

Megoldás a nehezebb/ érdekesebb feladatokra

dr. Bach Iván előadásai és
Csima Judit gyakorlatai
alapján készítette:
Szabó Péter
<pts@inf.bme.hu>

2000. október 1–7.

Feladatok

1.** Adjunk CF nyelvtant az alábbi nyelvhez:

$\{x \in \{a, b\}^* \mid x \text{ nem } ww \text{ alakú}\}$

2.* Mutassuk meg, hogy minden DVA, ami elfogadja a $(a+b)^*a(a+b)^{n-1}$ nyelvet, legalább 2^n állapotú, noha nemdeterminisztikus véges automata már van $n+1$ állapottal is.

3.** Nyelvtan kell az $\{a^{F_n} \mid n \geq 1, F_n \text{ az } n\text{-edik Fibonacci szám}\}$ nyelvre. (Nem baj, ha 0-s lesz a nyelvtan.)

4.*** Nyelvtan kell az $\{a^p \mid p \text{ prím}\}$ nyelvre. (Itt se baj, ha 0-s lesz a nyelvtan, sőt már az is jó, ha nagyjából el tudod mesélni, hogy hogyan működjön, nem kell rögtön szabályokra lebontva leírni.)

5.1.** Reguláris-e $L_1 = \{xx^Rw \mid x \in \{0, 1\}^+, w \in \{0, 1\}^*\}$?

5.2. Reguláris-e $L_2 = \{xwx^R \mid x \in \{0, 1\}^+, w \in \{0, 1\}^*\}$?

6.1. Reguláris-e $L_1 = \{0^i1^j \mid \text{luko}(i, j) \neq 1\}$?

6.2.* Reguláris-e $L_2 = \{0^{F_n} \mid n \geq 1, F_n \text{ az } n\text{-edik Fibonacci szám}\}$?

7.** Tegyük fel, hogy az L_1 nyelv reguláris, az L_2 nyelv pedig nem reguláris. Igazoljuk, hogy ekkor L_1L_2 sem reguláris!

8.** Legyen L egy reguláris nyelv a Σ ábécé felett. $\frac{1}{2}L := \{x \in \Sigma^* \mid \exists y \in \Sigma^* : |y| = |x|, xy \in L\}$. Azaz $\frac{1}{2}L$ -ben az L -beli szavak első felei vannak. Reguláris-e az $\frac{1}{2}L$ nyelv?

9.**** Bizonyítsd, hogy ha $L \subseteq 0^*$ és L CF nyelv, akkor L reguláris!

Megoldások

1.** Adjunk CF nyelvtant az alábbi nyelvhez:

$\{x \in \{a, b\}^* \mid x \text{ nem } ww \text{ alakú}\}$

$S \rightarrow AB \mid BA \mid A \mid B, \quad A \rightarrow XAX \mid a, \quad B \rightarrow XBX \mid b, \quad X \rightarrow a, b.$

Ez a CF nyelvtan a páratlan hosszú $(A \mid B)$, az $(a+b)^i a (a+b)^{i+j} b (a+b)^j$, és az $(a+b)^i b (a+b)^{i+j} a (a+b)^j$ alakú szavakra illeszkedik, tehát pontosan a nem ww alakúakra.

2.* Mutassuk meg, hogy minden DVA, ami elfogadja a $(a+b)^* a (a+b)^{n-1}$ nyelvet, legalább 2^n állapotú, noha nemdeterminisztikus véges automata már van $n+1$ állapottal is.

A nemdet. automata nyelvtana: $S \rightarrow aS \mid bS \mid aA_1, A_i \rightarrow aA_{i+1} \mid bA_{i+1}$ ($i = 1 \dots n$), $A_n \rightarrow \varepsilon$. Ez $n+1$ állapotú.

Tekintsünk egy DVA-t, ami a nyelvet fogadja el, de $< 2^n$ állapota van. A skatulyaelv szerint a 2^n db $(a+b)^n$ alakú szó között van kettő (x és y), amely a DVA-t ugyanabba az állapotba viszi. x -nek és y -nak egyezzen meg az első i db betűje, de az $i+1$ -edik már különbözzön, mégpedig úgy, hogy x -ben ez a betű a , y -ban pedig b legyen!

Ekkor az xa^i és ya^i szavak a DVA-t ugyanabba az állapotba viszik. Másrészt viszont xa^i nincs benne a nyelvben (hátról az n -edik betűje a), noha ya^i benne van (hátról az n -edik betűje b). Ez ellentmondás, tehát eredeti feltevésünk hamis volt, így bármely, e nyelvet felismerő DVA $\geq 2^n$ állapotú.

3.** Nyelvtan kell az $\{a^{F_n} \mid n \geq 1, F_n \text{ az } n\text{-edik Fibonacci szám}\}$ nyelvre. (Nem baj, ha 0-s lesz a nyelvtan.)

| | | | | |
|------------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| $S \rightarrow a$ | $S \rightarrow aa$ | $S \rightarrow aaa$ | $S \rightarrow CABBD$ | $BD \rightarrow LE$ |
| $BL \rightarrow LB$ | $AL \rightarrow AAM$ | $MB \rightarrow BM$ | $BME \rightarrow LAE$ | $BMA \rightarrow LAA$ |
| $AMA \rightarrow ONAA$ | $AON \rightarrow OPB$ | $PBA \rightarrow APB$ | $PBE \rightarrow NBE$ | $PBB \rightarrow NBB$ |
| $AN \rightarrow NA$ | $CON \rightarrow CQQ$ | $QQA \rightarrow AQQ$ | $QQB \rightarrow BQQ$ | $QQE \rightarrow BBD$ |
| $CA \rightarrow aR$ | $RA \rightarrow aR$ | $RB \rightarrow aR$ | $RD \rightarrow a0$ | |

Ez egy nemcsökkentő, tehát CS nyelvtan. F_n -t $CA^{F_n-2-1}B^{F_n-1-1}D$ alakban ábrázoljuk. A rekurziós képlet szerint a B-ket az A-hoz adva először $CA^{F_n-3}ONA^{F_n-1-1}D$ -t, majd ebből mozgatóssal $CA^{F_n-1-1}A^{F_n-1}D$ -et vezetjük le, ami épp F_{n+1} -et adja. Illusztrációul bemutatjuk $F_6 = 8$ levezetését:

$S \Rightarrow CABBD (2+3) \Rightarrow CABLE (-) \Rightarrow CALBE \Rightarrow CAAMBE \Rightarrow CABME \Rightarrow CAALAE \Rightarrow CAAAMAE \Rightarrow CAAONAAE (5+3) \Rightarrow CAOPBAE \Rightarrow CAOAPBAE \Rightarrow CAOAPBE \Rightarrow CAOANBE \Rightarrow CAOANABE \Rightarrow CAOANABE \Rightarrow COPBAABE \Rightarrow COAPBABE \Rightarrow COAAPBBE \Rightarrow COAANBBE \Rightarrow COANABBE \Rightarrow CONAABBE \Rightarrow CQQAABBE \Rightarrow CAQQABBE \Rightarrow CAQQBBE \Rightarrow CAABQQBE \Rightarrow CAABBQQE \Rightarrow CAABBBBD \Rightarrow 0RABBBBD \Rightarrow 00RBBBBD \Rightarrow^4 000000RD \Rightarrow 00000000 (8).$

4.* Nyelvtan kell az $\{a^p \mid p \text{ prím}\}$ nyelvre. (Itt se baj, ha 0-s lesz a nyelvtan, sőt már az is jó, ha nagyjából el tudod mesélni, hogy hogyan működjön, nem kell rögtön szabályokra lebontva leírni.)**

CS nyelvtant adunk, de csak „nagyjából”. Először generálunk egy akár-mekkora számot, és – a nála kisebb számokkal vett osztási maradék alapján – ellenőrizzük, hogy prím-e. Csak akkor érhet véget a levezetés, ha a szám prím. Az n számot $KA^{d-1}B^{dk-d}C^{n-dk-1}V$ alakban ábrázoljuk, melynek hossza n . Az első d írásjel az aktuális osztót jelöli (kezdetben $d = 2$, végül pedig $d = n - 1$), az első dk írásjel pedig az osztó többszöröse, melyet n -ből már levontunk annak érdekében, hogy meghatározzuk n maradékát modulo d (kezdetben $k = 1$).

A nyelvtan úgy működik, hogy d db C jelet B-re cserélünk (a szó elején levő K-ból és minden A-ból egy-egy cserejelet „indítunk el”, ami C-hez érve azt B-re cseréli). Ha mind a d -t le tudtuk cserélni, akkor újabb d -s cserének futunk neki. Ha csak $d - 1$ -et tudunk cserélni (mert a d -edik jel V), akkor $d \mid n$, n összetett, a levezetés akadjon el. Ha ennél is kevesebbet tudunk cserélni, akkor $d \nmid n$; a B-ket visszairjuk C-be, majd eggyel hosszabb d -vel próbálkozunk újra. Amint az A-k elérik V-t, már biztosak lehetünk benne, hogy a szám prím, tehát minden jelet 0-ra cserélünk.

A nyelvtan CS lesz, mivel a kezdeti (hossznövelő) generálás után már nem változik a mondatszerű forma hossza. A nyelvtan eleje: $S \rightarrow 00$, $S \rightarrow KAG$, $G \rightarrow W$, $G \rightarrow CW$, majd az „osztópróbáló” szabályok jönnek (hasonlóan az előző feladathoz), s végül $AV \rightarrow H0$, $AH \rightarrow H0$, $KH \rightarrow 00$.

$n = 11$ -re a főbb állomások: $S \Rightarrow^* KAG \Rightarrow^* KACCCCCCG \Rightarrow^* KAACCCCCCV \Rightarrow^* KAABBBCCCV \Rightarrow^* KAABBBBBBCV \Rightarrow^* KAAACCCCCV \Rightarrow^* KAAABBBCCV \Rightarrow^* KAAAACCCCV \Rightarrow^* KAAAABBBBV \Rightarrow^* KAAAAACCCV \Rightarrow^* KAAAAAAAV \Rightarrow^* KAAAAAAAH0 \Rightarrow^* 0000000000$.

5.1. Reguláris-e $L_1 = \{xx^Rw \mid x \in \{0, 1\}^+, w \in \{0, 1\}^*\}$?**

(Szerintem ez volt a **-os.) Tegyük fel, hogy L_1 reguláris. Tekintsük a $(01)^n$ szót, és hosszabbítsuk meg egy tetszőleges olyan u szóval, hogy az eredmény benne legyen L_1 -ben (pl. $u = (10)^n$ megfelel).

(1) $xx^Rw = (01)^nu$. $|x| \geq |2n|$, mert ellenkező esetben x utolsó és x^R első betűje (a két betű ugyanaz!) is $(01)^n$ -ben követné egymást, ami ellentmond annak, hogy $(01)^n$ -ben nincs betűismétlődés. $|x| \geq 2n$ miatt viszont $|u| > |w|$, tehát u előáll $u = vw$ alakban. Ezt (1)-be írva: $xx^Rw = (01)^nvw$, tehát $xx^R = (01)^nv$. $4n \leq 2|x| = 2n + |v|$, tehát $|u| \geq |v| \geq 2n$, tehát egy $(01)^n$ alakú szót $\geq 2n$ betűvel kell kiegészítenünk, hogy L_1 minimálautomatája elfogadja. Ez azt jelenti, hogy az az állapot, ahová az automata $(01)^n$ hatására kerül, $\geq 2n$ távolságra van a legközelebbi elfogadó állapottól, tehát az automata $\geq 2n + 1$ állapotú. n -et az automata állapotszámánál nagyobb-

nak választva ellentmondást kapunk, tehát az eredeti feltevésünk hamis volt. L_1 **nem reguláris**.

5.2. Reguláris-e $L_2 = \{xwx^R \mid x \in \{0, 1\}^+, w \in \{0, 1\}^*\}$?

Vegyük észre, hogy L_2 -be pontosan a ≥ 2 hosszú, azonos kezdő- és záróbetűvel rendelkező szavak tartoznak. (Valóban: az ilyen szavak L_2 -beliek, ha x -et a kezdőbetűnek választjuk; és az L_2 -beli szavak ilyenek.) Tehát L_2 -t generálja a következő reguláris nyelvtan: $S \rightarrow aA|bB$, $A \rightarrow aA|bA|a$, $B \rightarrow aB|bB|b$. Tehát L_2 **reguláris**.

6.1. Reguláris-e $L_1 = \{0^i 1^j \mid \text{luko}(i, j) \neq 1\}$?

Pumpálási lemmával bizonyítjuk, hogy L_1 nem reguláris. Ha ugyanis az volna, akkor vegyünk egy „éleg nagy” p prímet, $i := p$, $j := p$, és pumpáljuk 0^{p-1} -et. Ez azt jelenti, hogy $\exists m < p: 0^{p+m} 1^p \in L_1$, tehát $1 \neq \text{luko}(p, p+m) = \text{luko}(p, m) = 1$, ami ellentmondás. Tehát L_1 **nem reguláris**.

6.2.* Reguláris-e $L_2 = \{0^{F_n} \mid n \geq 1, F_n \text{ az } n\text{-edik Fibonacci szám}\}$?

Pumpálási lemmával bizonyítjuk, hogy L_2 nem reguláris. Ha ugyanis az volna, akkor vegyünk egy „éleg nagy” i -t, és pumpáljuk 0^{F_i} -t. Ez azt jelenti, hogy $\exists m < F_i: \forall k \ 0^{F_i+mk} \in L_2$, tehát $F_i + mk$ Fibonacci-szám. F_n különbségsorozata F_{n-2} , és $F_{n-2} \rightarrow \infty$, tehát két szomszédos Fibonacci-szám különbsége előbb-utóbb $> m$, noha mi végtelen sok m különbségű Fibonacci-számpárt találtunk. Ez ellentmondás, tehát L_2 **nem reguláris**.

7.** Tegyük fel, hogy az L_1 nyelv reguláris, az L_2 nyelv pedig nem reguláris. Igazoljuk, hogy ekkor $L_1 L_2$ sem reguláris!

Az állítás nem igaz, vagyis tudunk mutatni olyan L_1 reguláris és L_2 nem reguláris nyelvet, hogy $L_1 L_2$ reguláris legyen. Pl. $L_1 := \{a^n \mid n \geq 0 \text{ egész}\}$, $L_2 := \{a^f \mid f \geq 1 \text{ Fibonacci-szám}\}$, $L_1 L_2 = \{a^n \mid n \geq 1 \text{ egész}\}$. L_1 és $L_1 L_2$ közismerten reguláris, L_2 -ről pedig 6.2-ben megmutattuk, hogy nem reguláris.

Megjegyzés: Ha a feladat szövege $L_1 L_2$ helyett $L_1 \cup L_2$ -et kérné, az előző bekezdés ellenpéldája itt is ellenpélda lenne, míg ha $L_1 \cap L_2$ nemregularitását kéne bizonyítani, $L_1 := \{\varepsilon\}$, $L_2 := \{a^f \mid f \geq 1 \text{ Fibonacci-szám}\}$ lenne ellenpélda.

8.** Legyen L egy reguláris nyelv a Σ ábécé felett. $\frac{1}{2}L := \{x \in \Sigma^* \mid \exists y \in \Sigma^* : |y| = |x|, xy \in L\}$. Azaz $\frac{1}{2}L$ -ben az L -beli szavak első felei vannak. Reguláris-e az $\frac{1}{2}L$ nyelv?

Előbb a 9. feladat megoldását érdemes elolvasni, mert merítünk az ott leírtakból. Azt állítjuk, hogy $\frac{1}{2}L$ **reguláris**.

Tegyük fel, hogy az ábécé egyetlen betűből áll. Készítsük el L -hez a 9. feladatban leírt M automatát, amely véges sok kivételtől eltekintve a szóhossz valamely m számmal vett osztási maradékából állapítja meg, hogy a szó L -beli-e. Az m -mel való osztási maradék azonban (véges sok kivételtől eltekintve) azt is meghatározza, hogy a szó $\frac{1}{2}L$ -beli-e: pontosan akkor $\frac{1}{2}L$ -beli, ha a dupla akkora szóhossz L -ben megengedett maradékot ad. Ez alapján $\frac{1}{2}L$ -hez is készíthetünk egy $\frac{1}{2}M$ automatát, tehát $\frac{1}{2}L$ reguláris.

Mi legyen, ha az ábécében többféle betű is van? A betűket egyformának tekintve készítsük el $\frac{1}{2}M$ -et az előző bekezdésben leírt módon. Vegyük még M -et, L minimálautomatáját. M állapotszáma legyen n .

$\frac{1}{2}M$ minden egyes állapotát cseréljük le n db részállapotra, melyek M állapotainak felelnek meg. Egy részállapot akkor legyen elfogadó, ha M -ben is elfogadó volt, és az ő $\frac{1}{2}M$ -beli „gyűjtőállapota” is elfogadó. A nyilak a részállapotok között ugyanúgy fussanak, mint M -ben, de ne a gyűjtőállapoton belül, hanem mindig a következő gyűjtőállapot megfelelő részállapotába.

Ezzel elértük, hogy az új automata pont az $\frac{1}{2}L$ -ben megengedett hosszúságú szavakat fogadja el, és – mivel a részállapotok pont jól alakulnak egymásba – minden elfogadott szó egy L -beli szó előtagja lesz. Tehát az új automata pontosan $\frac{1}{2}L$ -t ismeri fel. Tehát $\frac{1}{2}L$ reguláris. Q.E.D.

9.**** Bizonyítsd, hogy ha $L \subseteq 0^*$ és L CF nyelv, akkor L reguláris!

Bevezetünk néhány elnevezést. *betű*: terminális szimbólum. *írásjel*: grammatikai szimbólum. *forma*: mondatszerű forma. *S*: a mondatszimbólum. *szó*: mondat. *kezdés*: S -ből induló, szabályszerű átalakítás. *befejezés*: szóra végződő, szabályszerű átalakítás. *levezetés*: kezdés és befejezés is egyben. egy *írásjel elérhető*: van levezetés, melyben szerepel. egy *írásjel befejezhető*: van olyan befejezés, ami vele kezdődik.

Írjuk át L CF nyelvtanát úgy, hogy továbbra is CF maradjon, de $J \rightarrow \varepsilon$ alakú szabály ne legyen benne, leszámítva esetleg $S \rightarrow \varepsilon$ -t. (Ezt tanultuk, hogyan kell.)

(Ez a bekezdés lényegében a CNF-fé alakítást írja le.) Mivel az elérhetetlen írásjelek nincsenek hatással a levezetésekre, tehát a nyelvre sem, hagyjuk el őket! Az elhagyás után már minden J írásjel elérhető, tehát minden J -hez létezik egy levezetés, melyben ő szerepel. Ezt a levezetést alakítsuk át J befejezésévé, mégpedig úgy, hogy a levezetésben J -t és „leszármazottait” aláhúzzuk, majd csak az aláhúzott formákat tekintjük; ezek sorozata épp J egy befejezését adja. Azt kaptuk, hogy minden írásjel befejezhető. Emiatt azonban minden forma befejezhető, pl. úgy, hogy sorra befejezzük az írásjeleket.

A bizonyítandó állítást először azokra a nyelvtanokra látjuk be, melyekben S -ből eljuthatunk S -et tartalmazó, ≥ 2 hosszú formához (f). Az ilyen nyelvtanokat nevezük *hízlalhatónak*. f írásjeleit (egyetlen S -t kivéve) fejezzük be az előző bekezdésben leírt módon. Ekkor egy olyan f' formához jutunk,

amely 1 db S -et, és $m \geq 1$ db 0 -t tartalmaz. Az így kapott $S \Rightarrow \dots \Rightarrow f'$ átalakítássorozatot nevezzük az L nyelv *hízalásának*.

Vegyük L -nek egy tetszőleges (0^k alakú) szavát, és tekintsük ennek a szó-
nak a levezetését. Ha a levezetést az első átalakítás helyett a hízalással kezd-
jük, majd az eredeti levezetést a hízalás eredményéül kapott f' -ben levő S -ből
indulva hajtjuk végre, akkor egy 0^{k+m} hosszú szót kapunk. Ezzel beláttuk,
hogy $(\forall k) 0^k \in L \implies 0^{k+m} \in L$.

Soroljuk L szavait a hosszuk alapján m szerinti maradékosztályokba. Bizo-
nyos maradékok végtelen sokszor fordulnak elő (K_∞), mások pedig csak véges
sokszor (K_f). Mivel K_f -et csak véges sok szó képviseli, ezért egy bizonyos
hossz felett már csak K_∞ -beli szavak lehetnek. Másrészt azonban minden
 K_∞ -beli maradék ≥ 1 -szer előfordul (valóban: hisz' végtelen sokszor elfor-
dul), és bármely L -beli szót m -mel hízalhatunk (lásd előző bekezdés), tehát
egy bizonyos hossz felett már minden K_∞ -beli szó L -beli. Összefoglalva: egy
bizonyos hossz felett pontosan a K_∞ -beli szavak lesznek az L -beliek. Másként
fogalmazva: véges sok kivételtől eltekintve a szóhossz m szerinti maradéka ha-
tározza meg, hogy a szó L -beli-e.

Ekkor viszont könnyedén készíthetünk L -hez reguláris nyelvtant. Csiná-
lunk egy m hosszú irányított kört, melyen pontosan az K_∞ elemeinek megfe-
lelő állapotok az elfogadóak. A véges sok kivételt pedig úgy valósítjuk meg,
hogy a kezdőállapotot egy elegendően hosszú irányított úttal csatlakoztatjuk
a körhöz. Az út elfogadó állapotait a véges sok kivétel figyelembevételével
jelöljük ki.

Az állítást már csak a nem hízalható nyelvtanokra kell belátnunk. Ezek-
ben S csak a levezetések elején fordulhat elő. Az írásjelek számára (k) vonat-
kozó teljes indukciót alkalmazunk. $k = 1$ esetén L csak véges sok szóból áll,
tehát L reguláris. Ha feltesszük, hogy $k < n$ -re már igaz, akkor $k = n$ -re a
követzőképpen érvelünk: Ha a mondatszimbólumnak S helyett egy másikat
(J_2, \dots, J_n) jelölünk ki, akkor S elérhetetlen, tehát S -et elhagyhatjuk a nyelv-
tanból. Az így kapott L_2, \dots, L_n nyelvtanok írásjeleinek száma $< n$, tehát L_i
vagy hízalható (tehát reguláris), vagy az indukciós feltevés miatt reguláris. L
viszont felépíthető az L_i -k konkaténációjából és úniojából az $S \rightarrow$ -sel kezdődő
levezetés szabályok szerint. Tehát L is reguláris. Q.E.D.

$S \rightarrow a$

$S \rightarrow aa$

$S \rightarrow aaa$

$S \rightarrow CABBD$

$BD \rightarrow LE$

$BL \rightarrow LB$

$AL \rightarrow AAM$

$MB \rightarrow BM$

$BME \rightarrow LAE$

$BMA \rightarrow LAA$

$AMA \rightarrow ONAA$

$AON \rightarrow OPB$

$PBA \rightarrow APB$

$PBE \rightarrow NBE$

$PBB \rightarrow NBB$

$AN \rightarrow NA$

$CON \rightarrow CQQ$

$QQA \rightarrow AQQ$

$QQB \rightarrow BQQ$

$QQE \rightarrow BBD$

$CA \rightarrow aR$

$RA \rightarrow aR$

$RB \rightarrow aR$

$RD \rightarrow a0$