

Métodos de Busca Heurística

Prof. Júlio Cesar Nievola
PPGIA - PUCPR



Implementação do método de busca do melhor primeiro

function BUSCA_MELHOR_PRIMEIRO(*problema*, AVAL-FN)
returns uma sequência solução

inputs: *problema*, um problema
 Aval-Fn, uma função de avaliação

Ordenar-Fn uma função que ordena nós segundo
 Aval-Fn

return BUSCA_GERAL(*problema*,
 Ordenar-Fn)

Busca do melhor primeiro

- Utiliza uma medida estimada do custo da solução e tenta sua minimização
- A medida deve incorporar uma estimativa do custo do caminho de um estado ao estado objetivo mais próximo
- Há duas abordagens:
 - Expandir o nó mais próximo a um objetivo;
 - Expandir o nó no caminho da solução de menor custo

Busca Gulosa (“Greedy search”)


- A mais simples estratégia de busca do melhor primeiro consiste em minimizar o custo estimado para atingir o objetivo

$h(n) \equiv$ custo estimado do caminho mais “barato” do estado n até o estado objetivo


function BUSCA_GULOSA(*problema*) **returns** uma solução ou falha

return BUSCA_MELHOR_PRIMEIRO(*problema*, h)

Mapa da Romênia



Busca Gulosa para Bucareste



Minimizando o custo total do caminho

- Busca Gulosa não é ótima nem completa
- Busca de custo uniforme (que usa $g(n)$) é ótima e completa mas é ineficiente
- Pode-se combinar as duas, usando-se $f(n)$ como o custo estimado total da solução de menor custo passando por n :


$$f(n) = g(n) + h(n)$$

Estratégia A*


- Uma heurística é *admissível* se ela nunca superestima o custo de atingir o objetivo, ou seja, ela é otimista
- A estratégia A* faz uma busca do melhor primeiro, usando f como função de avaliação e uma função h admissível:

function BUSCA- A*(*problema*) **returns** uma solução ou falha
return BUSCA_MELHOR_PRIMEIRO(*problema*, $g + h$)

A* para a busca de Bucareste



Mapa da Romenia com contornos com $f = 380$, $f = 400$ e $f = 420$



Funções Heurísticas

5	4	
6	1	8
7	3	2

Start State

1	2	3
8		4
7	6	5

Goal State

- h_1 quantidade de blocos na posição incorreta
- h_2 soma das distâncias de cada bloco à sua posição objetivo

Comparação entre A^* com h_1 e h_2 com aprofundamento iterativo

d	Search Cost			Effective Branching Factor		
	IDS	$A^*(h_1)$	$A^*(h_2)$	IDS	$A^*(h_1)$	$A^*(h_2)$
2	10	6	6	2.45	1.79	1.79
4	112	13	12	2.87	1.48	1.45
6	680	20	18	2.73	1.34	1.30
8	6384	39	25	2.80	1.33	1.24
10	47127	93	39	2.79	1.38	1.22
12	364404	227	73	2.78	1.42	1.24
14	3473941	539	113	2.83	1.44	1.23
16	–	1301	211	–	1.45	1.25
18	–	3056	363	–	1.46	1.26
20	–	7276	676	–	1.47	1.27
22	–	18094	1219	–	1.48	1.28
24	–	39135	1641	–	1.48	1.26

Aprofundamento iterativo A*

- Com a finalidade de conservar memória pode-se usar a idéia do algoritmo de aprofundamento iterativo
- Transforma-se a estratégia de busca A* em aprofundamento iterativo usando-se a noção de contorno de mesmo custo
- Boa estratégia em domínios pequenos mas possui dificuldades em domínios grandes

IDA* - Algoritmo principal

```
function IDA*( problema) returns uma seqüência solução
  inputs: problema, um problema
  static:   f-limite, o limite atual f -CUSTO
            raiz, um nó
  raiz  $\leftarrow$  CRIAR_NÓ(ESTADO_INICIAL[problema])
  f-limite  $\leftarrow$  f -CUSTO(raiz)
  loop do
    solução, f-limite  $\leftarrow$  DFS-CONTORNO(raiz, f-limite)
    if solução é não-nula then return solução
    if f-limite =  $\infty$  then return falha;
  end
```

IDA* - Busca no contorno

```
function DFS-CONTORNO(nó, f-limite) returns uma sequência solução  
                                e um novo f -CUSTO limite  
inputs: nó, um nó f-limite, o limite atual f -CUSTO  
static: próximo-f, o f -COST limite para o próximo contorno,  
                                inicialmente  $\infty$   
if f -CUSTO[nó] > f-limite then return nulo, f -CUSTO[nó]  
if TESTE_OBJETIVO[problema](ESTADO[nó]) then return  
                                nó, f-limite  
for each nó s in SUCESSORES(nó) do  
    solução, novo-f  $\leftarrow$  DFS-CONTORNO(s, f-limite)  
    if solução é não-nulo then return solução, f-limite  
    próximo-f  $\leftarrow$  MÍN(próximo-f, novo-f); end  
return nulo, próximo-f
```


Simplified Memory-Bounded A*

- Utiliza a memória disponível
- Evita repetição de estados, se a memória permitir
- É completo se a memória for suficiente para encontrar a solução de menor profundidade
- É ótimo se a memória permitir, ou retorna a melhor solução dentro da disponibilidade de memória

Algoritmo SMA*

```
function SMA*(problema) returns uma seqüência solução
  inputs: problema, uma problema
  static: Fila, uma fila de nós ordenados por  $f$  -custo
   $Fila \leftarrow \text{CRIAR\_FILA}(\{\text{CRIAR\_NÓ}(\text{ESTADO\_INICIAL}[\textit{problema}])\})$ 
  loop do
    if Fila está vazia then return falha
     $n \leftarrow$  nó mais profundo de menor  $f$ -custo em Fila
    if  $\text{TESTE\_DO\_OBJETIVO}(n)$  then return sucesso
     $s \leftarrow \text{PRÓXIMO-SUCESSOR}(n)$ 
    if  $s$  não é um objetivo e está na profundidade máxima then  $f(s) \leftarrow \infty$ 
    else  $f(s) \leftarrow \text{MÁX}(f(n), g(s)+h(s))$ 
    if todos os  $n$ 's sucessores foram gerados then
      atualizar  $n$ 's  $f$  -custo e aqueles de seus antecessores se necessário
    if  $\text{SUCESSORES}(n)$  estão todos na memória then remover  $n$  da Fila
    if a memória está cheia then
      apagar nó mais superficial de maior  $f$ -custo em Fila
      removê-lo da lista de sucessores de seu pai
      inserir seu pai em Fila se necessário
    inserir  $s$  na Fila
  end
```


Andamento na busca SMA*



Algoritmos de Melhora Iterativa

- Inicia-se com uma configuração completa e realizam-se modificações para melhorar a qualidade
- Há basicamente dois tipos:
 - Subida da montanha (ou descida do gradiente), que tenta melhoras graduais no estado atual
 - Recozimento simulado, que tenta modificações abruptas, às vezes prejudicando o estado atual

Subida da montanha



Algoritmo da subida da montanha

function SUBIDA_DA_MONTANHA(*problema*) **returns**
um estado solução

inputs: *problema*, um problema

static: *atual*, um nó
 próximo, um nó

atual $\leftarrow$ CRIAR_NÓ(ESTADO_INICIAL[*problema*])

loop do

próximo $\leftarrow$ um sucessor de maior valor de *atual*

if VALOR[*próximo*] < VALOR[*atual*] **then return** *atual*

atual $\leftarrow$ *próximo*

end

Problemas da subida da montanha

- Máximos locais
- Planícies
- Cadeia de montanhas
- Utilização da subida da montanha com reinício em pontos aleatórios

Recozimento simulado

```
function RECOZIMENTO_SIMULADO( problema, agenda) returns
                                um estado solução
```

inputs: *problema*, um problema
 agenda, um mapeamento do tempo para
 “temperatura”

static: *atual*, um nó; *próximo*, um nó; *T*, uma “temperatura” controlando a probabilidade de passos para

trás

$$atual \leftarrow \text{CRIAR_NÓ}(\text{ESTADO_INICIAL}[problema])$$
for $t = 1$ to ∞ do
$$T \leftarrow agenda[t]$$

if $T=0$ then return *atual*

$próximo \leftarrow$ um sucessor de $atual$ aleatoriamente selecionado

$$\Delta E \leftarrow \text{VALOR}[\textit{próximo}] - \text{VALOR}[\textit{atual}]$$

if $\Delta E > 0$ then $atual \leftarrow próximo$

else *atual* $\leftarrow$ *próximo* somente com probabilidade $e^{\Delta E/T}$