

6. Algoritmikus kérdések, CYK algoritmus

1. Adott egy $L \subseteq \{0, 1\}^*$ reguláris nyelv. Az a kérdés, hogy tartalmaz-e minden 0-val kezdődő szót. Adjon eljárást, ami ezt a kérdést eldönti, ha a nyelv megadásának módja
- véges automata
 - reguláris kifejezés
 - reguláris nyelvtan

Megoldás: Jelölje L_0 a 0-val kezdődő szavak nyelvét. Ekkor a kérdés: Igaz-e, hogy $L \cap L_0 = L_0$?

(a) Vegyünk L_0 -hoz a minimálautomatát. Ebből és az L -et megadó véges automatából elkészítjük a metszethez tartozó véges automatát, majd ezt minimalizáljuk. Ha az eredmény izomorf az L_0 minimálautomatájával, akkor a válasz igen, különben a válasz nem.

(b) Készítsünk a reguláris kifejezésből véges automatát. Innen ugyanaz, mint az (a). (Előzőleg elhagyhatjuk a reguláris kifejezésből az 1-gyel kezdődő tagokat, így a kezdő automatánk kisebb lehet.)

(c) Ha elhagyjuk az $S \rightarrow 1A$ típusú szabályokat, az nem elég, mert az is kell, hogy minden L_0 -beli generálható. De az automatára áttérés itt is működik – ezt akár csinálhatjuk a teljes nyelvtanból vagy az $S \rightarrow 1A$ alakú szabályok elhagyása után.

2. Adott egy M nemdeterminisztikus véges automata és egy R reguláris kifejezés. Vázzon algoritmust annak eldöntésére, hogy
- az M által elfogadott $L(M)$ nyelv megegyezik-e a reguláris kifejezés $L(R)$ nyelvével,
 - a két nyelv csak véges sok szóban különbözik-e!

Megoldás:

(a) Készítsünk a reguláris kifejezésből a tanult algoritmussal véges automatát. Ezt determinizáljuk és minimalizáljuk. Most már csak azt kell ellenőrizni, hogy az M determinizálása és minimalizálása után kapott automatával izomorf DVA-t kaptunk-e.

(b) Kezdjük, mint az előbb: készítsünk a reguláris kifejezésből a tanult algoritmussal véges automatát. Ezt determinizáljuk és minimalizáljuk, legyen ez M_R . Determinizáljuk az M automatát is, ez legyen M' . Az a kérdés, hogy az $L = (L(M_R) - L(M')) \cup (L(M') - L(M_R))$ nyelv véges-e. Ennek eldöntéséhez készítsük el az L -hez tartozó minimálautomatát, felhasználva a különbséghez és az unióhoz tartozó konstrukciót (amiből kapott automatát aztán determinizálni, minimalizálni kell). Most már csak azt kell ellenőrizni, hogy ez a DVA nem tartalmaz olyan kört, amiből elérhető elfogadó állapot.

Az utóbbi rész (minimalizálás, kör keresés) helyettesíthető annak ellenőrzésével, hogy a kapott automata nem fogad el egyetlen olyan szót sem, melynek hossza p és $2p$ közé esik. (Itt a pumpálási hossz helyett választhatunk annál nagyobb p értéket is amire pl. a determinisztikus teljes automata állapotainak száma megfelelő.)

3. Az $L \subseteq \{0, 1\}^*$ nyelvben csak véges sok szó van, és ezek közé tartozik a 10 db 0-ból álló szó is. Igazolja, hogy a nyelv reguláris de a minimálautomatája legalább 11 állapotú!

Megoldás: Jelölje s a minimálautomata állapotszámát.

1. változat – használjuk a tanultakat: Minden véges nyelv reguláris (lehet pl. NVA-t készíteni, amiben minden nyelvbeli szóhoz egy-egy külön út tartozik, amikben csak a kezdőállapot közös. Hasonlóan lehet egyszerű reguláris nyelvtant is adni). Tudjuk, hogy a nyelv pontosan akkor véges, ha minden szavának a hossza legfeljebb p , ami a pumpálási hosszt jelöli. Tehát most $10 < p$. A pumpálási lemma bizonyításában p egy determinisztikus teljes véges automata állapotszáma, azaz lehet $p = s$. Ezért $10 < s$.

2. változat – elemi: A 10 hosszú szóhoz egy 11 állapotot tartalmazó elfogadó számítási út tartozik. Ha ennek állapotai között van ismétlődés, akkor van egy kör a számítási útban, ami akárhányszor ismétlődő, azaz végtelen a nyelv. Tehát minden VA legalább 11 állapotú.

4. Hozza a következő nyelvtanokat Chomsky-normálformájúra! Milyen nyelvet generálnak a felsorolt nyelvtanok?

(a) $S \rightarrow aSa \mid ab$

(b) $S \rightarrow aSa \mid bSa \mid \varepsilon$

(c) $S \rightarrow aAbBc \mid aCbDc, A \rightarrow aAb \mid ab, B \rightarrow Bc \mid c, C \rightarrow aC \mid a, D \rightarrow bDc \mid bc$

(d) $E \rightarrow E + E \mid E * E \mid a$

Megoldás:

(a) A nyelv: $\{a^{k+1}ba^k : k \geq 0\}$

1. rész (minden legalább 2 hosszú jobb oldal csak változókból áll):

$$S \rightarrow X_a S X_a \mid X_a X_b \quad X_a \rightarrow a \quad X_b \rightarrow b$$

2. rész (feldarabolás):

$$S \rightarrow X_a Y \mid X_a X_b \quad Y \rightarrow S X_a \quad X_a \rightarrow a \quad X_b \rightarrow b$$

(b) A nyelv: páros hosszú szavak, a felétől kezdve csupa a betű.

Ez nem egy szabályos CF nyelvtan, előbb az ε -szabálytól meg kell szabadulni. Ennek eredménye:

$$S' \rightarrow \varepsilon \mid S \quad S \rightarrow aSa \mid aa \mid bSa \mid ba$$

A keletkezett egyszeres szabályt is meg kell szüntetni:

$$S' \rightarrow \varepsilon \mid aSa \mid aa \mid bSa \mid ba \quad S \rightarrow aSa \mid aa \mid bSa \mid ba$$

Most jöhet az 1. rész:

$$S' \rightarrow \varepsilon \mid X_a S X_a \mid X_a X_a \mid X_b S X_a \mid X_b X_a \quad S \rightarrow X_a S X_a \mid X_a X_a \mid X_b S X_a \mid X_b X_a \quad X_a \rightarrow a \quad X_b \rightarrow b$$

2. rész (az algoritmust követve, nem optimalizálunk!)

$$S' \rightarrow \varepsilon \mid X_a Y \mid X_a X_a \mid X_b Z \mid X_b X_a \quad S \rightarrow X_a R \mid X_a X_a \mid X_b T \mid X_b X_a \quad X_a \rightarrow a \quad X_b \rightarrow b$$

$$Y \rightarrow S X_a \quad Z \rightarrow S X_a \quad R \rightarrow S X_a \quad T \rightarrow S X_a$$

(A 4 legutóbb bevezetett változót lehetne egyetlen változóval helyettesíteni.)

(c) Az A változóból levezethetők: $L_A = \{a^k b^k : k \geq 1\}$, a B változóból levezethetők: $L_B = \{c^\ell : \ell \geq 1\}$, a C változóból levezethetők: $L_C = \{a^m : m \geq 1\}$, a D változóból levezethetők: $L_D = \{b^n c^n : n \geq 1\}$. Ezek alapján a nyelv: $aL_a bL_B c \cup aL_C bL_D c = \{a^p b^q c^r : p, q, r \geq 2, p = q \text{ vagy } q = r\}$

Átalakítás 1. rész:

$$S \rightarrow X_a A X_b B X_c \mid X_a C X_b D X_c$$

$$A \rightarrow X_a A X_b \mid X_a X_b \quad B \rightarrow B X_c \mid c \quad C \rightarrow X_a C \mid a \quad D \rightarrow X_b D X_c \mid X_b X_c$$

$$X_a \rightarrow a \quad X_b \rightarrow b \quad X_c \rightarrow c$$

2. rész

$$S \rightarrow X_a Y_1 \mid X_a Z_1 \quad Y_1 \rightarrow A Y_2 \quad Y_2 \rightarrow X_b Y_3 \quad Y_3 \rightarrow B X_c \quad Z_1 \rightarrow C Z_2 \quad Z_2 \rightarrow X_b Z_3 \quad Z_3 \rightarrow D X_c$$

$$A \rightarrow X_a R \mid X_a X_b \quad R \rightarrow A X_b \quad B \rightarrow B X_c \mid c \quad C \rightarrow X_a C \mid a \quad D \rightarrow X_b T \mid X_b X_c \quad T \rightarrow D X_c$$

$$X_a \rightarrow a \quad X_b \rightarrow b \quad X_c \rightarrow c$$

(d) A nyelv az (egyszerű, zárójel nélküli) aritmetikai kifejezések nyelve.

1. rész:

$$E \rightarrow E X_+ E \mid E X_* E \mid a \quad X_+ \rightarrow + \quad X_* \rightarrow *$$

2. rész

$$E \rightarrow E Y \mid E Z \mid a \quad Y \rightarrow X_+ E \quad Z \rightarrow X_* E \quad X_+ \rightarrow + \quad X_* \rightarrow *$$

5. Egy $A \rightarrow \alpha$ nyelvtani szabály hossza legyen $1 + |\alpha|$. Egy CF nyelvtan hossza jelentse a benne levő szabályok hosszainak összegét.

Legyen $\Sigma = \{0, 1\}$ és G egy egyszeres szabályok nélküli CF nyelvtan, amiben n változó van és a nyelvtan hossza N . A G -ből a tanult módon elkészítjük a Chomsky-normálformájú G' nyelvtant. Az n és N paraméterek segítségével adjon felső becslést G' változóinak számára és a G' nyelvtan hosszára!

Megoldás: A régi változók mellett Σ minden karakteréhez tartozhat új változó és egy új szabály. Egy $A \rightarrow \alpha$ szabályból pedig $|\alpha| - 2$ új változó keletkezik és ezt $|\alpha| - 1$ új 3 hosszú szabállyal helyettesítjük. Tehát $h = 1 + |\alpha|$ hosszából $3(|\alpha| - 1) = 3(h - 2) \leq 3h$ hossz lesz. Vegyük észre, hogy ez $|\alpha| = 2$ esetében is igaz, és a végső becslés az $A \rightarrow a$ alakúaknál is helyes (az utóbbi esetekben a hossz nem változik).

A CNF-ben a változók száma $n' \leq n + |\Sigma| + N - 3 = n + N - 1$.

Az új nyelvtan hossza $N' \leq 2|\Sigma| + 3N \leq 3N + 6$.

6. A Cocke-Younger-Kasami algoritmussal elemezzük az **aaab** szót a következő nyelvtan alapján.

$$S \rightarrow XY \mid YX \quad X \rightarrow AZ \mid a \quad Z \rightarrow XA \quad Y \rightarrow AT \mid AA \mid b \quad T \rightarrow AY \quad A \rightarrow a$$

Az alábbi táblázatban már kitöltöttük a 2. és 3. sorokat.

- Töltse ki az első sort!
- Mit jelent az, hogy két S szimbólum került a 3. sor első mezőjébe?
- Egészítse ki a megfelelő indexekkel a táblázatban szereplő változókat!
- Mi lesz a legfelső mező tartalma?
- A táblázat alapján állapítsa meg, hogy a megadott szó levezethető-e a nyelvtanból!

4.				
3.	S S	Y		
2.	X T	Z	S	
1.	Y	Y	T	
	a	a	a	b

Megoldás: A nyelvtan Chomsky-normálformában van, a CYK algoritmust átalakítás nélkül lehet rá alkalmazni,

- Ide azok a változók jönnek amiknek van az adott betűből álló jobb oldala, lásd a táblázat.
- Azt, hogy S -ből az adott szó 3 hosszú kezdőszelete kétféleképpen is levezethető.
- (c-d) Lásd a táblázat. A nem egy betűs szabályokat számoztuk meg:

$$S \rightarrow \overset{1}{XY} \mid \overset{2}{YX} \quad X \rightarrow \overset{3}{AZ} \mid a \quad Z \rightarrow \overset{4}{XA} \quad Y \rightarrow \overset{5}{AT} \mid \overset{6}{AA} \mid b \quad T \rightarrow \overset{7}{AY} \quad A \rightarrow a$$

4.	$S_{1,1}$ $T_{7,1}$			
	$S_{2,3}$			
3.	$S_{1,1}$ $S_{2,2}$	$Y_{5,1}$		
	$X_{3,1}$ $T_{7,1}$			
2.	$Z_{4,1}$	$Z_{4,1}$	$S_{1,1}$	
	$Y_{6,1}$	$Y_{6,1}$	$T_{7,1}$	
1.	X	X	X	Y
	A	A	A	Y
	a	a	a	b

(e) Mivel S szerepel a legfelső mezőben, a szó levezethető. (Sőt, mivel kétszer is szerepel, kétféle levezetési fa is van. Az indexek mutatják, hogy az egyik az 1., a másik a 2. szabállyal indul.)

7. A CYK-algoritmussal elemezze az alábbi nyelvtant használva az **abbba** és az **abbba** szavakat! Rajzolja fel a kapott levezetési fákat is!

$$S \rightarrow AX \mid BY \mid AA \mid BB \quad X \rightarrow SA \quad Y \rightarrow SB \quad A \rightarrow a \quad B \rightarrow b$$

Megoldás: A nyelvtan Chomsky-normálformában van, tehát az algoritmus a nyelvtan további átalakítása nélkül alkalmazható.


Beszámozzuk a szabályokat:

$$S \rightarrow \overset{1}{AX} \mid \overset{2}{BY} \mid \overset{3}{AA} \mid \overset{4}{BB} \quad X \rightarrow \overset{5}{SA} \quad Y \rightarrow \overset{6}{SB} \quad A \rightarrow a \quad B \rightarrow b,$$

majd kitöltjük a táblázatot.

Látszik, hogy egyetlen levezetési fa van a szóhoz:

6.	$S_{1,1}$					
5.	—	$X_{5,4}$				
4.	—	$S_{2,1}$	—			
3.	—	$Y_{6,2}$	$Y_{6,2}$	$X_{5,2}$		
2.	—	$S_{4,1}$	$S_{4,1}$	$S_{4,1}$	—	
1.	A	B	B	B	B	A
	a	b	b	b	b	a



A másik, rövidebb szóra:

5.	—			
4.	—	—		
3.	—	$Y_{6,2}$	$X_{5,2}$	
2.	—	$S_{4,1}$	$S_{4,1}$	—
1.	A	B	B	A
	a	b	b	a

Mivel a felső mezőbe nem került be az S , ezért a szó nem vezethető le, nincs levezetési fája.

8. Adjon meg egy 2 szalagos, determinisztikus Turing-gépet (az átmeneti függvény leírásával) az $\{a^n b^n c^n : n \geq 0\}$ nyelvhez!

Megoldás: A működés elve: a 2. szalagra egy, a szalag elejét mutató X karakter kiírása után q_a állapotban lemásoljuk az a -kat. Amikor az 1. szalagon a b -khez érünk, egy új q_b állapotban összehasonlítjuk a b -k számát a 2. szalagon levő a -kkal. Ha egyszerre érünk az 1. szalagon az első c -hez és a 2-on az X -hez, akkor a q_c állapotban az első szalag c -inek számát hasonlítjuk a 2. szalag a -ihoz. Elfogadunk (q_+), ha egyszerre érünk az első $*$ -hoz mindkét szalagon.

	$(*,*)$	$(a,*)$	$(b,*)$	(b,a)	(c,X)	(c,a)
q_0	$(q_+, *, *, H, H)$	(q_a, a, X, H, J)				
q_a		(q_a, a, a, J, J)	$(q_b, b, *, H, B)$			
q_b				(q_b, b, a, J, B)	(q_c, c, X, H, J)	
q_c	$(q_+, *, *, H, H)$					(q_c, c, a, J, J)

Elfogadó állapot: q_+ – itt a számítás véget ér. Vagy az üres bemenetnél léphetünk ide q_0 -ból, vagy ha sikeresen feldolgoztuk az egész szót.