volume 8854, pp. 239–248.
- [Skinner, 1989a] Skinner, B. F. (1989). “The origins of cognitive thought.” American Psychologist, 44, 13- 18.
- [Souza et. al., 2011] Souza, M. Vieira, R. Busseti, D. Chishman, R. Alves, I. M. (2011) “Construction of a Portuguese Opinion Lexicon from multiple resources.” In: 8th Brazilian Symposium in Information and Human Language Technology, 2011.
- [Speer & Havasi, 2013] Speer, R. Havasi, C. (2013) “ConceptNet 5: A large semantic network for relational knowledge.” In The People’s Web Meets NLP, Springer Heidelberg, Berlin, Germany, p. 161-176, 2013.
- [Speer, 2017] Speer, R. Chin, J. Havasi, C. (2017). “ConceptNet 5.5: An Open Multilingual Graph of General Knowledge.” In Proceedings of the 31st AAAI Conference on Artificial Intelligence, San Francisco, CA, USA, 4–9 February 2017; pp. 4444–4451.

- [Stamatatos et. al., 2001] Stamatatos, E. Fakotakis, N. and Kokkinakis, G. (2001). Computer-based authorship attribution without lexical measures. *Computers and the Humanities*, 35(2):193– 21
- [Statamatos et. al., 2009] Stamatatos E. (2009). “A Survey of modern authorship attribution methods.” *Journal of American Society Information Science and Technology*, Volume 60, Issue 3, March 2009, DOI 10.1002/asi.v60:3
- [Stelmack & Stalikas, 1991] Stelmack, R. M. Stalikas A. (1991).“Galen and the humor theory of temperament. *Personality and Individual Differences*”, Volum 12, Issue 3, 1991, p. 255-263.
- [Stone, 1996] Stone, P. J. (1966). “The General Inquirer: A Computer Approach to Content Analysis.”, *American Sociological Review*, 32(5), p. 859. doi: 10.2307/2092070.
- [Sumner et. al., 2012] Sumner, C. Byers, A. Boochever, R. Park G.J. (2012) “Predicting dark triad personality traits from Twitter usage and a linguistic analysis of tweets”, in 11th international conference on machine learning and applications, pp. 386–393, 2012.
- Sewwandi, D. Perera, K. Sandaruwan, S. Lakchani, O. Nugaliyadde A. and Thelijjagoda, S. (2017) "Linguistic features based personality recognition using social media data," 2017 6th National Conference on Technology and Management (NCTM), Malabe, Sri Lanka, pp. 63-68, 2017, doi: 10.1109/NCTM.2017.7872829.
- [Tellegen & Ben-Porath, 2008] Tellegen, A. Ben-Porath, Y. S. (2008). "MMPI-2-RF (Minnesota Multiphasic Personality Inventory-2 Restructured Form): Technical manual." Minneapolis: University of Minnesota Press.
- [Thelwall et. al., 2010] Thelwall, M. et al. (2010) ‘Sentiment Strength Detection in Short Informal Text’, *The American Society for Informational science and technology*, 61(12), pp. 2544–2558. doi: 10.1002/asi.
- [Theophratus, 4bc] “Theophrastus.” *The Characters*, 4th Century BC.
- [Tsoumakas et. al., 2011] Tsoumakas, G. Spyromitros-Xioufis, E. Vilcek, J. Vlahavas I. (2011) “Mulan: A Java library for multi-label learning”. *J. Mach. Learn. Res.* 2011, 12:2411–2414.
- [Tsoumakas, 2007] Tsoumakas, G. Vlahavas, I. (2007). “Random k-labelsets: An ensemble method for multilabel classification (PDF).” *ECML*.
- [Urbina, 2007] Urbina S. (2007). “Introdução aos Testes Psicológicos e seus usos,” 2007.
- [Vaz & Alchieri, 2016] Vaz, C. E. Alchieri, J. C. (2016) “Z-Teste Coletivo e Individual”, 3ed. Editora Hogrefe, ISBN 978-85-85439-37-8.

[Veronica et al., 2017] Ong, V. Rahmanto, A. D. S. Williemi, Suhartono D. (2017) “Exploring Personality Prediction From Text on Social Media: A Literature Review”, *Internetworking Indonesia Journal*, Vol 9, No 1, 2017.

[Vinciarelli & Mohammadi, 2014] Vinciarelli, A. Mohammadi, G. (2014). “A Survey of Personality Computing.” *IEEE Transactions on Affective Computing*, v.5, n.3, p. 273-291.

[Vu et. al., 2017] Vu, X. Flekova, L. Jiang, L. Gurevych, I. (2017). “Lexical-semantic resources: yet powerful resources for automatic personality classification.” *CoRR*, abs/1711.09824.

[Wald et. al., 2012] Wald, R. Khoshgoftaar T. Sumner C. “Machine prediction of personality from Facebook profiles”, in 2012 IEEE 13th international conference on Information Reuse and Integration (IRI), pp. 109–115.

[Wald, 2012 b] Wald, R. Khoshgoftaar T. Napolitano, A. Sumner, C. (2012) “Using Twitter content to predict psychopathy”, in *Proceedings of the 2012 11th international conference on machine learning and applications—Volume 02*, pp. 394– 401, Washington, DC, USA.

[Watson et. al., 1988] Watson, D. Clark, L. A. Tellegen, A. (1988) “Development of validation brief measures of positive and negative affect: The PANAS scales”., *Journal of Personality and Social Psychology*, 54, 1063-1070.

[Whitelaw and Argamon, 2004] Whitelaw, C. Argamon, S. (2004). “Systemic functional features in stylistic text classification.”, In *Proc. AAAI Fall Symposium on Style and Meaning in Language, Art, Music, and Design*, Washington, DC, October 2004.

[Winter, 1989] Winter D.G. (1989). “Manual for scoring motive imagery in running text.” Unpublished manuscript, University of Michigan, Ann Arbor.

[Witten & Frank, 2005] Witten, I. H. Frank, E. (2005) “Data Mining: Practical Machine Learning Tools and Techniques”, *The Morgan Kaufmann Series in Data Management Systems*, 2nd ed. San Francisco: Elsevier.

[Zeldow & McAdams, 1993] Zeldow P.B. McAdams, D.P. (1993). “On the comparison of TAT and free speech technique in personality assessment.” *Journal of Personality Assessment*. 181-185.

[Zeldow & McAdams, 1993] Zeldow P.B. McAdams, D.P.;(1993). “On the comparison of TAT and free speech technique in personality assessment.” *Journal of Personality Assessment*. 181-185.

[Zhang & Lee, 2006] Zhang, D. Lee, W.S. (2006). “Extracting key-substring-group features for text classification.” In *Proceedings of the 12th Annual SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 474-483).

[Zulliger, 1948] Zulliger, H. (1948) “Diapositiv-test”, Stuttgart Bern, Suiza: Verlag Hans Huber.

“<https://www.clips.uantwerpen.be/datasets/personae-corpus>”, acessado em 05/01/2018.

<http://paginas.fe.up.pt/~arocha/AED1/0607/trabalhos/thesaurus.txt>, março, 2018.

Vozes.

[Yang & Pedersen, 1997] Yang Y. Pedersen, J. O. (1977) “A comparative study on feature selection in text categorization,” in International Conference on Machine Learning, pp. 412–420, 1997.

[Yoav & Robert, 1996] Freund, Y. Schapire, R. E. (1996), “Experiments with a new boosting algorithm”, Proceedings of the Thirteenth International Conference on International Conference on Machine Learning, p. 148-156, 1996.