




A nyelvtechnológia alapjai



5. Gyakorlat

Kétszintes morfológia



- Chomsky (1957): generatív nyelvtan
 - A formális nyelveket jól tudjuk kezelni: modellezzük a természetes nyelvet valamilyen formális nyelvvel.
- próbáljuk meg reguláris nyelvvel, mert az a legkényelmesebb
- bizonyos szintaktikai jelenségekre nem elég – vita azóta is
 - →környezetfüggő kell
- morfológia leírására viszont alkalmas!
- Példa:
 - kutya + t = kutyát
 - perec + vAl = pereccel



- sorba rendezett „újraíró szabályok” = Chomsky-nyelvtan produkciós szabálya
 - újraírás: $S \rightarrow abc$ alkalmazásakor S eltűnik
- szabályok sorrendje nyilván fontos
- a szabályalkalmazás után az elemzés újabb szintje jön létre



- Kimmo Koskenniemi (1983): kétszintes morfológia
 - Lényege: párhuzamos generatív szabályokat egy szabállyá alakító algoritmus.
- reguláris (=véges állapotú) eszköz a morfológia leírására



- nem sorrendben futnak, hanem párhuzamosan az automaták metszetét számolja ki
- szabályok sorrendje nem számít
 - egymástól függetlenül lehet leírni az egyes jelenségeket
- csak egy szabály → összesen két szint:
 - mögöttes – felszíni (lexical – surface)
 - hivatkozhatunk a mögöttes és a felszíni szimbólumokra
- nem újraírás: megfeleltetés
- a szabályok kétirányúak
 - generálás: mögöttes $\leftrightarrow$ felszíni: elemzés



- Szabályformátum
 - példa: latin kiejtés
 - lexikon: leírt alak (pl. ratio), felszín: kiejtés (racio)
 - Forma:
 - $t:c \leq _ @:i$
 - szimbólum: mögöttes:felszíni
 - $x:x$ rövidítése: x
 - a szimbólum helye a környezetben: $_$
 - tetszőleges elem: $@$



- Szabályformátum
 - üres elem: $0 \rightarrow$ beszúrás: $0:x$, törlés: $x:0$
 - Példa: $y:0 \leq g _ g y$
- operátorok: $\Rightarrow$, $\leq$, $\leq\Rightarrow$, $/\leq$

$a:b \Leftrightarrow l_r$	$\Rightarrow$ és $\leq$ egyszerre
$a:b \Rightarrow l_r$	ha $a:b$ megjelenik, akkor mindenképp az adott környezetben kell megjelennie
$a:b \leq l_r$	ha a mögöttes a az adott környezetben jelenik meg, akkor mindenképp b -ként kell realizálódnia
$a:b /\leq l_r$	ha a mögöttes a az adott környezetben jelenik meg, akkor sosem realizálódhat b -ként

t:c <=> _ @:i

	t	t	@	@
	c	@	i	@
1:	2	3	1	1
2.	0	0	1	0
3:	2	3	0	1

- az automata éleit szimbólumpárokkal címkézzük
- kezdőállapot: az első
- elfogadó állapot: a kettőspontos



- Fájlok:
 - szabályok: .rul
 - lexikon: .lex
 - „take” fájlok: .tak – szkript
 - generálás fájlok: .gen
 - felismerés fájlok: .rec
- Parancsok:
 - l(oad) r(ules) <fájl>
 - l(oad) l(exicon) <fájl> – ebben a sorrendben!
 - t(ake) <fájl>
 - g(enerate) – üzemmód
 - r(ecognize) – üzemmód
 - co(mpare) g(enerate)/r(ecognize)



Xerox Finite-State Tool

- Xerox Finite-State Tool
 - Xerox Palo Alto Research Center(PARC)
 - Xerox Research Centre Europe(XRCE)
- Tools
 - xfst – interface to Finite-State Calculus algorithms
 - lexc – lexicon compiler
 - twolc – two-level rule compiler



- Stack – Last-in, first-out (LIFO)
 - push, pop
 - a legfelső automatát használja
- Automaták – reguláris kifejezések
 - define *változó reguláris_kifejezés* ;
 - read regex *reguláris_kifejezés* ;
- Felszíni szint - elemzés
 - apply up
- Mögöttes szint - generálás
 - apply down



- Skript fájl
 - Betöltés: `source script.xfst`
 - `define var [...];`
 - `regex [var];`
- Környezetfüggő szabályok
 - $[A \rightarrow B \mid L _ R]$
 - A-ból B lesz, ha A előtt L és A után R áll



- Fontosabb reguláris kifejezése és operátorok
 - $\emptyset$ – üres sztring (epsilon)
 - $?$ – bármilyen sztring (any)
 - $\cdot\# \cdot$ – sztring eleje vagy vége
 - $()$ – opcionális
 - $+$ – iteráció: 1 vagy többször
 - $*$ – iteráció: 0 vagy többször
 - $|$ – únio
 - $\cdot o \cdot$ – kompozíció



Köszönöm a figyelmet



ध्यान देने के लिए आपका धन्यवाद
आप अपना ध्यान के लिए धन्यवाद
थैंक यू फॉर योर अटेंशन

Thank you for your attention
Thank you for your attention
Thank you for the attention

Merci de votre attention
Je vous remercie pour votre attention
Merci pour l'attention

感谢您的关注
谢谢你的关注
谢谢您的注意