

Formális nyelvek és fordítóprogramok

4. Véges automaták és reguláris nyelvek II.

Bodó Zalán


Babeş–Bolyai Tudományegyetem
Matematika és Informatika Kar
Magyar Matematika és Informatika Intézet



Tétel

A következő három nyelvosztály megegyezik:

- ▶ a reguláris nyelvek osztálya
- ▶ DVA által felismerhető nyelvek osztálya
- ▶ NDVA által felismerhető nyelvek osztálya



Már ismerjük: NDVA \rightarrow DVA

- ▶ ismétlés: $G = (N, T, P, S)$ reguláris nyelvtan:
 - ▶ P szabályai $A \rightarrow aB$ vagy $A \rightarrow a$ alakúak, ahol $a \in T$, $B \in N$
 - ▶ megengedhető az $S \rightarrow \epsilon$ szabály is, ha S nem szerepel egyetlen szabály jobb oldalán sem
 - ▶ $L(G) = \{w \in T \mid S \xrightarrow[G]{*} w\}$ a G grammatika által generált reguláris nyelv

Tétel

Ha L egy tetszőleges DVA által felismert nyelv, akkor megkonstruálható egy olyan reguláris nyelvtan, amelyik az L nyelvet generálja.

Az algoritmus lépései:

- ▶ $A = (Q, \Sigma, E, \{q_0\}, F)$, $L = L(A)$
- ▶ $G = (Q, \Sigma, P, q_0)$, vagyis a nemterminális szimbólumoknak az automata állapotait választjuk, a terminálisok az automata ábécéje lesz, a kezdőszimbólum pedig az automata kezdőállapota
- ▶ P :
 - ▶ ha $(p, a, q) \in E$, akkor felvesszük a $p \rightarrow aq$ szabályt
 - ▶ ha $(p, a, q) \in E$ és $q \in F$, akkor a fenti szabály mellett felvesszük a $p \rightarrow a$ szabályt is

Fontos: ha A felismeri ϵ -t is, akkor bevezetünk egy új q'_0 kezdőszimbólumot, felvesszük az új $q'_0 \rightarrow \epsilon$ szabályt, és minden $q_0 \rightarrow \alpha$ szabály mellé bevisszük a $q'_0 \rightarrow \alpha$ szabályt is

$$A = (Q, \Sigma, E, \{q_0\}, F) \rightarrow G = (Q, \Sigma, P, q_0)$$

ALG 1 DVA \rightarrow RG


```

1:  $P = \emptyset$ 
2: for minden  $(p, a, q) \in E$  do
3:    $P = P \cup \{p \rightarrow aq\}$ 
4:   if  $q \in F$  then
5:      $P = P \cup \{p \rightarrow a\}$ 
6:   end if
7: end for

```

+ megjegyzés

1. Példa



$G = (\{q_0, q_1, q_2, q_3\}, \{a, b\}, P, q_0)$

A szabályok: $P : \{$

$q_0 \rightarrow aq_1$

$q_1 \rightarrow aq_2 \mid bq_3 \mid b$

$q_2 \rightarrow aq_1 \mid bq_3 \mid b$

$\}$

Próba: $aaab: q_0 \Rightarrow aq_1 \Rightarrow aaq_2 \Rightarrow aaaq_1 \Rightarrow aaab$

RG \rightarrow NDVA

Tétel

Ha $L = L(G)$ reguláris nyelv, akkor megkonstruálható olyan NDVA, amely az L nyelvet ismeri fel.

Az algoritmus lépései:

- ▶ $G = (N, T, P, S)$
- ▶ $A = (Q, T, E, \{S\}, F)$, vagyis az automata ábécéje a terminális szimbólumok halmazával fog megegyezni, a kezdőállapot pedig a grammatika kezdőszimbóluma lesz
- ▶ $Q = N \cup \{Z\}$, ahol Z egy új szimbólum/állapot
- ▶ minden $A \rightarrow aB$ szabályra felvesszük az (A, a, B) átmenetet
- ▶ minden $A \rightarrow a$ szabályra felvesszük az (A, a, Z) átmenetet
- ▶ $F = \begin{cases} \{Z\}, & \text{ha } G\text{-ben nincs } S \rightarrow \epsilon \text{ szabály} \\ \{Z, S\}, & \text{ha } G\text{-ben van } S \rightarrow \epsilon \text{ szabály} \end{cases}$

$$G = (N, T, P, S) \rightarrow A = (Q, T, E, \{S\}, F)$$

ALG 2 RG \rightarrow NDVA

```

1:  $E = \emptyset$ 
2:  $Q = N \cup \{Z\}$ 
3: for minden  $A \rightarrow u$  szabályra do
4:   if  $u = aB$  then
5:      $E = E \cup \{(A, a, B)\}$ 
6:   end if
7:   if  $u = a$  then
8:      $E = E \cup \{(A, a, Z)\}$ 
9:   end if
10: end for
11: if  $(S \rightarrow \epsilon) \in P$  then
12:    $F = \{Z\}$ 
13: else
14:    $F = \{Z, S\}$ 
15: end if

```

2. Példa

Legyen a köv. G reg. grammatika (szabályhalmaza):

$$S \rightarrow a|aA|\varepsilon$$

$$A \rightarrow aB$$


$$B \rightarrow aB|b$$

$(L(G) = \{a^n x \mid n \geq 0, x = \varepsilon \text{ ha } n \in \{0, 1\}, \text{ ellenkező esetben } x = b\})$

Az átmenettáblázat:

	a	b
S	$\{A, Z\}$	\emptyset
A	$\{B\}$	\emptyset
B	$\{B\}$	$\{Z\}$
Z	\emptyset	\emptyset

Az automata:



Reguláris nyelvek – kiegészítés

Ha L_1, L_2 reg. nyelvek, akkor regulárisak a köv. is:

- ▶ $L_1 \cup L_2$
- ▶ L_1L_2, L_2L_1
- ▶ L_1^*, L_2^*

Ezen kívül regulárisak köv. konstrukciók is:

- ▶ $\overline{L_1}, \overline{L_2}$

Biz. Legyen $A = (Q, \Sigma, E, \{q_0\}, F)$ az L_1 -et felismerő *teljes determinisztikus* automata. Ekkor $\overline{A} = (Q, \Sigma, E, \{q_0\}, Q \setminus F)$ az $\overline{L_1}$ -et fogja felismerni; tehát a grammatika (melyet könnyen megszerkeszthetünk) reguláris lesz

- ▶ $L_1 \cap L_2$

Biz. $L_1 \cap L_2 = \overline{\overline{L_1} \cup \overline{L_2}}$

- ▶ $L_1 \setminus L_2, L_2 \setminus L_1$

Biz. $L_1 \setminus L_2 = L_1 \cap \overline{L_2}$

ϵ -lépéses automaták

- ▶ ϵ -lépés: az automata nem olvas semmit a bemeneti szalagról, de átmegy egy állapottól a másikba
- ▶ $E \subseteq Q \times (\Sigma \cup \{\epsilon\}) \times Q$
- ▶ $\delta : Q \times (\Sigma \cup \{\epsilon\}) \rightarrow \mathcal{P}(Q)$, $\delta(p, a) = \{q \in Q \mid (p, a, q) \in E\}$


Tétel

Tetszőleges ϵ -lépéses véges automatához mindig megkonstruálható egy vele ekvivalens NDVA, amely nem tartalmaz ϵ -lépéseket.


- ▶ ϵ -lépéses automata: $A = (Q, \Sigma, E, I, F)$
- ▶ NDVA: $\bar{A} = (Q, \Sigma, \bar{E}, I, \bar{F})$ (az algoritmus az \bar{E} és \bar{F} halmazokat határozza meg)
- ▶ **Def.:** $\Lambda(q) =$ azon állapotok halmaza, amelyekbe el lehet jutni q -ból csupa ϵ -lépéssel (beleértve magát a q -t is).
Halmaz esetén:

$$\Lambda(S) = \bigcup_{q \in S} \Lambda(q), \forall S \subseteq Q$$

Példa ε -lépéses véges automatára:



Az algoritmus alapötletének grafikus ábrázolása:



ALG 3 ϵ -mentesítés

1: $\bar{F} = F \cup \{q \in I \mid \Lambda(q) \cap F \neq \emptyset\}$

2: **for** minden $q \in Q$ **do**

3: **for** minden $a \in \Sigma$ **do**

4: $\Delta = \bigcup_{p \in \Lambda(q)} \delta(p, a)$


5: $\bar{\delta}(q, a) = \Delta \cup \left(\bigcup_{p \in \Delta} \Lambda(p) \right)$

6: **end for**

7: **end for**


8: $\bar{E} = \{(p, a, q) \mid p, q \in Q, a \in \Sigma, q \in \bar{\delta}(p, a)\}$

3. Példa



$$\Lambda(q_0) = \{q_0, q_1, q_2\}, \Lambda(q_1) = \{q_1, q_2\}, \Lambda(q_2) = \{q_2\}$$
$$\bar{F} = \{q_2\} \cup \{q_0\} = \{q_0, q_2\}$$

$\bar{\delta}$	0	1
q_0	$\{q_1, q_2\}$	$\{q_0, q_1, q_2\}$
q_1	$\{q_1, q_2\}$	$\{q_2\}$
q_2	\emptyset	$\{q_2\}$



Műveletek véges automatákkal

$A_1 = (Q_1, \Sigma_1, E_1, I_1, F_1)$, $A_2 = (Q_2, \Sigma_2, E_2, I_2, F_2) \Rightarrow$
 $A = (Q, \Sigma, E, I, F)$ (ϵ -lépéses) véges automata

1. Egyesítés: $A = A_1 \cup A_2$

$$Q = Q_1 \cup Q_2 \cup \{q_0\}$$

$$\Sigma = \Sigma_1 \cup \Sigma_2$$

$$I = \{q_0\}$$

$$F = F_1 \cup F_2$$

$$E = E_1 \cup E_2 \cup \bigcup_{q \in I_1 \cup I_2} \{(q_0, \epsilon, q)\}$$

2. Szorzat: $A = A_1 \cdot A_2$

$$Q = Q_1 \cup Q_2$$

$$\Sigma = \Sigma_1 \cup \Sigma_2$$

$$F = F_2$$

$$I = I_1$$

$$E = E_1 \cup E_2 \cup \bigcup_{p \in F_1, q \in I_2} \{(p, \epsilon, q)\}$$

3. Iteráció: A_1^*

$$Q = Q_1$$

$$\Sigma = \Sigma_1$$

$$F = F_1$$

$$I = I_1$$

$$E = E_1 \cup \bigcup_{p \in I_1, q \in F_1} \{(p, \epsilon, q), (q, \epsilon, p)\}$$

DVA minimalizálása

Def. Minimális automata

Egy $A = (Q, \Sigma, E, \{q_0\}, F)$ teljes DVA-t minimálisnak nevezünk, ha bármely vele ekvivalens $A' = (Q', \Sigma, E', \{q'_0\}, F')$ teljes DVA esetében teljesül, hogy $|Q| \leq |Q'|$.

Def. Ekvivalens állapotok

Az $A = (Q, \Sigma, E, \{q_0\}, F)$ DVA p és q állapotát ekvivalensnek nevezzük, ha minden w szóra mindkettőből végállapotba jutunk vagy egyikből sem, vagyis

$$p \equiv q, \text{ ha minden } w \in \Sigma^* : \begin{cases} p \xrightarrow{w} r, r \in F \text{ és } q \xrightarrow{w} s, s \in F \text{ VAGY} \\ p \xrightarrow{w} r, r \notin F \text{ és } q \xrightarrow{w} s, s \notin F \end{cases}$$


Az algoritmus alapötlete:

- ▶ meghatározzunk az ekvivalens állapotpárokat
- ▶ az ekvivalenseket összevonjuk
- ▶ (az elérhetetlen állapotokat első lépésben kizárjuk – ezek nem játszanak szerepet az algoritmusban; a nem produktívakat hagyjuk – ezekre szükség lehet a teljességhez)

ALG 4

- 1: Jelöljük meg csillaggal (*) az összes (p, q) állapotpárt, amelyre $p \in F$ és $q \notin F$ vagy fordítva
 - 2: Minden jelöletlen (p, q) párhoz rendeljünk egy üres listát
 - 3: **for** Minden jelöletlen (p, q) párra és minden $a \in \Sigma$ betűre vizsgáljuk meg a $(\delta(p, a), \delta(q, a))$ állapotpárokat **do**
 - 4: **if** az így kapott párok közül valamelyik meg van csillagozva **then**
 - 5: csillagozzuk meg a (p, q) párt is, a már előzőleg ehhez a párhoz rendelt lista elemeivel együtt
 - 6: **else if** a fenti állapotpárok közül egy sincs megcsillagozva **then**
 - 7: írjuk be a (p, q) párt a $(\delta(p, a), \delta(q, a))$ párokhoz rendelt lista mindegyikébe, feltéve, hogy $\delta(p, a) \neq \delta(q, a)$
 - 8: **end if**
 - 9: **end for**
 - 10: Vonjuk össze a jelöletlen (ekvivalens) állapotpárokat.
-

4. Példa



$$(q_0, q_1)^* \xrightarrow{a} (q_1, q_2) \xrightarrow{a} (q_2, q_1) \xrightarrow{a} (q_1, q_2) \text{ (kör)}$$

$$\xrightarrow{b} (q_3, q_3)$$

$$\xrightarrow{b} (q_3, q_3)$$


$$(q_0, q_2)^* \xrightarrow{a} (q_1, q_1)$$

$$\xrightarrow{b} (q_4, q_3)^*$$


$$(q_0, q_4)^* \xrightarrow{a} (q_1, q_4)^* \xrightarrow{a} (q_2, q_4)^* \xrightarrow{a} (q_1, q_4) \text{ (kör)}$$

$$\xrightarrow{b} (q_3, q_4)^*$$

Az eredő táblázat (könnyen leolvasható, mit kell/lehet összevonni):



A minimalizált automata:




Lemma (Bar-Hillel)

Bármely L reguláris nyelv esetében létezik olyan $n \geq 1$ természetes szám (amely csak L -től függ), hogy L bármely legalább n hosszúságú u szava felírható $u = xyz$ alakban úgy, hogy

1. $|xy| \leq n$,
2. $|y| \geq 1$,
3. $xy^iz \in L$, minden $i = 0, 1, 2, \dots$ értékre.

A fenti lemmát arra használjuk, hogy bebizonyítsuk egy nyelvről, hogy az nem reguláris.

Yehoshua Bar-Hillel



Yehoshua Bar-Hillel (születési nevén Oscar Westreich, 1915 Bécs–1975 Jeruzsálem) izraeli filozófus, matematikus és nyelvész. A gépi fordítás mint tudományág megteremtője, ő szervezte az első ilyen konferenciát is 1952-ben. Az információ-visszakeresés egyik úttörőjének is tartják.

Egy híres műve:

Bar-Hillel J. *Language and Information. Selected Essays on Their Theory and Application*. Addison-Wesley, Reading, MA, 1964.

5. Példa

Mutassuk meg, hogy az $L = \{a^k b^k \mid k \geq 1\}$ nyelv nem reguláris.

Tegyük fel, hogy L reguláris, és válasszuk a pumpáló lemmában szereplő számot n -nek. Ekkor $|a^n b^n| = 2n > n$, tehát válasszuk az $u = a^n b^n$ szót. Ekkor u felbontható xyz alakban. A lemma 1. és 2. követelményének eleget téve az $u = a^n b^n$ szót a következőképpen bonthatjuk fel:

$$\begin{array}{ccc} x & y & z \\ a^\ell & a^m & a^{n-\ell-m} b^n \end{array}$$

ahol a következő feltételeknek kell teljesülniük: $\ell + m \leq n$, $m \geq 1$ és $\ell \geq 0$.

A 3. pont feltételeit nem tudjuk minden esetben kielégíteni, mivel $xy^i z = a^\ell a^{m \cdot i} a^{n-\ell-m} b^n$ alakú, ami az egyszerűsítések után $a^{n+m(i-1)} b^n$ lesz. Ha i -t pl. 2-nek választjuk, az $a^{n+m} b^n$ szóhoz jutunk, és mivel $m \geq 1$, nem lesz egyenlő számú a és b szimbólumunk.

Ellentmondáshoz jutottunk, tehát a feltevésünk, hogy L reguláris, hamis.