
30 Maggio 2006

Morfologia & Part of Speech

Marco Pennacchiotti

pennacchiotti@info.uniroma2.it

Tel. 06 7259 7717

Ing.dell'Informazione, *stanza P1B-03* (nuova ala Ing.Inf, primo piano)

- **Cambio Aula**

- Giovedì → **Aula 3** (11.30 – 13.15)

- **Download Chaos**

- <http://ai-nlp.info.uniroma2.it/external/chaosproject/protectedDownload/download.html>

- **Progetto**

- Formare gruppi 3-5 persone
- Inviare e-mail per iscriversi entro **giovedì 1 Giugno**
- <http://ai-nlp.info.uniroma2.it/pennacchiotti/teaching/>

Programma

- **Breve introduzione all’NLP**

- Linguaggi Naturali e Linguaggi Formali
- Complessità

- **Morfologia**

- *Teoria:* Morfologia del Linguaggio Naturale
- *Strumenti:* Automi e Trasduttori
- *Analisi Morfologica:* con automi e trasduttori

- **Part of Speech Tagging**

- *Teoria:* Le classi morfologiche
- *Strumenti a Analisi:* modelli a regole e statistici

- **Sintassi**

- *Teoria:* Sintassi del Linguaggio Naturale
- *Strumenti:* CFG
- *Analisi Sintattica:* parsing top-down, bottom-up, Early

- **Semantica**

- Lexical Semantics
- Sentence Semantics

FSA: definizione formale

Un FSA è definito dai seguenti parametri:

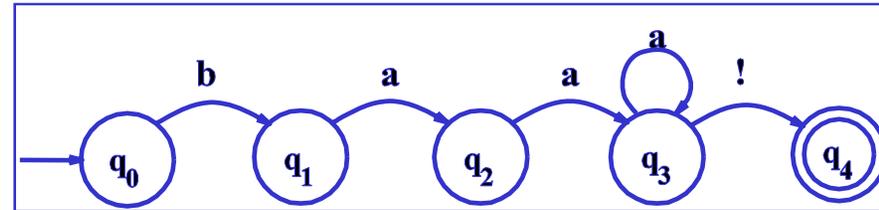
- Q : un insieme finito di N stati $q_0 \dots q_N$

- Σ : un alfabeto finito di simboli

- q_0 : lo stato iniziale

- F : un insieme di stati finali $F \subseteq Q$

- $\delta(q,i)$: funzione di transizione tra stati che restituisce un nuovo stato a partire da un dato stato e un simbolo in input

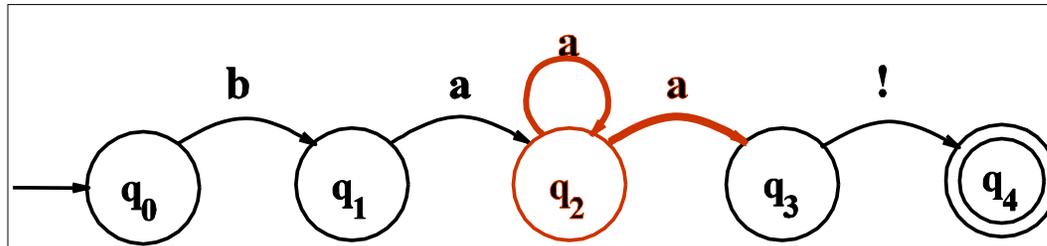


Un FSA può essere anche rappresentato attraverso una *state-transition table*

State	Input		
	b	a	!
0	1	∅	∅
1	∅	2	∅
2	∅	3	∅
3	∅	3	4
4:	∅	∅	∅

FSA non-deterministici (NFSA)

Un automa è detto **non-deterministico** se ha due archi uguali uscenti dallo stesso stato.



Quindi:

- Deterministico vuol dire che ad ogni stato può essere presa una sola decisione
- Non-Deterministico vuol dire che ad ogni stato si può scegliere tra più decisioni

Equivalenza tra FSA e NFSA

- Un NFSA può essere sempre convertito in un FSA *equivalente* (che definisce cioè lo stesso linguaggio)
- NFSA e FSA hanno quindi lo stesso potere di riconoscimento/generazione
- L'FSA equivalente di un NFSA ha sempre più stati dell'NFSA

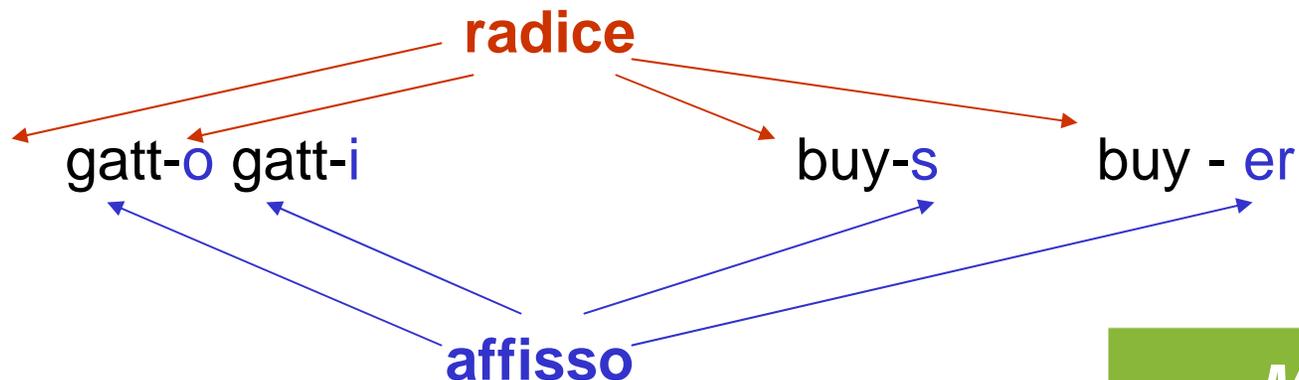
Morfologia: *definizioni*

La **morfologia** (*morphology*) è lo studio di come le **parole** sono costruite a partire da unità atomiche dette *morfemi*.

I **morfemi** (*morphemes*) sono le più piccole unità linguistiche che possiedono un significato. Possono essere divisi in due classi:

- **Radice** (*stem*) → il morfema che dà il significato principale alla parola
- **Affisso** (*affix*) → particelle apposte alla radice che ne completano il significato e la funzione grammaticale

ESEMPIO



Morfologia: *definizioni*

La **morfologia** può essere divisa in due parti principali

- **Inflectional Morphology**: combinazione di una radice con un affisso che risulta in una parola (*forma flessa*) della *stessa classe* (nome, verbo, aggettivo, ecc..) con una funzione grammaticale specifica
 - *cat* (nome sing) → *cat-s* (nome plur)
 - *cut* (verbo base) → *cut-ting* (verbo progressivo)

- **Derivational Morphology**: combinazione di una radice con un affisso che risulta in una parola di una *classe diversa*. Il significato della nuova parola non è facilmente prevedibile
 - *trasporto* (nome) → *trasport-abile* (aggettivo)
 - *computerize* (verbo) → *computeriz-ation* (nome)

Morfologia inglese

Caratteristiche:

- Concatenative morphology
- Non-agglutinative (al più 4 o 5 affissi)
- Una parola può avere più affissi:
 - *Prefissi:* *un-certain*
 - *Suffissi:* *eat-s*
 - *Combinazioni:* *un-clear-ly*
- Inflectional morphology: semplice, applicata solo a *nomi, verbi e aggettivi*
- Derivational Morphology: complessa

Inflectional Morphology

NOMI:

Due solo inflessioni:

- Plurale: *cat* → *cat-s* *thrush* → *thrush-es*
- Possessivo: *dog* → *dog's* *children* → *childrens'*

VERBI:

Quattro forme morfologiche:

- stem: *walk*
- s form: *walk* → *walk-s*
- past form: *walk* → *walked*
- *ing* form: *walk* → *walking*

- **Irregolari:** (ca. 250) Parole che non seguono le regole morfologiche (Esempio: *mouse* → *mice*
go → *goes, going, went*). La maggior parte dei nomi e verbi inglesi sono regolari

- La classe dei verbi regolari è **produttiva** : una nuova parola della lingua è automaticamente inclusa nella classe (Esempio: *fax* → *faxes, faxing, faxed*)

Quali strumenti usare ?

- *Lessico esteso*

- Un lessico (lista di parole) che contiene tutte le parole della lingua in tutte le forme flesse
- Spreco di spazio e non è *produttivo*!

- *Lessico ridotto + Automi*

- La morfologia è generalmente produttiva (gran parte delle parole segue le regole morfologiche per formare le forme flesse)
- Conviene quindi utilizzare:
 - Lessico contenente solo radici e affissi (ed eventualmente irregolarità)
 - Implementazione delle regole morfologiche in un dispositivo
 - FSA sono semplici dispositivi per implementare tali regole

FSA: *riconoscimento*

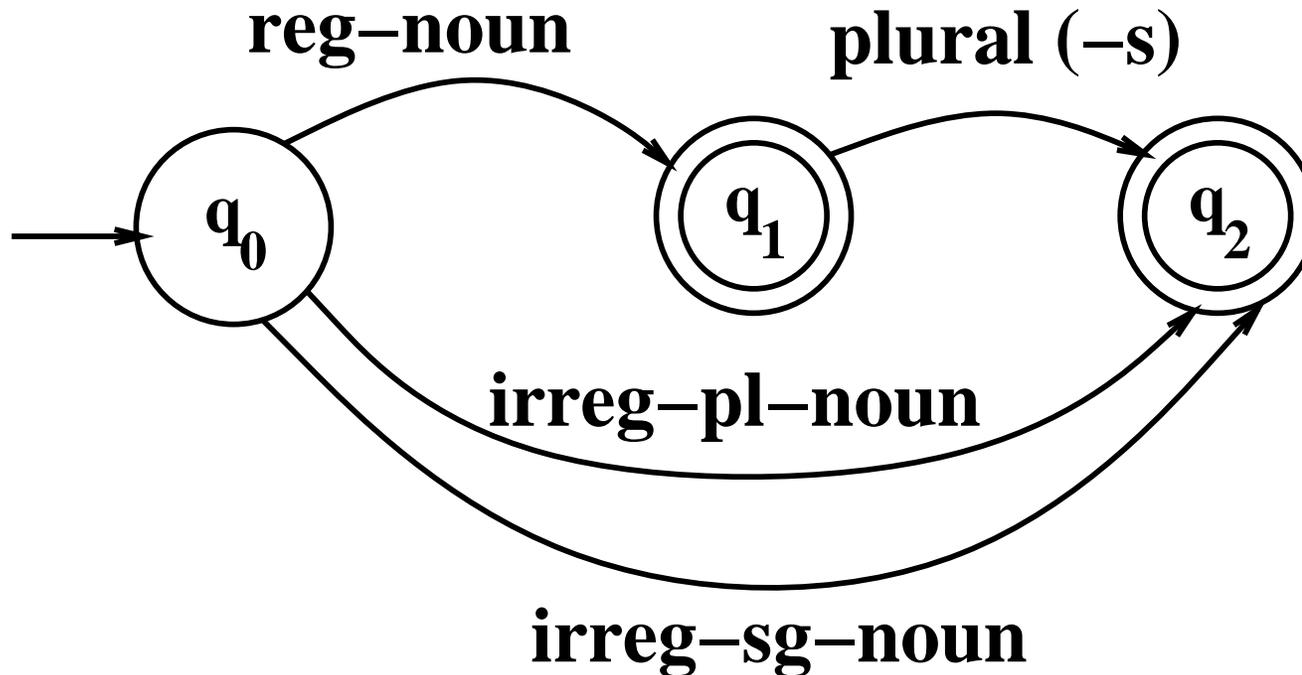
Un FSA può essere utilizzato per **riconoscere** se una parola è ammissibile in una lingua

Cosa serve:

1. **Lessico**: lista di radici ed affissi della lingua
 - Esempio: [cat,dog,cut,go,...,-s,-ed,-ation,-able,...,un-,dis-]
2. **Regole Morfologiche** (*morphotactics*): le regole di costruzione dei morfemi
 - Esempio: Plurale inglese: radice + -s
3. **Regole Ortografiche**: cambiamenti che occorrono in una parola quando due morfemi si combinano
 - Esempio: *city* → *cities*

NOMI: *regole morfologiche*

FSA per modellare l'inflessione plurale per nomi regolari ed irregolari



Come modellare i nomi (regolari ed irregolari) nell'FSA?

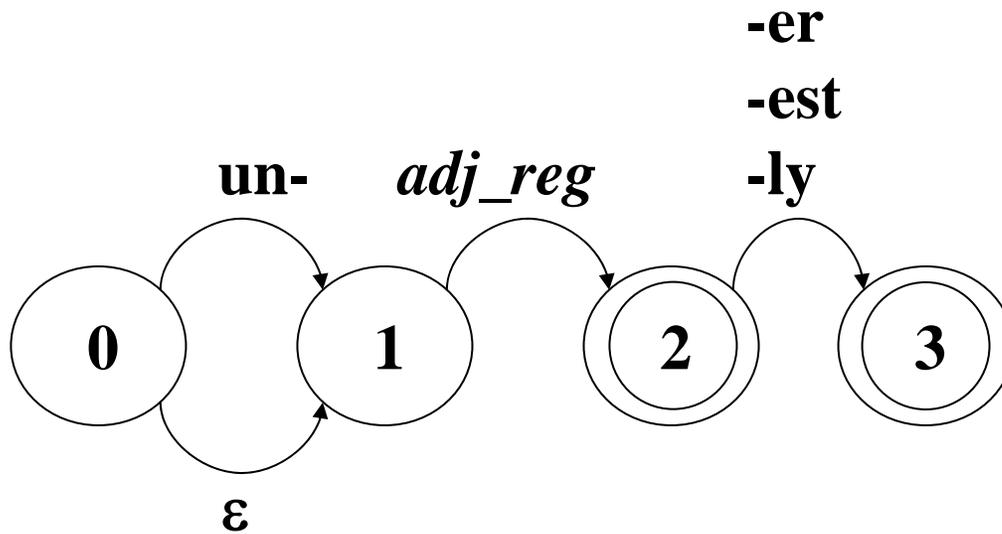
Ovvero: Come si può integrare il lessico?

FSA per la morfologia

1. Scrivere un FSA che riconosca la morfologia derivazionale degli aggettivi inglesi, ovvero:
 - *Un aggettivo può avere come prefisso negante “un-”*
 - *Un aggettivo può avere forma comparativa, superlativa e avverbiale (rispettivamente i suffissi –er,-est,-ly)*
2. Aggiungere all’FSA il seguente fatto:
 - *Esistono alcuni aggettivi “irregolari” che non possono prendere “un-” e “-ly” (es: big, cool)*
3. Integrare il lessico: regolari: *“clear, happy”*, irregolari: *“big,cool”*

Soluzione esercizio 4

1

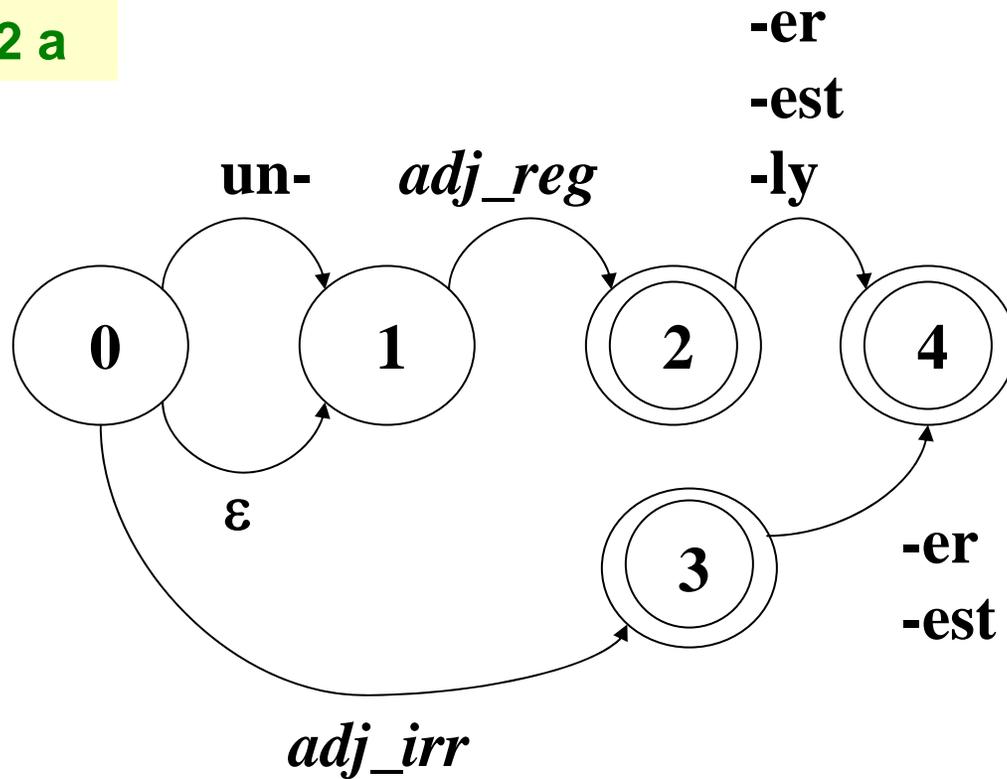


LESSICO

<i>adj_reg</i>
Clear
Happy

Soluzione esercizio 4

2 a



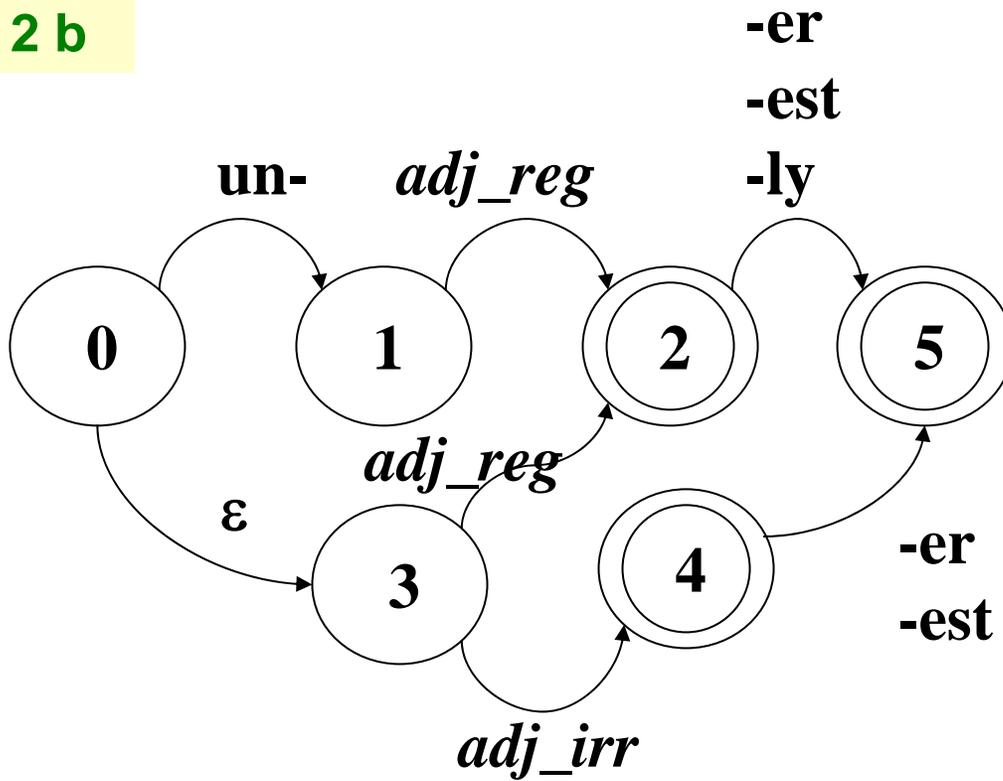
LESSICI

<i>adj_reg</i>	<i>adj_irr</i>
Clear	Big
Happy	cool

ESERCIZIO 4

Soluzione esercizio 4

2 b



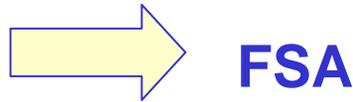
LESSICI

<i>adj_reg</i>	<i>adj_irr</i>
Clear	Big
Happy	cool

ESERCIZIO 4

Dal Riconoscimento al Parsing

RICONOSCIMENTO : indica se una data parola in input è morfologicamente corretta o no (ad esempio *gatti* è corretta, *gattare* è scorretta)



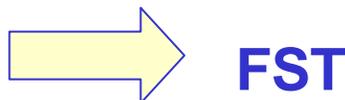
PARSING/GENERAZIONE :

- **parsing**: produce un'analisi morfologica della parola in input: data la parola in input viene restituita la sua struttura

cats → *cat +N +PL*

- **generazione**: data una struttura morfologica in input, produce una *forma superficiale* (parola)

cat +N +PL → *cats*



FST

Trasduttori a Stati Finiti (FST)

I *Trasduttori* sono automi a stati finiti con due nastri *A* e *B*

Ad es, può leggere da un nastro (ad es. “*cats*”) e scrivere sull'altro (“*cat + N + PL*”)

Quattro modalità di utilizzo dell' FST:

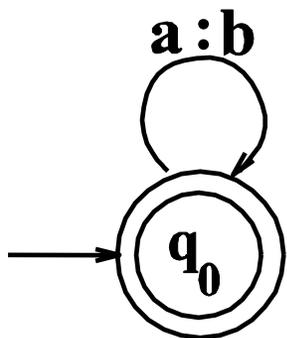
- ricognoscitore: riceve in input una coppia di stringhe su *A* e *B*, e restituisce *accept* se essa appartiene al linguaggio delle coppie
 - *cats, cat+N+PL* → *accept*
- produttore: restituisce coppie di stringhe appartenenti al linguaggio su *A* e *B*
 - Output: tutte le parole del lessico con la loro struttura
- traduttore: riceve in input una stringa su *A* (o *B*) e ne restituisce un'altra su *B* (o *A*)
 - *cats* → *cat+N+PL* (PARSING)
 - *cat+N+PL* → *cats* (GENERAZIONE)

FST: definizione formale

Un FST è definito dai seguenti parametri:

- Q : un insieme finito di N stati q_0, \dots, q_N
- Σ : un alfabeto finito di simboli complessi. Ogni simbolo complesso è una coppia di simboli $i:o$ appartenenti rispettivamente agli alfabeti I e O ($\Sigma \subseteq I \times O$)
- q_0 : lo stato iniziale
- F : un insieme di stati finali $F \subseteq Q$
- $\delta(q, i:o)$: funzione di transizione tra stati che restituisce un nuovo stato a partire da un dato stato e un simbolo complesso in input

ESEMPIO



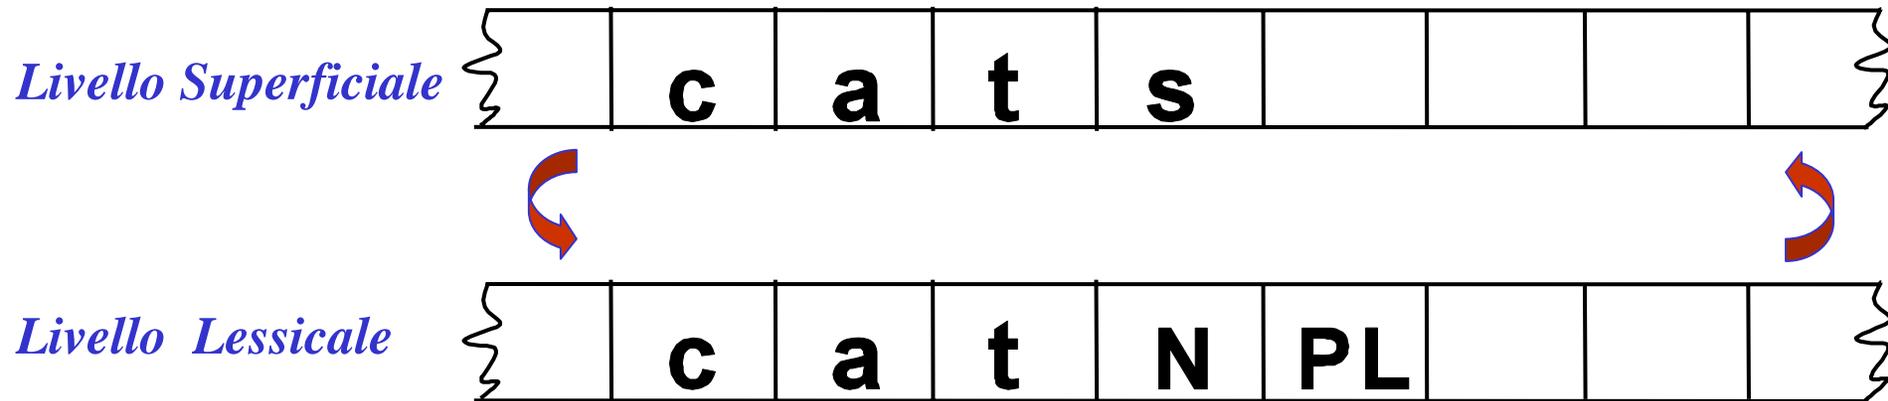
- *riconosce* tutte le coppie di stringhe in cui una ha tutte a e l'altra uno stesso numero di b
- *produce* stringhe di a su un nastro e stringhe di b sull'altro, con la stessa lunghezza
- *traduce* stringhe di a in input in stringhe di b della stessa lunghezza in output, e viceversa

Strumenti per la **Morfologia**

- **Automati a stati finiti (FSA)**
 - FSA deterministici
 - FSA non-deterministici (NFSA)
 - Introduzione alla Morfologia
 - FSA e Morfologia: *riconoscimento*
- **Trasduttori a stati finiti (FST)**
 - Cosa sono
 - **FST e Morfologia: *parsing***

FST e morfologia: *parsing*

OBIETTIVO:

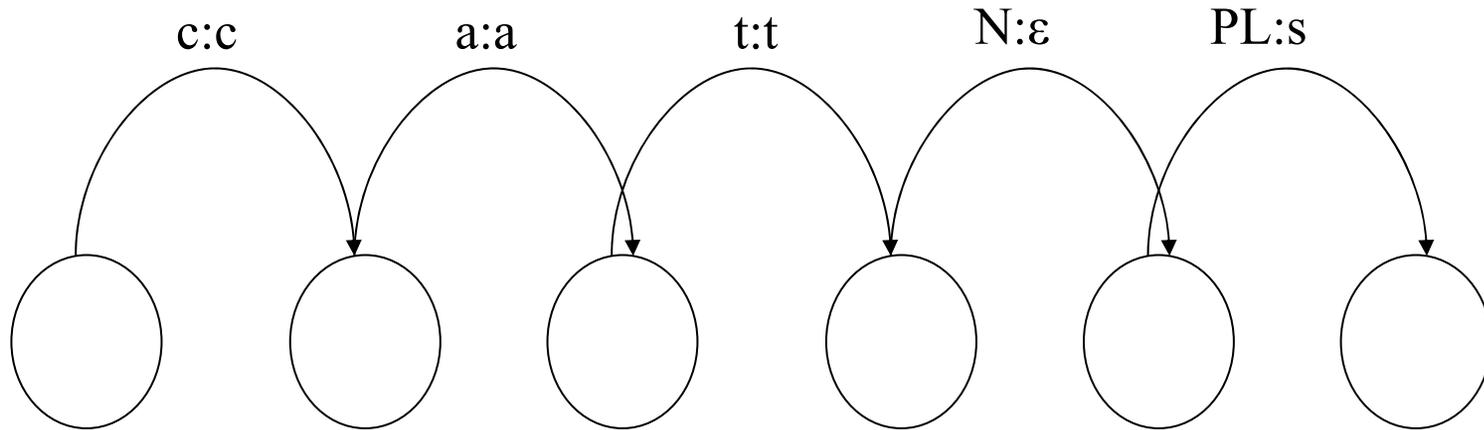


Passare da un **livello superficiale** ad un **livello lessicale** e viceversa, utilizzando un FST in funzione di *traduttore*:

- *cats* → *cat+N+PL* (PARSING)
- *cat+N+PL* → *cats* (GENERAZIONE)

FST e morfologia: *parsing*

OBIETTIVO:



Passare da un **livello superficiale** ad un **livello lessicale** e viceversa, utilizzando un FST in funzione di *traduttore*:

- *cats* → *cat+N+PL* (*PARSING*)
- *cat+N+PL* → *cats* (*GENERAZIONE*)

Analisi morfologica a due stadi

Dal livello superficiale al livello lessicale (PARSING)

Sono necessari due stadi (→ due trasduttori)

1. IDENTIFICAZIONE DEI MORFEMI: Data la parola in input sul nastro *A*, il trasduttore la divide su *B* nei morfemi costituenti (radice + affissi)
2. IDENTIFICAZIONE DELLA STRUTTURA: Dati i morfemi costituenti sul nastro *A*, il trasduttore identifica la categoria della radice e il significato degli affissi

Livello Superficiale



Livello Intermedio



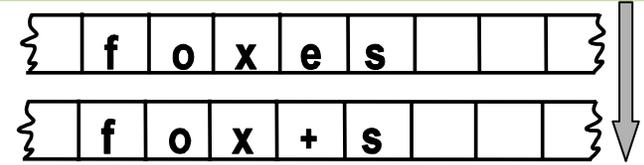
Livello Lessicale



PARSING

Stadio 1: Identificazione dei morfemi

ESEMPIO: nomi singolari/plurali



Obiettivo

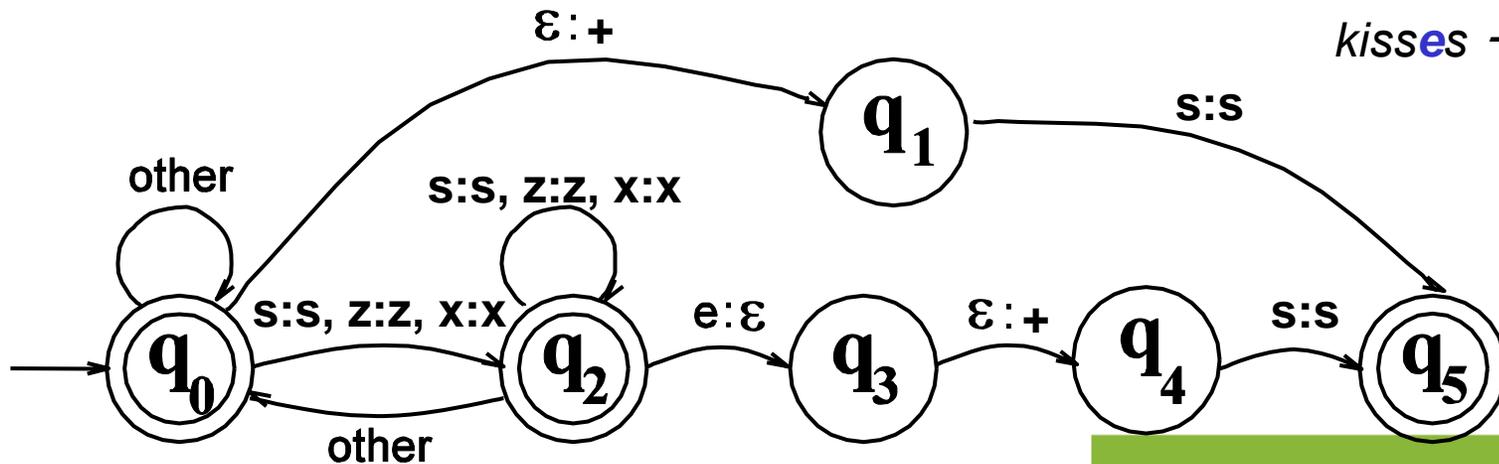
- Rappresentare con un FST le *regole ortografiche* della lingua per i nomi regolari e irregolari
- Input: *cats* Output: *cat+s*

Regola e-insertion

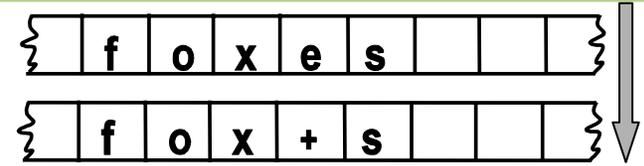
cats → *cat+s*

foxes → *fox+s*

kisses → *kiss+s*



Stadio 1: *non è così facile ...*



Problemi

- Il trasduttore gestisce solo la regola della e-insertion, e non altri casi:
 - Regola y-replacement: *berries* → *berry* +s (*berrie* +s)
 - Regola raddoppio consonanti: *beg* → *begging*
 - *Ecc. ecc.*
- Bisogna quindi implementare **più regole ortografiche**, nello stesso trasduttore, o in trasduttori paralleli!
- **Ambiguità locale**: *foxes* produce due forme di cui solo la prima è corretta: *fox*+s , *foxe*+s, *foxes*.

Identificazione dei morfemi

A

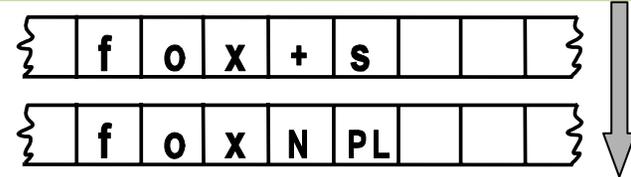
1. Scrivere l' FST che modelli la morfologia dei nomi singolari/plurali prendendo in considerazione la regola ortografica dell' *y-replacement*:
 - -y cambia in -ie prima della -s
 - ES: berry → berries

B

1. Scrivere l' FST che modelli la morfologia dei verbi presente/passato prendendo in considerazione la regola ortografica della *k-insertion*, sapendo che:
 - In generale la forma passata si forma dal presente apponendo come suffisso la particella -ed (ES: *press* → *press-ed*)
 - La *k-insertion* prevede che ai verbi terminanti in *vocale+c* sia aggiunta la *k* (ES: *panic* → *panic + k +ed*)

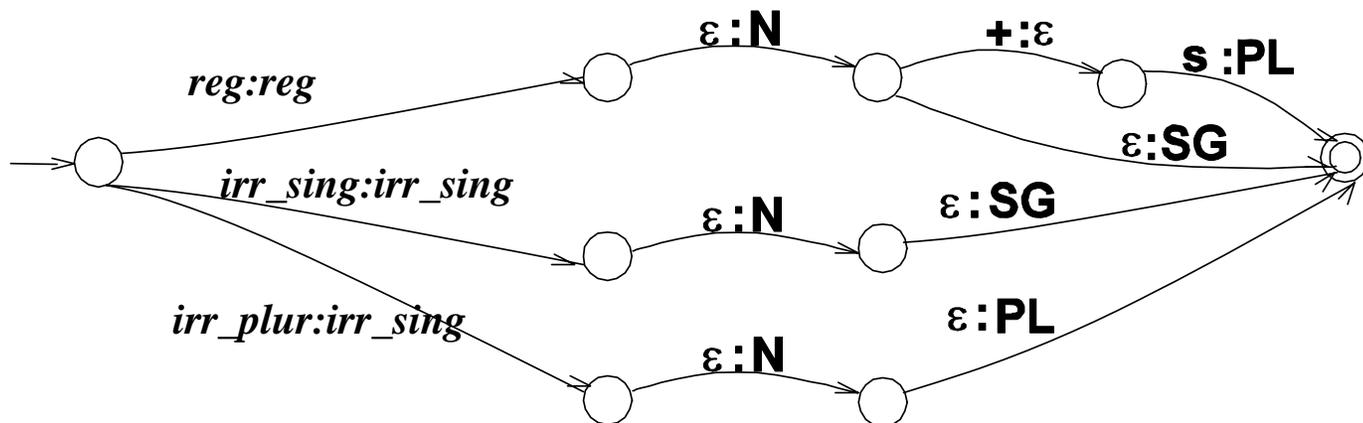
Stadio 2: Identificazione della struttura

ESEMPIO: nomi singolari/plurali



Obiettivo

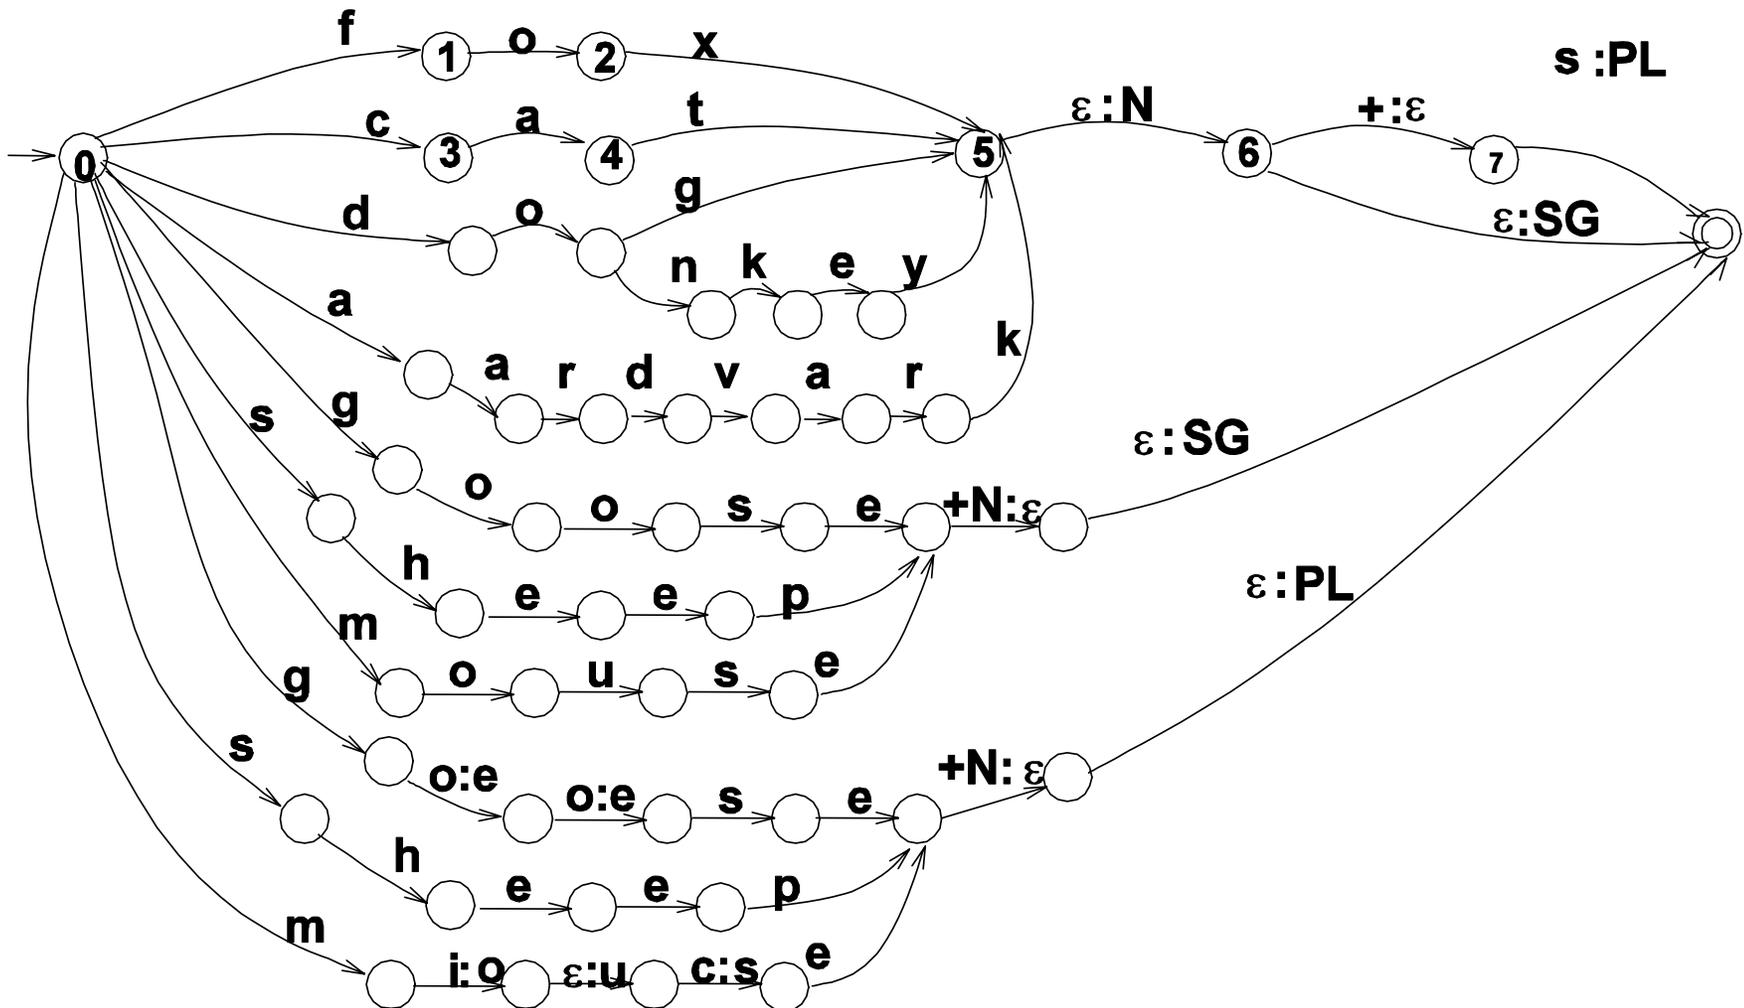
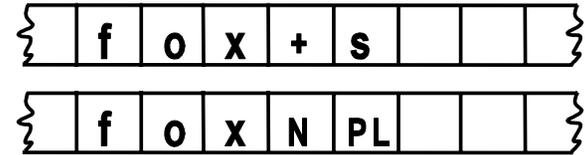
- Rappresentare con un FST le *regole morfologiche* della lingua per i nomi regolari e irregolari
- Input: *cat+s, mouse, mice* Output: *cat N PL, mouse N SG, mouse N PL*



Bisogna aggiungere il lessico !

Stadio 2: Identificazione della struttura

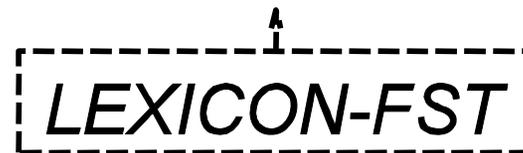
ESEMPIO: nomi singolari/plurali



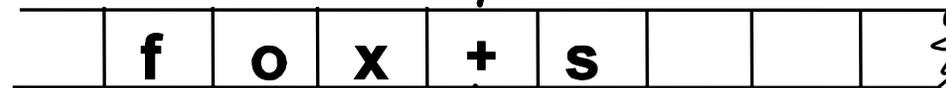
Stadio 1+2: *Combinare lessico e regole*

- E' possibile combinare i due stadi mettendo *in cascata* (in serie) i due trasduttori: l'output dell'uno sarà l'input dell'altro

Livello Lessicale

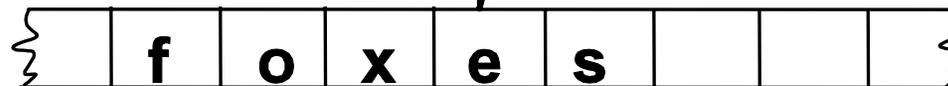


Livello Intermedio



} in serie o in parallelo

Livello Superficiale



- Oppure, è possibile fondere i due trasduttori, attraverso un'operazione di *intersezione*

Vantaggi e problemi

Vantaggi degli FST

- Computazionalmente efficienti
- Semplici
- Doppio uso: parsing e riconoscimento
 - Qual'è la morfologia di *foxes* ? *foxes* → *fox+N+PL*
 - Qual è il plurale di *fox* ? *Fox+N+PL* → *foxes*

Problemi

- Laborioso costruire e codificare un trasduttore per gestire ogni regola ed eccezione:
 - Soluzione: Tool automatici di traduzione *regola* → *FST*
- **Ambiguità globale**: *kisses* può essere sia verbo che nome
 - *kisses* → *kiss+N+PL* *kisses* → *kiss+V+3SG*
 - Per disambiguare sono necessarie risorse esterne (non morfologiche), ad esempio il contesto sintattico

Tool per il parsing morfologico

CHAOS *Morpho-Analyzer*

[/data/KB/it/db_morfo]

- Basato su lessico esteso (*dizionari*)
 - il lessico esteso è precedentemente costruito ed arricchito utilizzando *ALMA* (generatore morfologico basato su FST ed implementato in Prolog)
 - Nessun utilizzo di FST “on-line”
- Utilizza diversi dizionari:
 - Dizionario principale (IT: 115.000 parole, EN: 35.000 parole)
 - Dizionario nomi propri (IT: 80.000 nomi, EN: 52.000 nomi)
 - Dizionario terminologico (IT: 5000 termini)

morphg

[www.cogs.susx.ac.uk/research/nlp/carroll/morph.html]

- Tool per la *inflectional morphology* basato su FST
- Accuracy 99.9% in parsing/generazione

Qualche link...

DEMO di automi per la morfologia

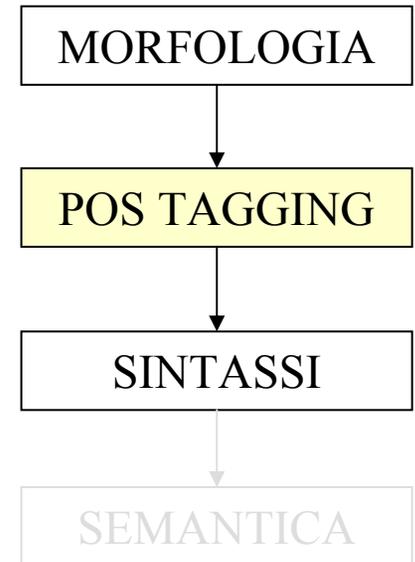
- <http://www.xrce.xerox.com/competencies/content-analysis/demos/english>
- <http://www.xrce.xerox.com/competencies/content-analysis/demos/italian>

TOOLS per costruire e gestire automi

- <http://www.research.att.com/sw/tools/fsm/>

Part of Speech Tagging

- **Part of Speech Tagging**
 - Cos'è
 - Part of Speech
 - Part of Speech Tagging
 - » Rule-based
 - » Stochastic
 - » Misto
 - Prestazioni



Part Of Speech (POS)

Part of Speech (*classi morfologiche*)

Categoria morfo-sintattiche cui una parola appartiene

Categorie principali

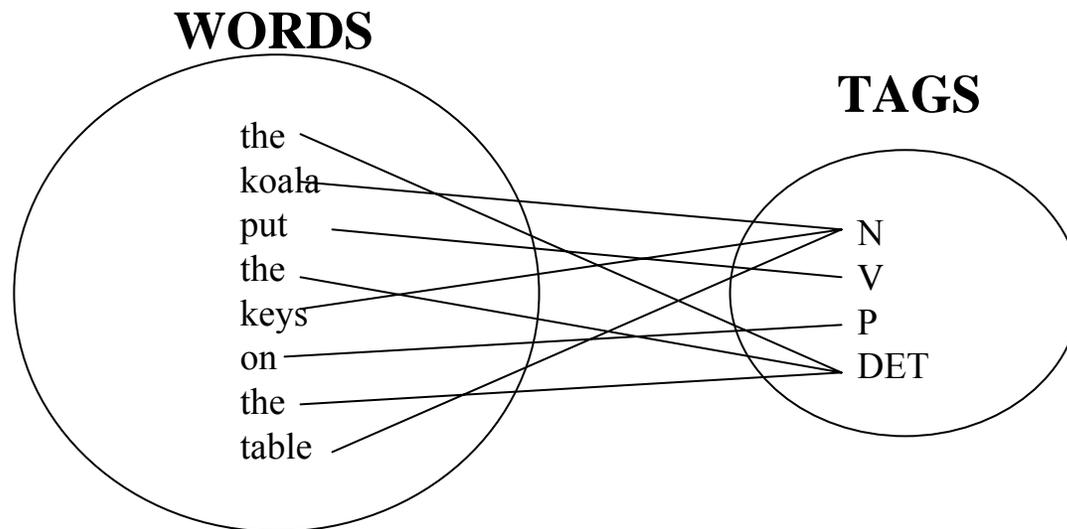
- Nomi, verbi, aggettivi, avverbi, articoli, pronomi, congiunzioni ...

Esempio

- | | | |
|-------|--------------------|--------------------------|
| ▪ N | <i>noun</i> | chair, bandwidth, pacing |
| ▪ V | <i>verb</i> | study, debate, munch |
| ▪ ADJ | <i>adj</i> | purple, tall, ridiculous |
| ▪ ADV | <i>adverb</i> | unfortunately, slowly, |
| ▪ P | <i>preposition</i> | of, by, to |
| ▪ PRO | <i>pronoun</i> | I, me, mine |
| ▪ DET | <i>determiner</i> | the, a, that, those |

POS Tagging

Processo di assegnazione della Part of Speech ad ogni parola di un corpus (insieme di documenti)



MODELLI

- Modelli a regole
- Modelli probabilistici
- Modelli misti

A cosa serve il POS Tagging?

STEMMING IN INFORMATION RETRIEVAL

- Sapendo la classe di una parola, si possono produrre le forme flesse
- Ricerca effettuata utilizzando tutte le forme flesse

PARSING

- La classe di una parola può aiutare a predire la struttura sintattica di una frase
- ES: un pronome possessivo è sempre seguito da un nome

INFORMATION EXTRACTION / QUESTION ANSWERING

- Si estrae o si restituisce solo l'informazione di una data classe
- ES: si può cercare un luogo (nome) o una azione (verbo)

Quale relazione con la morfologia ?

ANALISI MORFOLOGICA

- Data una parola, trovare le sue interpretazioni morfologiche
- Può essere presente **ambiguità**:
ES: talks → talk+s → talk V 3PS
→ talk N PL

POS TAGGING

- Data una parola, trovare la sua unica interpretazione morfologica
- Analisi morfologica + **disambiguazione**
- → metodi dell'analisi morfologica (es. FST) + algoritmi di disambiguazione

Part of Speech Tagging

- **Part of Speech Tagging**
 - Cos'è
 - **Part of Speech**
 - Part of Speech Tagging
 - » Rule-bales
 - » Stochastic
 - » Misto
 - Prestazioni

Part Of Speech

Tradizionalmente, la definizione di una POS è basata su caratteristiche:

- **Morfologiche:** gli affissi che compongono una parola
- **Sintattiche:** il contesto sintattico in cui si trova la parola

Non sono significative di solito *caratteristiche semantiche*, sebbene le classi presentino solitamente un buon grado coerenza semantica.

ESEMPIO (nomi)

I *nomi* in inglese hanno generalmente una forma singolare e una plurale (affisso –s)

I *nomi* in inglese sono solitamente preceduti da articoli o avere una forma possessiva (ES: *IBM's revenues*)

I *nomi* in inglese possono esprimere diverse categorie semantiche: persone, cose, astrazioni (ES. *relationship*), termini simil-verbali (ES: *pacing*)

Classificazione delle POS

Possono essere identificate due categorie principali:

- **CLASSI APERTE:**

- Classi a cui vengono spesso aggiunte nuove parole
- Generalmente produttive
- ES: in Inglese ed Italiano sono quattro: *nomi, verbi, aggettivi, avverbi*
- *Tutte le lingue hanno almeno le classi verbo e nome (lingua universale?)*

- **CLASSI CHIUSE:**

- Classi cui appartengono un insieme relativamente statico di parole
- ES: *articoli, preposizioni, congiunzioni, parole*
- ***Function Words:*** parole grammaticalmente significative, generalmente molto corte e frequenti nel linguaggio
 - ES: *of, and, or, you ...*

Classi Aperte

NOMI (N): cose, persone, luoghi...

- Nomi Comuni (NN) (*house, dog, ...*)
- Nomi Propri (NNP) (*Gino, Pino, ...*)
- Mass vs Count
 - *Count nouns*: hanno il plurale, sono enumerabili (*due panini*)
 - *Mass nouns*: gruppi omogenei, non enumerabili (*neve, sale...*)

VERBI (V): azioni, processi ...

- Diverse classificazioni in base a: morfologia, sintassi.

AGGETTIVI (JJ): proprietà, qualità...

- Base, Superlativi, Comparativi

AVVERBI (RB): modificatori di altre classi

- Direzionali/Locativi (*here*), Temporalis (*now*), Modali (*slowly*), di Gradazione (*very*)...

Classi Chiuse

PREPOSIZIONI : relazioni temporali, spaziali...

- Precedono i nomi (*of, in, for, ...*)
- Molto comuni

PARTICLE:

- Si combinano con i verbi, formando *phrasal verbs*
- ES: *go on, take off, ...*
- Si distinguono dalle preposizioni solo per caratteristiche sintattiche

ALTRE CLASSI:

- Articoli: *the, a, an*
- Congiunzioni: *and, or, but*
- Pronomi: personali (*I, you, us....*) e possessivi (*mine, yours, ...*)
- Ausiliari: copulativi (*be, do, have*) e modali (*should, mus, can*)
- Interiezioni, numerali, negazioni, greetings....

Tagset per l'inglese

Possono essere definite moltissime classi, in base alle caratteristiche morfo-sintattiche.

- Tagset generici (solo macro-classi: nomi, verbi, aggettivi...)
- Tagset molto specifici (fino a 200-300 tag)
- Tagset a taglia media (C5 tagset, PeenTreebank)

PENN TREEBAK:

- E' uno dei tagset più utilizzati: applicato a numerosi corpora (*Brown Corpus*)
- Comprende 45 tag: troppo generico per alcune applicazioni

ESEMPIO (dal Brown Corpus)

The/DT grand/JJ jury/NN commmented/VBD on/IN a/DT
number/NN of/IN other/JJ topics/NNS ./.

Penn Treebank tagset

Tag	Description	Example	Tag	Description	Example
CC	Coordin. Conjunction	<i>and, but, or</i>	SYM	Symbol	<i>+, %, &</i>
CD	Cardinal number	<i>one, two, three</i>	TO	"to"	<i>to</i>
DT	Determiner	<i>a, the</i>	UH	Interjection	<i>ah, oops</i>
EX	Existential 'there'	<i>there</i>	VB	Verb, base form	<i>eat</i>
FW	Foreign word	<i>mea culpa</i>	VBD	Verb, past tense	<i>ate</i>
IN	Preposition/sub-conj	<i>of, in, by</i>	VBG	Verb, gerund	<i>eating</i>
JJ	Adjective	<i>yellow</i>	VBN	Verb, past participle	<i>eaten</i>
JJR	Adj., comparative	<i>btgger</i>	VBP	Verb, non-3sg pres	<i>eat</i>
JJS	Adj., superlative	<i>wildest</i>	VBZ	Verb, 3sg pres	<i>eats</i>
LS	List item marker	<i>1, 2, One</i>	WDT	Wh-determiner	<i>which, that</i>
MD	Modal	<i>can, should</i>	WP	Wh-pronoun	<i>what, who</i>
NN	Noun, sing. or mass	<i>llama</i>	WPS	Possessive wh-	<i>whose</i>
NNS	Noun, plural	<i>llamas</i>	WRB	Wh-adverb	<i>how, where</i>
NNP	Proper noun, singular	<i>IBM</i>	\$	Dollar sign	<i>\$</i>
NNPS	Proper noun, plural	<i>Carolmas</i>	#	Pound sign	<i>#</i>
PDT	Predeterminer	<i>all, both</i>	"	Left quote	<i>(' or ")</i>
POS	Possessive ending	<i>'s</i>	"	Right quote	<i>(' or ")</i>
PRP	Personal pronoun	<i>I, you, he</i>	(Left parenthesis	<i>([({ (<</i>
PRP\$	Possessive pronoun	<i>your, one's</i>)	Right parenthesis	<i>(]) } ></i>
RB	Adverb	<i>quickly, never</i>	,	Comma	<i>,</i>
RBR	Adverb, comparative	<i>faster</i>	.	Sentence-final punc	<i>(. ! ?)</i>
RBS	Adverb, superlative	<i>fastest</i>	:	Mid-sentence punc	<i>(: ; ... - -)</i>
RP	Particle	<i>up, off</i>			

POS Tagging: ambiguità

Processo di assegnazione della Part of Speech ad ogni parola di un corpus (insieme di documenti)

AMBIGUITA'

- Ogni parola dovrebbe avere un solo POS assegnato
- Molte parole sono **ambigue** (più POS tag possibili)
- Un *POS tagger* deve *disambiguare*, restituendo se possibile un solo tag:
 - Utilizzando evidenze contestuali
 - Utilizzando evidenze probabilistiche da corpora annotati

ESEMPIO

- The **back/JJ** door
- On my **back/NN**
- Win the voters **back/RB**
- Promised to **back/VB**

ESEMPIO

“La vecchia porta la sbarra “
...proviamo a costruire regole per disambiguare

POS Tagging: ambiguità

Quanto sono ambigue le parole inglesi ?

NON AMBIGUE (1 tag): 35,340 (88,5%)
AMBIGUE (2-7 tag): 4,100 (11,5%)

2 tags	3,760
3 tags	264
4 tags	61
5 tags	12
6 tags	2
7 tags	1

POS Tagging

Caratteristiche generali dei POS tagger:

INPUT

- Tagset
- Dizionario con tag
- Frase da annotare

OUTPUT

- Frase annotata

METODI

- Rule-based: database di regole di disambiguazione
- Stochastic: risolvono le ambiguità con evidenze probabilistiche estratte da un corpus annotato (*HMM, Markov models...*)
- Misti: utilizzano regole di disambiguazione ricavate con metodi stocastici

Part of Speech Tagging

- **Part of Speech Tagging**
 - Cos'è
 - Part of Speech
 - **Part of Speech Tagging**
 - » Rule-bales
 - » Stochastic
 - » Misto
 - Prestazioni

POS Tagging: Rule Based

ESEMPIO (fase 2)

Regola 1: Rimuovere *VBN* se è il alternativa a *VBD* e se segue “<inizio frase>*PRP*”

Regola 2: Rimuovere *VB* se è in alternativa a *NN* e se segue *DT*

.....

			NN		
			RB		
	VBN		JJ		VB
PRP	VBD	TO	VB	DT	NN
<i>She</i>	<i>promised</i>	<i>to</i>	<i>back</i>	<i>the</i>	<i>bill</i>

POS Tagging: Rule Based

ENGTWOL (*Voutilainen, 1995*)

FASE 1:

- Lessico di 56,000 parole
- FST a due livelli per il parsing morfologico

FASE 2:

- 1,100 regole di disambiguazione in *espressione negativa*

ESEMPIO

Pavlov had shown that salivation ...

Pavlov	PAVLOV N NOM SG PROPER
had	HAVE V PAST VFIN SVO
shown	HAVE PCP2 SVO
that	SHOW PCP2 SVOO SVO SV ADV
	PRON DEM SG
	DET CENTRAL DEM SG
	CS
salivation	N NOM SG



Given input: "that"

If

(+1 A/ADV/QUANT)

(+2 SENT-LIM)

(NOT -1 SVOC/A)

Then **eliminate non-ADV tags**

Else **eliminate ADV**

POS tagging

POS Tagging: Stochastic

Differisce dall'approccio a regole nella fase di disambiguazione:

- Il tag corretto viene selezionato in base ad evidenze statistiche e alla teoria della probabilità
- **Approcci semplici:** *Most Frequent Tag*
- **Approcci complessi:** *HMM, Transformation-based tagging*

METODO MOST FREQUENT TAG

- **IDEA:** Le parole ambigue utilizzano un tag più spesso di altri.
- **Metodo:**
 1. Creare un dizionario e annotare manualmente un corpus
 2. Per ogni parola ambigua in un nuovo testo calcolare probabilità di annotazione
 3. Assegnare il tag più probabile

POS Tagging: Stochastic

ESEMPIO

I/PP give/VB you/PP **a/?** pen/NN

Section/NN 381/CD **a/?**

- **Possibili tag per a:** DT NN FW
- **Qual è il più probabile ?**

1. Utilizzo di un corpus

- Corpus: insieme di documenti annotato manualmente con tag non ambigui (ES: *Brown Corups*, 1 mil di parole)
- Calcolare occorrenze di *a* con i diversi tag:

a/DT	21,830
a/NN	6
a/FW	3

POS Tagging: Stochastic

2. Calcolo della probabilità di annotazione con un determinato tag

- ES: Qual è la probabilità che la parola abbia un certo tag?

$$P(\text{tag} \mid \text{word}) = \frac{\text{Count}(\text{word is tag})}{\text{total Count}(\text{word})}$$

- La probabilità viene stimata con delle *conte statistiche* nel corpus (ad esempio nel Brown corpus, $P(\text{Verb}|\text{race}) = 96/98 = .98$)
- Nell'esempio:

$$P(\text{DT} \mid a) = \frac{\text{Count}(a \text{ is DT})}{\text{total Count}(a)} = \frac{21,830}{21,839} = 0,99996$$

$$P(\text{NN} \mid a) = \frac{\text{Count}(a \text{ is NN})}{\text{total Count}(a)} = \frac{6}{21,839} = 0,00002$$

POS Tagging: Stochastic

3. Assegnazione del tag più probabile

I/PP give/VB you/PP **a/DT** pen/NN

Section/NN 381/CD **a/DT** ← **ERRATO (NM)**

LIMITI

- Annota bene in molti casi
- Nei casi più rari sbaglia sempre
- Per aumentare le prestazioni è necessario prendere in considerazione altre informazioni.
 - Ad esempio: guardare il tag della parola precedente e successiva risolverebbe il caso precedente
 - Implementare automaticamente in versione probabilistica le regole dei sistemi rule-based (*learning*)
- **Approcci complessi:** *HMM, Transformation-based tagging*