

6. Algoritmikus kérdések, Chomsky-normálforma

1. Adott $L_1, L_2 \subseteq \{a, b\}^*$ nyelvekhez legyen L_{\oplus} az azokból a szavakból álló nyelv, melyek az L_1 és L_2 nyelvek közül pontosan az egyikben vannak benne. Igazolja, hogy van olyan L_1 és L_2 környezetfüggetlen nyelv, melyre
- L_{\oplus} is környezetfüggetlen!
 - L_{\oplus} nem környezetfüggetlen!

Megoldás:

(a) Legyen pl. L_1 tetszőleges CF nyelv és $L_2 = L_1$. Ekkor $L_{\oplus} = \emptyset$, ami környezetfüggetlen (reguláris is). Egy másik egyszerű példa: $L_1 = \emptyset$, L_2 tetszőleges CF nyelv. Ekkor $L_{\oplus} = L_2$.

(b) Legyen $L_1 = \{a, b\}^*$. Ekkor $L_{\oplus} = \overline{L_2}$. Tehát ha L_2 egy olyan CF nyelv, aminek komplementere nem CF (tudjuk, hogy van ilyen), akkor L_{\oplus} nem környezetfüggetlen.

2. Lehetséges-e, hogy ha az $L_1, L_2 \subseteq \Sigma^*$ nyelvek környezetfüggetlenek, akkor az $L_1 \cup L_2$ és az $L_1 \cap L_2$ nyelvek közül
- pontosan az egyik környezetfüggetlen?
 - mindkettő környezetfüggetlen?
 - egyik sem környezetfüggetlen?

Megoldás: Tudjuk, hogy a CF nyelvek zártak az unióra, de a metszetre nem. Ennek alapján

- Lehet: L_1 és L_2 legyen olyan CF, amiknek metszete nem CF.
- Lehet, pl. $L_1 = L_2$ esetén az uniójuk és a metszetük is az L_1 , tehát CF.
- Nem lehet, hiszen az unió mindig CF.

3. 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) Vegyük 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.

4. 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.)

5. 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 nyelvbéli 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 ismételtető, azaz végtelen a nyelv. Tehát minden VA legalább 11 állapotú.

6. 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!)

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

$$Y \rightarrow SX_a \quad Z \rightarrow SX_a \quad R \rightarrow SX_a \quad T \rightarrow SX_a$$

(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:

$$\begin{aligned} S &\rightarrow X_a A X_b B X_c \mid X_a C X_b D X_c \\ A &\rightarrow X_a A X_b \mid X_a X_b \quad B \rightarrow B X_c \mid c \quad C \rightarrow X_a C \mid a \quad D \rightarrow X_b D X_c \mid X_b X_c \\ X_a &\rightarrow a \quad X_b \rightarrow b \quad X_c \rightarrow c \end{aligned}$$

2. rész

$$\begin{aligned} S &\rightarrow X_a Y_1 \mid X_a Z_1 \quad Y_1 \rightarrow A Y_2 \quad Y_2 \rightarrow X_b Y_3 \quad Y_3 \rightarrow B X_c \quad Z_1 \rightarrow C Z_2 \quad Z_2 \rightarrow X_b Z_3 \quad Z_3 \rightarrow D X_c \\ A &\rightarrow X_a R \mid X_a X_b \quad R \rightarrow A X_b \quad B \rightarrow B X_c \mid c \quad C \rightarrow X_a C \mid a \quad D \rightarrow X_b T \mid X_b X_c \quad T \rightarrow D X_c \\ X_a &\rightarrow a \quad X_b \rightarrow b \quad X_c \rightarrow c \end{aligned}$$

(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

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

7. 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 $N' \leq 2|\Sigma| + 3N \leq 3N + 6$.