

Agenda

- 1 Introdução
- 2 Estruturação e Execução
- 3 Ferramentas
- 4 Hadoop

Agenda

1 Introdução

2 Estruturação e Execução

3 Ferramentas

4 Hadoop

Sobre

- Jean Paul Barddal
- Professor do PPGIa/PUCPR
- www.jpbarddal.com.br
- Áreas de Pesquisa
 - Data stream mining
 - Machine Learning aplicado
- jean.barddal@ppgia.pucpr.br

Datasets

- Durante as aulas, usaremos diferentes datasets
- Datasets e códigos estarão disponíveis em: www.jpbarddal.com.br

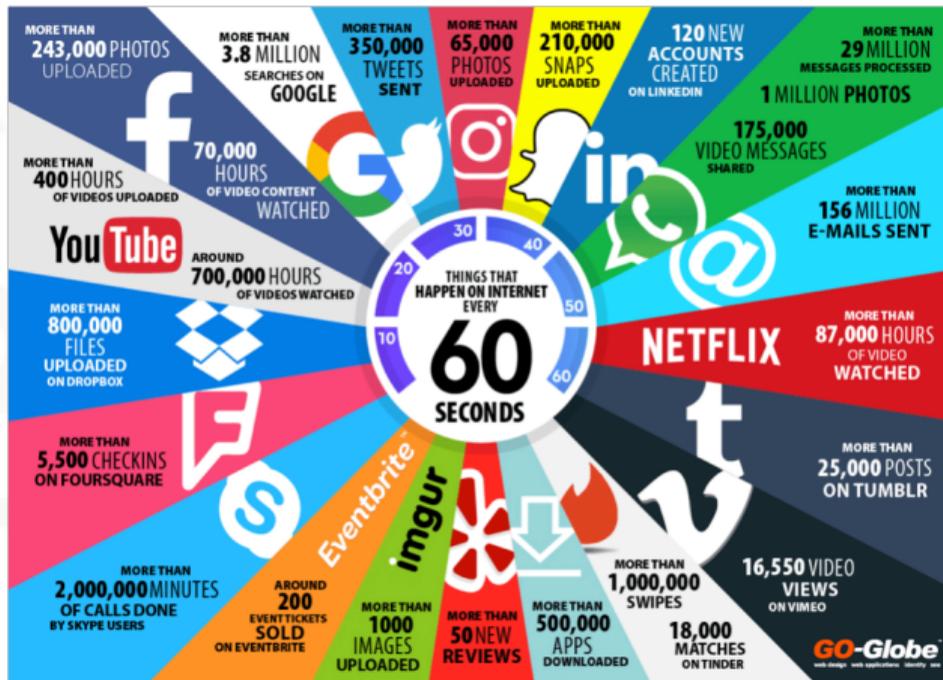
O que nós faremos durante o curso?

- Discutiremos o que é Big Data
- Entenderemos o Hadoop Distributed File System (HDFS)
- Processaremos dados usando Spark (RDDs, Pair RDDs, SQL e Pandas)

Big Data

- Coleção de dados tão grande e complexa que não conseguimos tratar usando bancos de dados e ferramentas de processamento tradicionais (monolíticas)

Motivação



O que faz de Big Data realmente Big Data?

Definition de Dan Ariely, Duke University

“Big Data is like teenage sex; everyone talks about it, nobody really knows how to do it, everyone thinks everyone else is doing it, so everyone claims they are doing it.”

7 Vs de Big Data (Características)

- Volume
- Velocidade
- Variedade
- Variabilidade
- Veracidade
- Visualização
- Valor

3, 5, 7, 10, ou 42 Vs?

- 3 Vs: <https://www.flydata.com/blog/3-vs-of-big-data/>
- 5 Vs:
<https://www.ibm.com/blogs/watson-health/the-5-vs-of-big-data/>
- 7 Vs: <https://impact.com/marketing-intelligence/7-vs-big-data/>
- 10 Vs: <https://tdwi.org/articles/2017/02/08/10-vs-of-big-data.aspx>
- 42 Vs: <https://www.elderresearch.com/blog/42-v-of-big-data>

Volume

- A característica mais óbvia
- A quantidade astronômica de dados gerada, armazenada e processada
- Examples:
 - 300 horas de video são enviadas ao Youtube a cada minuto
 - 1.1 trilhões de fotos tiradas em 2016 e 9% a mais em 2017
 - Visa trata aprox. 24 mil transações de cartão de crédito por segundo nos EUA



Velocidade

- Frequência com que dados se tornam disponíveis e são processados
- Exemplos:
 - Facebook diz armazenar aproximadamente 300PB de dados, mas isso aumenta em 600TB a cada dia
 - Google tem aproximadamente 40k queries por segundo, resultando em 3.5B de queries por dia
- Dados sequencialmente gerados: data streams
- Como processamos data streams?
 - Periodicamente? (Batch)
 - Em tempo real (ou quase real)?



Variedade

- Dado de acordo com os tipos de dados e respectivas origens
- Dados estruturados, semi-estruturados e não estruturados
- Como combinar tipos de dados?

Variabilidade

- Variabilidade não é o mesmo que Variedade
- Se uma cafeteria vende 6 tipos de café: variedade
- Se você pede o mesmo café todos os dias, mas ele sempre tem sabor diferente: variabilidade
- Como discernir entre um outlier e uma mudança de conceito?

Veracidade

- Uma das características mais infelizes de Big Data
- Mais dados, menos confiáveis eles podem ser
- Razão: os dados podem ser obtidos de diferentes fontes e nem todas as fontes são confiáveis

Veracidade

- Exemplo: ao obter estatísticas sobre dados, pense sobre:
 - Quem criou a amostra de dados
 - Qual foi a metodologia de aquisição?
 - Os dados foram sumarizados?
 - Os dados foram editados, verificados, ou corrigidos?
- Importante: dados são obtidos ou processados por pessoas
 - E se as pessoas estão mentindo?
 - E se alguém processou ou modificou os dados de forma errada?

Visualização

- Como visualizamos Big Data?
- Dificuldades:
 - Muitos dados (linhas e colunas), não cabe em RAM
 - Como plotar milhões/bilhões de pontos em um gráfico?
- Técnicas específicas: clustering, tree maps, sunbursts, parallel coordinates, cone trees, etc
- Como visualizamos tipos de dados diferentes que se tornam disponíveis ao longo do tempo?

Valor

- As demais características são irrelevantes caso não tragam valor
- Financeiro ou social
 - Entender clientes, segmentação: marketing direcionado
 - Otimização de processos
 - Identificação de fraudes, etc
 - Foco analítico/preditivo (Data Science/Machine Learning)

Agenda

1 Introdução

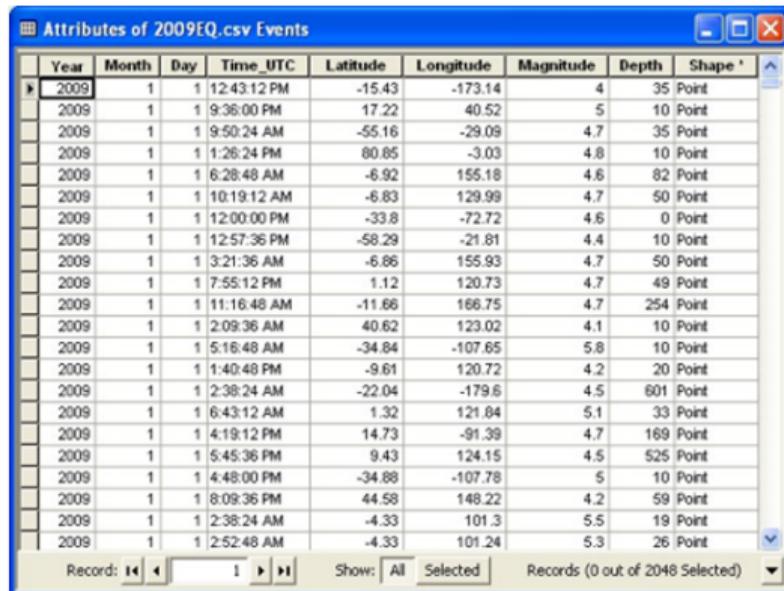
2 Estruturação e Execução

3 Ferramentas

4 Hadoop

Dados estruturados

- Dados tabulares com schema
- Linhas, colunas e tipos de colunas
- Linhas são chamadas de exemplos, instâncias, amostras, registros
- Colunas são chamadas de atributos, características, variáveis



Year	Month	Day	Time_UTC	Latitude	Longitude	Magnitude	Depth	Shape
2009	1	1	12:43:12 PM	-15.43	-173.14	4	35	Point
2009	1	1	9:36:00 PM	17.22	40.52	5	10	Point
2009	1	1	9:50:24 AM	-55.16	-29.09	4.7	35	Point
2009	1	1	1:26:24 PM	80.85	-3.03	4.8	10	Point
2009	1	1	6:28:48 AM	-6.92	155.18	4.6	82	Point
2009	1	1	10:19:12 AM	-6.83	129.99	4.7	50	Point
2009	1	1	12:00:00 PM	-33.8	-72.72	4.6	0	Point
2009	1	1	12:57:36 PM	-58.29	-21.81	4.4	10	Point
2009	1	1	3:21:36 AM	-6.86	155.93	4.7	50	Point
2009	1	1	7:55:12 PM	1.12	120.73	4.7	49	Point
2009	1	1	11:16:48 AM	-11.66	166.75	4.7	254	Point
2009	1	1	2:09:36 AM	40.62	123.02	4.1	10	Point
2009	1	1	5:16:48 AM	-34.84	-107.65	5.8	10	Point
2009	1	1	1:40:48 PM	-9.61	120.72	4.2	20	Point
2009	1	1	2:38:24 AM	-22.04	-179.6	4.5	601	Point
2009	1	1	6:43:12 AM	1.32	121.84	5.1	33	Point
2009	1	1	4:19:12 PM	14.73	-91.39	4.7	169	Point
2009	1	1	5:45:36 PM	9.43	124.15	4.5	525	Point
2009	1	1	4:48:00 PM	-34.88	-107.78	5	10	Point
2009	1	1	8:09:36 PM	44.58	148.22	4.2	59	Point
2009	1	1	2:38:24 AM	-4.33	101.3	5.5	19	Point
2009	1	1	2:52:48 AM	-4.33	101.24	5.3	26	Point

Dados semi-estruturados

- Dados não estritamente tabulares
- Demandam pré-processamento para conversão em tabela
- Exemplos: XML, JSON, etc
- Estrutura irregular e implícita
- Estrutura definida de acordo com seu conteúdo, e.g., tags XML definidas de acordo com os atributos da aplicação

XML

```
<menu id="file" value="File">  
  <popup>  
    <menuitem value="New" onclick="CreateNewDoc()" />  
    <menuitem value="Open" onclick="OpenDoc()" />  
    <menuitem value="Close" onclick="CloseDoc()" />  
  </popup>  
</menu>
```

JSON

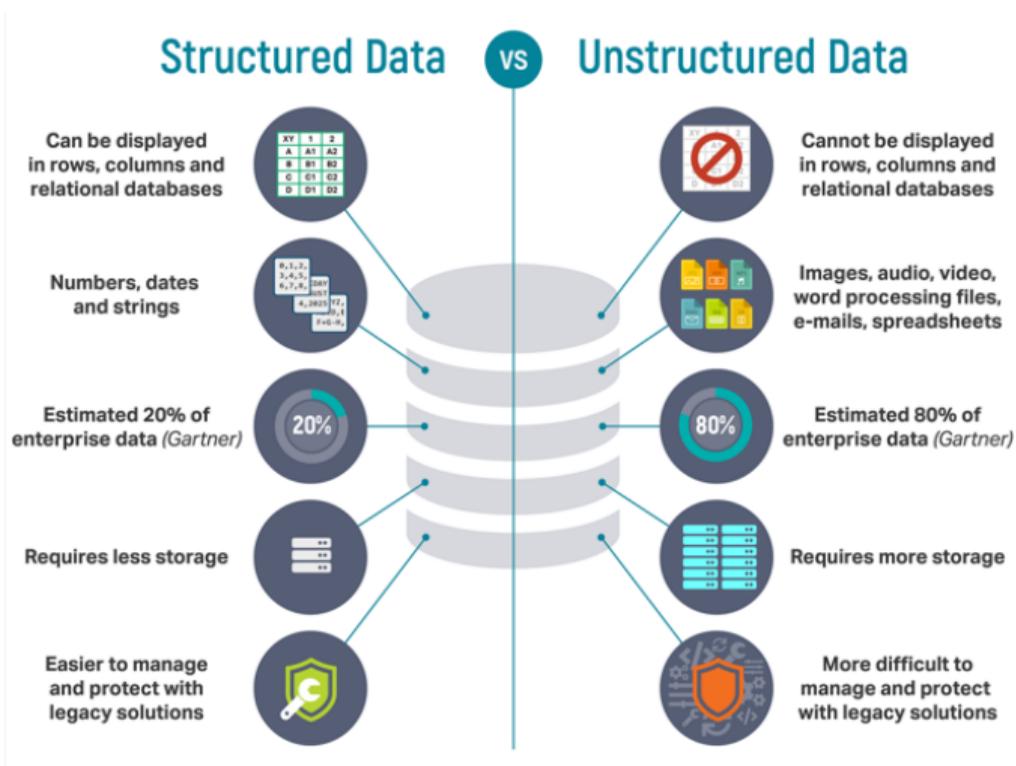
```
{  
  "menu": {  
    "id": "file",  
    "value": "File",  
    "popup": {  
      "menutem": [ { "value": "New", "onclick": "CreateNewDoc()" },  
                  { "value": "Open", "onclick": "OpenDoc()" },  
                  { "value": "Close", "onclick": "CloseDoc()" } ]  
    }  
  }  
}
```

Log

```
tecmint@TecMint ~ $ tailf /var/log/apache2/access.log
127.0.0.1 - - [31/Oct/2017:11:11:37 +0530] "GET / HTTP/1.1" 200 729 "-" "Mozilla/5.0 (Windows NT 6.0; rv:56.0) Gecko/20100101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:11:37 +0530] "GET /icons/blank.gif HTTP/1.1" 200 101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:11:37 +0530] "GET /icons/folder.gif HTTP/1.1" 200 101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:11:37 +0530] "GET /icons/text.gif HTTP/1.1" 200 512 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:11:38 +0530] "GET /favicon.ico HTTP/1.1" 404 500 Mozilla/5.0 (Windows NT 6.0; rv:56.0) Gecko/20100101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:12:05 +0530] "GET /tecmint/ HTTP/1.1" 200 787 "Mozilla/5.0 (Windows NT 6.0; rv:56.0) Gecko/20100101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:12:05 +0530] "GET /icons/back.gif HTTP/1.1" 200 401 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:13:58 +0530] "GET /tecmint/Videos/ HTTP/1.1" 200 101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:13:58 +0530] "GET /icons/compressed.gif HTTP/1.1" 200 101 Firefox/56.0"
127.0.0.1 - - [31/Oct/2017:11:13:58 +0530] "GET /icons/movie.gif HTTP/1.1" 200 101 Firefox/56.0"
```

Dados não estruturados

- Sem estrutura pré-definida
- Imagem
- Áudio
- Vídeo
- Texto



Modos de Processamento

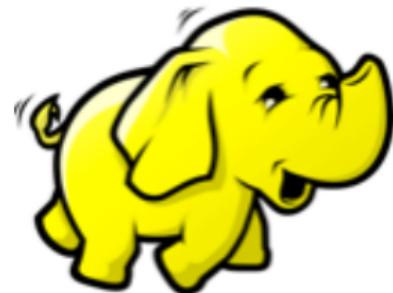
- Batch
 - Dados armazenados no HDFS
 - Periodicamente (ou sob demanda), dados são processados
 - Nosso foco: Spark
- Stream (quase-, tempo real)
 - Dados processados conforme a chegada
 - Opcionalmente, dados são armazenados
 - Ferramentas: Storm e Spark streaming

Agenda

- 1 Introdução
- 2 Estruturação e Execução
- 3 Ferramentas**
- 4 Hadoop

Hadoop

- Big Data se tornou um tópico de interesse por conta do Hadoop
- Objetiva armazenamento e processamento de dados
- Clusters que vão de um único computador a milhares de computadores
- Computadores heterogêneos: hardware e SO
- Detecção de falhas
- Redundância



Composição do Hadoop

- Hadoop Distributed File System (HDFS)
- MapReduce

Características

- Inspirado no modelo de localidade
- Processamento vai aos dados
- Uso reduzido de rede
- Escalabilidade
- Mesmo software roda em 1, 10, 100 ou milhares de computadores
- Performance elevada

Apache Spark

- Framework para processamento de dados em memória
- Altamente escalável
- Permite processamento em lote (batch) e stream
- Otimizado para SQL e Machine Learning
- Programação e otimização baseada em DAGs (directed acyclic graphs)
- Flexível: podemos usar em Java, Scala, Python e R



Teste de Ambiente

- Vamos realizar um teste de acesso ao ambiente e verificar as principais partes disponíveis para uso
- HDFS
- Spark
- Jupyter Notebook

Formulário

- Caso você tenha problemas para acessar o ambiente, favor preencher o formulário abaixo com:
- Nome completo (sem abreviações)
- Email institucional
- Link: <https://forms.office.com/r/UKQv3CPfMh>

Agenda

- 1 Introdução
- 2 Estruturação e Execução
- 3 Ferramentas
- 4 Hadoop

Como processar massivas bases de dados?

- Desafios:
 - Processamento é lento dadas as quantidades de dados
 - Aquisição de dados a partir de HDs é lenta
 - Quantidade limitada de RAM
 - Idéia-chave: armazenamento e processamento distribuído de dados

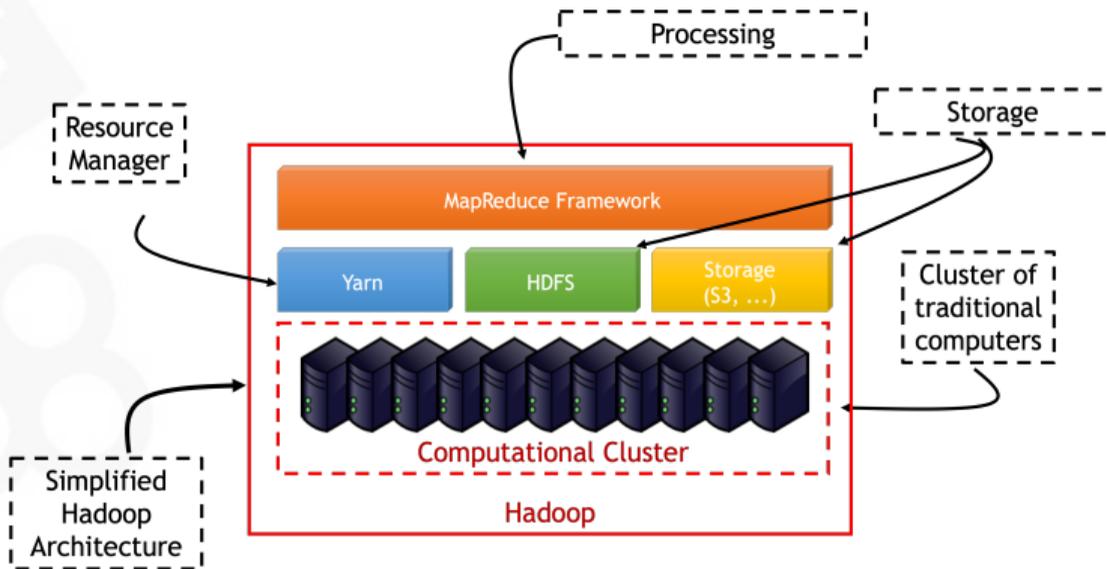
Hadoop

- Hadoop traz uma solução de computação distribuída para:
 - Concorrência
 - Portabilidade
 - Confiabilidade
 - Escalabilidade
 - Heterogeneidade
 - Transparência
 - Tolerância a falhas

Princípios

- O sistema deve ser auto-gerenciável e se recuperar de desastres
- Falhas podem acontecer mas devem ser transparentes para o usuário
- Balanceamento de carga: quando possível, as tarefas devem ser alocadas de acordo com a performance dos computadores
- Performance deve escalar de acordo com a quantidade de computadores disponíveis
- Processamento deve ir até os dados
- Pouco consumo de banda de rede

Visão Geral



Curiosidade

- Criado por Doug Cutting
- “Hadoop” veio do nome do brinquedo do filho

