

Reconhecimento vs. Parsing/Geração

- FSAs podem ser usados para reconhecimento.
- Porém reconhecimento não é suficiente.
 - Além de saber que a string pertence à linguagem queremos saber sua estrutura (**parsing**)
 - A partir da estrutura podemos querer gerar a string (**geração**)
- Exemplo
 - De "cats" para "cat +N +PL"
 - De "cat +N +PL" para "cats"

Aula 5 - 11/09/2008

7


Transdutores de Estado Finito (FSTs)

- Um FST é um tipo de autômato finito que relaciona dois conjuntos de símbolos.
 - Tem duas fitas.
 - Lê uma string numa fita e escreve uma string na outra fita.
 - Cada arco do autômato tem dois símbolos (um para cada fita), separados por dois pontos.
 - Exemplo: em uma fita lê "cats", na outra escreve "cat +N +PL"

Aula 5 - 11/09/2008

8

Exemplo



- c:c significa ler c numa fita e escrever c na outra.
- +N:ε significa ler o símbolo +N numa fita e não escrever nada na outra.
- +PL:s significa ler +PL e escrever um s

Aula 5 - 11/09/2008

9

FSTs – Definição Formal

- Um conjunto de estados: Q
- Um alfabeto finito: Σ
- Um estado inicial $q_0 \in Q$
- Um conjunto F de estados finais $F \subseteq Q$
- Uma função de transição $\delta(q,w)$ que mapeia de $Q \times \Sigma^*$ para um conjunto de estados $\in Q$.
- Uma função de saída $\sigma(q,w)$ que dá o conjunto de possíveis saídas para cada estado e entrada.

Aula 5 - 11/09/2008

10

Propriedades dos FSTs


- Enquanto FSAs são equivalentes às linguagens regulares, FSTs são equivalentes às relações regulares.
- FSTs são "fechados" em relação às operações de
 - União
 - Inversão (trocar as strings de entrada e saída)
 - Útil para converter de parsing para geração
 - Composição (Se T_1 é um transdutor de A para B e T_2 é um transdutor de B para C então $T_1 \circ T_2$ é um transdutor de A para C).

Aula 5 - 11/09/2008

11

Transdutores Sequenciais

- Nem todo transdutor não-determinístico pode ser transformado em um transdutor determinístico.
- Transdutores sequenciais são um tipo de transdutor determinístico.
 - A saída pode ser ambígua, mas a entrada não.
 - Podem ter símbolos ϵ na saída, mas não na entrada.



Aula 5 - 11/09/2008

12

Transdutores Subsequenciais


- Geram uma saída adicional nos estados finais, que é concatenada à saída normal.
- Assim como os transdutores sequenciais são eficientes.
 - O tempo de processamento é proporcional ao tamanho da entrada.
- A generalização chamada de **transdutor p-subsequencial** permite p strings de saída para cada estado final.
 - Permite uma quantidade finita de ambiguidade mantendo a eficiência.
 - Serve para muitas tarefas de NLP, incluindo parsing morfológico.



Aula 5 - 11/09/2008

13

FSTs para Parsing Morfológico




- Fita léxica: composta de símbolos do alfabeto Σ .
- Fita superficial: composta de símbolos do alfabeto Δ .
- Pares factíveis: pares de $\Sigma \times \Delta$ que são aceitos pelo FST.
- Pares default: pares do tipo a:a (que podem ser escritos apenas como a)

Aula 5 - 11/09/2008

14

FST para Inflexão de Número




O símbolo ^ indica um **limite de morfema**.
O símbolo # indica um **limite de palavra**.
Fitas com esses símbolos são chamadas de **fitas intermediárias**.

Aula 5 - 11/09/2008

15

FST Expandido (Nível Intermediário)




Aula 5 - 11/09/2008

16

Regras Ortográficas

- Para passar do nível intermediário para o nível superficial usamos regras ortográficas.




Name	Description of Rule	Example
Consonant doubling	1-letter consonant doubled before <i>-ing/-ed</i>	beg/begging
E deletion	Silent e dropped before <i>-ing</i> and <i>-ed</i>	make/making
E insertion	e added after <i>-s, -z, -x, -ch, -sh</i> before <i>-s</i>	watch/watches
Y replacement	y changes to <i>-ie</i> before <i>-s, -i</i> before <i>-ed</i>	try/tries
K insertion	verbs ending with vowel + <i>-c</i> add <i>-k</i>	panic/panicked

Aula 5 - 11/09/2008

17


Transdutor para Regra Ortográfica de Inserção de E



Aula 5 - 11/09/2008

18


FSTs em Cascata



Aula 5 - 11/09/2008

19

Interseção e Composição



Aula 5 - 11/09/2008

20

Stemming: O algoritmo de Porter

- Somente encontra a raiz (stem).
- Não utiliza um léxico.
- É baseado numa série de regras de re-escrita em cascata.
 - Exemplos: ATIONAL → ATE (e.g., relational → relate)
 - ING → e if stem contains vowel (e.g., motoring → motor)
 - Podem ser implementadas como um FST.
- É simples e eficiente, porém comete erros.

Errors of Commission	Errors of Omission
organization	organ
doing	doe
generalization	generic
numerical	police
policy	
	European
	analysis
	matrices
	noise
	sparse

Aula 5 - 11/09/2008

21

Correção Ortográfica

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

Aula 5 - 11/09/2008

22

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 5 - 11/09/2008

23

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 5 - 11/09/2008

24

Distância Mínima de Edição

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

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

Alinhamento

Aula 5 - 11/09/2008

25

Distância Mínima de Edição

- A distância mínima pode ser computada usando um algoritmo de **programação dinâmica**.
 - Classe de algoritmos introduzida por Bellman que resolve problemas combinando soluções de sub-problemas.

Aula 5 - 11/09/2008

26