

Processamento Estatístico da Linguagem Natural

Aula 6

Professora Bianca
(Sala 302 – Bloco E)
bianca@ic.uff.br

<http://www.ic.uff.br/~bianca/peln/>

Aula 6 - 16/09/2008

1

Correção Ortográfica

- Três tipos de problemas:
 - Detecção de palavras que não existem.
 - Detectar que a palavra *Graffe* não existe em inglês.
 - Correção de palavras isoladas.
 - Corrigir *graffe* para *giraffe*
 - Detecção e correção de erros dependentes de contexto.
 - Corrigir *three* pra *there* na frase "*I went three*".

Aula 6 - 16/09/2008

2

Detecção de palavras que não existem

- Podemos usar um parser morfológico (FST) para reconhecer as palavras da língua.
 - Se o parser não reconhece ela não existe.
- Lida automaticamente com as inflexões e derivações morfológicas.
 - Não é necessário listar todas as palavras da língua explicitamente.

Aula 6 - 16/09/2008

3

Correção de Erros

- Temos que encontrar a palavra que tem mais chance de ser a palavra original que foi escrita incorretamente.
- Precisamos de uma métrica para calcular a distância entre a palavra "superficial" (digitada) e cada possível palavra "fonte" (do dicionário).
 - Soluções atuais usam probabilidade e serão tratadas no capítulo 4.
 - Mas são baseadas no conceito de **distância mínima de edição** que será discutido nesse capítulo.

Aula 6 - 16/09/2008

4

Distância Mínima de Edição

- É o número mínimo de edições (inserções, deleções e substituições) necessário para transformar uma string em outra.
 - Também chamada de medida de Levenshtein

INTENTION
| | | | |
* EXECUTION
d s s i s

Alinhamento

Aula 6 - 16/09/2008

5

Distância Mínima de Edição

- A distância mínima pode ser computada usando um algoritmo de **Programação Dinâmica (PD)**.
 - Classe de algoritmos introduzida por Bellman que resolve problemas combinando soluções de sub-problemas.
 - Usa uma tabela para armazenar resultados de sub-problemas.
 - Dessa forma ao invés de repetir a computação, pode-se olhar o valor na tabela.

Aula 6 - 16/09/2008

6

PD para Distância Mínima de Edição

- Solução parcial = Custo de alinhar **s** até a posição **i** com **t** até a posição **j**.
- Próximo passo = Para alinhar **s** até a posição **x** e **t** até a posição **y**, a próxima operação deve ser substituição, inserção ou deleção?

Aula 6 - 16/09/2008

7

Tabela de PD para Distância de Edição

Medir distância entre as strings **PARK**
SPAKE

		P	A	R	K
S					
P					
A			c_{ij}		
K					
E					

c_{ij} = número de operações de edição necessárias para alinhar PA com SPA

Aula 6 - 16/09/2008

8

Tabela de PD para Distância de Edição

Medir distância entre as strings **PARK**
SPAKE

Operações de edição para transformar SPAKE em PARK

		P	A	R	K
S					
P					
A					
K					
E					

Aula 6 - 16/09/2008

9

Tabela de PD para Distância de Edição

Medir distância entre as strings **PARK**
SPAKE

		P	A	R	K
	c_{00}	c_{02}	c_{03}	c_{04}	c_{05}
S	c_{10}	c_{11}	c_{12}	c_{13}	c_{14}
P	c_{20}	c_{21}	c_{22}	c_{23}	c_{24}
A	c_{30}	c_{31}	???		
K					
E					

Aula 6 - 16/09/2008

10

Tabela de PD para Distância de Edição

		P	A	R	K
	c_{00}	c_{02}	c_{03}	c_{04}	c_{05}
S	c_{10}	c_{11}	c_{12}	c_{13}	c_{14}
P	c_{20}	c_{21}	c_{22}	c_{23}	c_{24}
A	c_{30}	c_{31}	???		
K					
E					

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j-1), & \text{if } si=tj & //copy \\ D(i-1,j-1)+1, & \text{if } si \neq tj & //substitute \\ D(i-1,j)+1 & & //insert \\ D(i,j-1)+1 & & //delete \end{cases}$$

Aula 6 - 16/09/2008

11

Cálculo da Distância de Edição

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j-1) + d(si,tj) & //subst/copy \\ D(i-1,j)+1 & //insert \\ D(i,j-1)+1 & //delete \end{cases}$$

(simplify by letting $d(c,d)=0$ if $c=d$, 1 else)

also let $D(i,0)=i$ (for i inserts) and $D(0,j)=j$

Aula 6 - 16/09/2008

12

Inicialização da tabela

		P	A	R	K
	0	1	2	3	4
S	1	?			
P	2				
A	3				
K	4				
E	5				

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{substitute} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

Aula 6 - 16/09/2008

13

Preenchendo a tabela

		P	A	R	K
	0	1	2	3	4
S	1	1			
P	2				
A	3				
K	4				
E	5				

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{substitute} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

Aula 6 - 16/09/2008

14

Preenchendo a tabela

		P	A	R	K
	0	1	2	3	4
S	1	1	2	3	4
P	2		?		
A	3				
K	4				
E	5				

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{substitute} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

Aula 6 - 16/09/2008

15

Preenchendo a tabela

		P	A	R	K
	0	1	2	3	4
S	1	1	2	3	4
P	2		1		
A	3				
K	4				
E	5				

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{substitute} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

Aula 6 - 16/09/2008

16

Preenchendo a tabela

		P	A	R	K
	0	1	2	3	4
S	1	1	2	3	4
P	2		1	2	3
A	3	2	1	2	3
K	4	3	2	2	2
E	5	4	3	3	3

$D(i,j)$ = score of best alignment from $s1..si$ to $t1..tj$

$$= \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{substitute} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

Aula 6 - 16/09/2008

17

Custo total de alinhar as duas strings até o final.

Recuperando o alinhamento (Backtrace)

$$D(i,j) = \min \begin{cases} D(i-1,j)+d(s_i,t_j) & // \text{subst/copy} \\ D(i-1,j)+1 & // \text{insert} \\ D(i,j-1)+1 & // \text{delete} \end{cases}$$

A trace indicates where the min value came from, and can be used to find edit operations and/or a best alignment (may be more than 1)

	C	O	H	E	N
M	1	2	3	4	5
C	1	2	3	4	5
C	2	3	3	4	5
O	3	2	3	4	5
H	4	3	2	3	4
N	5	4	3	3	3

Aula 6 - 16/09/2008

18

Distância Mínima de Edição

- Algoritmo e código em diversas linguagens disponível em <http://www.merriampark.com/ld.htm>

Aula 6 - 16/09/2008

19

Segunda Lista de Exercícios

- Capítulo 3 (segunda edição)
 - 3.4
 - 3.7
 - 3.10
 - 3.12
- Data de entrega: 02/10

Aula 6 - 16/09/2008

20

Linguagem Python

- Introdução
 - Características de Python
 - Rodando programas
 - Módulos
- Tipos básicos
 - Números e variáveis
 - Strings
 - Listas e tuplas
 - Dicionários
- Fluxo de controle
 - Execução condicional
 - Repetições

Aula 6 - 16/09/2008

21

Características de Python

- Gratuita. Roda em muitas plataformas.
- Fácil de ler.
 - Ao contrário de Perl = “write only language”
- Tempo de implementação rápido.
 - Ao contrário de Java.
- Orientada a objeto.
- NLTK = Natural Language Toolkit

Aula 6 - 16/09/2008

22

Usando Python no modo interativo

- Usuário digitando em vermelho, máquina respondendo em preto.

```
$ python
>>> print "Hello everyone!"
Hello everyone!
>>> print 2+2
4
>>> myname = "Andrew"
>>> myname
'Andrew'
```

Aula 6 - 16/09/2008

23

Módulos

- Arquivos texto contendo código Python.

```
foo.py
print 25*3                # multiply by 3
print 'CompLing ' + 'lecture 3' # concatenate with +
myname = 'Andrew'
```

Módulo sendo executado a partir da linha de comando:

```
$ python foo.py
75
CompLing lecture 3
$
```

Aula 6 - 16/09/2008

24

Importando módulos

- Todo arquivo terminando em **.py** é um módulo python que pode ser importado.
 - A terminação **.py** é omitida.
 - As declarações do módulo (funções, variáveis) ficam disponíveis como atributos de um objeto que tem o nome do módulo.

```
$ python
>>> import foo
75
compiling lecture 3
>>> foo.myname
'Andrew'
```

Aula 6 - 16/09/2008

25

Recarregando módulos

- A importação de módulos é cara computacionalmente e Python só a realiza uma vez (mesmo que o arquivo seja editado).
- Para forçar que o arquivo seja importado novamente, devemos usar o comando “reload”.

```
Edit foo.py to print 25*4 (instead of 25*3) and reload
>>> reload(foo)
100
compiling lecture 3
<module 'foo' from 'foo.py'>
```

Aula 6 - 16/09/2008

26

Atributos de Módulos

- Considere o arquivo **bar.py**

```
university = 'UMass'
department = 'Linguistics'

>>> import bar
>>> print bar.department
Linguistics

>>> from bar import department
>>> print department
Linguistics

>>> from bar import *
>>> print university
UMass
```

Aula 6 - 16/09/2008

27

Estruturas de Programas em Python

- Programas são compostos de módulos.
- Módulos contém comandos.
- Comandos contém expressões.
- Expressões criam e processam objetos.
- Comandos incluem:
 - Atribuição de variáveis
 - Chamadas de função
 - Controle de fluxo
 - Declaração de função
 - Declaração de objeto
 - Leitura e impressão

Aula 6 - 16/09/2008

28

Objetos “built-in” de Python

- Números: inteiro e ponto-flutuante
- Strings
- Listas
- Dicionários
- Tuplas
- Arquivos

Aula 6 - 16/09/2008

29

Expressões numéricas e variáveis

- Operadores usuais: +, *, /, **
- Precedência usual:
 - $A * B + C * D = (A * B) + (C * D)$
- Módulos úteis: **math** e **random**
- Variáveis
 - Criadas na primeira atribuição
 - São substituídas pelo seu valor quando usadas em expressões
 - Tem que ter recebido um valor antes do primeiro uso.
 - Não precisam ser declaradas

Aula 6 - 16/09/2008

30