

Formális nyelvek I.

Véges automaták és reguláris nyelvek

Fülöp Zoltán

SZTE TTIK Informatikai Intézet
Számítástudomány Alapjai Tanszék
6720 Szeged, Árpád tér 2.

1/141

A formális nyelvek egy alkalmazása

Egy (programozási) nyelv szintaxisa: azon szabályok összessége, amelyek meghatározzák a nyelvet.

Hogyan, milyen módszerrel adható meg a programozási nyelvek szintaxisa?

A legelterjedtebb módszer a *generatív nyelvtannal* történő szintaxis megadás.

Adjuk meg az A , B és C változókból, a 0 és 1 konstansokból, a $+$ és a $*$ műveleti jelekből, valamint a $($ és $)$ zárójelekből felépíthető aritmetikai kifejezések szintaxisát!

Ilyenek például az A , 1 , $A + 1$, $A + B$, $A * (B + 1)$ aritmetikai kifejezések. Az összes ilyen kifejezés egy nyelvet alkot.

3/141

Irodalom

- Fülöp Zoltán, Formális nyelvek és szintaktikus elemzésük, Polygon, 2004.
- Ésik Zoltán, Gombás Éva és Iván Szabolcs: Automaták és formális nyelvek példatár, Typotex Kiadó, 2011.
- J. E. Hopcroft és R. Motwani, J. D. Ullman, Introduction to Automata Theory, Languages, and Computation, Addison Wesley, 2001 és Pearson Education Limited 2014. (A biblia.)
- Peter Linz, An Introduction to Formal Languages and Automata, Jones & Barlett Learning, 2012.

Ajánlott az előadások látogatása és a jegyzetelés! A vizsgán az előadáson elhangzottakat is tudni kell.

2/141

A formális nyelvek egy alkalmazása

Aritmetikai kifejezések

Aritmetikai kifejezéseknek az A , B és C változó jelekből, a 0 és 1 konstans jelekből, a $+$ és $*$ műveleti jelekből, valamint a $($ és $)$ csoportosító jelekből, a

$$\begin{aligned}\langle kif \rangle &\rightarrow \langle tag \rangle | \langle kif \rangle + \langle tag \rangle \\ \langle tag \rangle &\rightarrow \langle fakt \rangle | \langle tag \rangle * \langle fakt \rangle \\ \langle fakt \rangle &\rightarrow (\langle kif \rangle) | \langle valt \rangle | \langle konst \rangle \\ \langle valt \rangle &\rightarrow A | B | C \\ \langle konst \rangle &\rightarrow 0 | 1\end{aligned}$$

szabályok alkalmazásával felépíthető jelsorozatok (szavakat) nevezzük. A $|$ jel választási lehetőséget jelent, olvassuk "vagy"-nak. Ez egy *generatív nyelvtan*.

4/141

A formális nyelvek egy alkalmazása

Levezetés:

$\langle kif \rangle$
 $\Rightarrow \langle tag \rangle$
 $\Rightarrow \langle tag \rangle * \langle fakt \rangle$
 $\Rightarrow \langle tag \rangle * (\langle kif \rangle)$
 $\Rightarrow \langle tag \rangle * (\langle kif \rangle + \langle tag \rangle)$
 $\Rightarrow \langle tag \rangle * (\langle tag \rangle + \langle tag \rangle)$
 $\Rightarrow \langle fakt \rangle * (\langle tag \rangle + \langle tag \rangle)$
 $\Rightarrow \langle fakt \rangle * (\langle fakt \rangle + \langle tag \rangle)$
 $\Rightarrow \langle fakt \rangle * (\langle fakt \rangle + \langle fakt \rangle)$

Minden lépésben az aláhúzott szintaktikai egységet helyettesítjük a megfelelő szabály jobb oldalán álló valamelyik kifejezéssel.

5/141

A formális nyelvek egy alkalmazása

Az $A, B, C, 0, 1, +, *, ($ és $)$ jelekből álló aritmetikai kifejezés szintaxisa:

egy jelsorozat (vagy szó) akkor és csak akkor aritmetikai kifejezés, ha a $\langle kif \rangle$ -ből a fenti szintaktikai szabályok alkalmazásával történő levezetéssel megkapható.

Röviden:

w szó aritmetikai kifejezés $\iff \langle kif \rangle \Rightarrow^* w$.

7/141

A formális nyelvek egy alkalmazása

Levezetés:

$\Rightarrow \langle fakt \rangle * (\langle fakt \rangle + \langle fakt \rangle)$
 $\Rightarrow \langle valt \rangle * (\langle fakt \rangle + \langle fakt \rangle)$
 $\Rightarrow \langle valt \rangle * (\langle valt \rangle + \langle fakt \rangle)$
 $\Rightarrow \langle valt \rangle * (\langle valt \rangle + \langle konst \rangle)$
 $\Rightarrow A * (\langle valt \rangle + \langle konst \rangle)$
 $\Rightarrow A * (B + \langle konst \rangle)$
 $\Rightarrow A * (B + 1)$

Jelölés: $\langle kif \rangle \Rightarrow^* A * (B + 1)$

6/141

A formális nyelvek egy alkalmazása

Egy másik példa: a FONYA programozási nyelv szintaxisa:

$\langle program \rangle \rightarrow \langle ut.lista \rangle.$
 $\langle ut.lista \rangle \rightarrow \langle ut \rangle | \langle ut \rangle ; \langle ut.lista \rangle$
 $\langle ut \rangle \rightarrow \langle ert.ado \rangle | \langle ifut \rangle |$
 $\quad \langle whileut \rangle | \langle blokk \rangle$
 $\langle ert.ado \rangle \rightarrow \langle valt \rangle := \langle kif \rangle$
 $\langle ifut \rangle \rightarrow \mathbf{if} \langle relacio \rangle \mathbf{then} \langle ut \rangle \mathbf{else} \langle ut \rangle$
 $\langle whileut \rangle \rightarrow \mathbf{while} \langle relacio \rangle \mathbf{do} \langle ut \rangle$
 $\langle blokk \rangle \rightarrow \mathbf{begin} \langle ut.lista \rangle \mathbf{end}$
 $\langle relacio \rangle \rightarrow \langle kif \rangle \langle relaciojel \rangle \langle kif \rangle$
 $\langle relaciojel \rangle \rightarrow < | > | = | \neq$

8/141

A formális nyelvek egy alkalmazása

Egy másik példa: a FONYA programozási nyelv szintaxisa:

$\langle kif \rangle \rightarrow \langle tag \rangle | \langle kif \rangle + \langle tag \rangle$
 $\langle tag \rangle \rightarrow \langle fakt \rangle | \langle tag \rangle * \langle fakt \rangle$
 $\langle fakt \rangle \rightarrow (\langle kif \rangle) | \langle valt \rangle | \langle konst \rangle$
 $\langle valt \rangle \rightarrow A | B | C$
 $\langle konst \rangle \rightarrow 0 | 1$

A formális nyelvek egy alkalmazása

Egy w jelsorozat akkor és csak akkor szintaktikusan helyes FONYA nyelvű program, ha $\langle program \rangle \Rightarrow^* w$.

Ilyen például a bal oldali jelsorozat és nem ilyen a jobb oldali:

$A := 0;$	$A := 0;$
while $A < C$ do	while $A + C$ do
begin $A := A + 1;$	begin $A := A + 1$
$B := B * C$	$B := B * C$
end;	end;
$C := C * B.$	$C := C * B.$

A jobb oldaliban két szintaktikus hiba van!

9/141

10/141

A formális nyelvek egy alkalmazása

Az elemzés alapkérdése:

Amennyiben adott egy programozási nyelv szintaxisa és adott egy – ezen a nyelven írott – program, akkor hogyan tudjuk eldönteni azt, hogy az adott program engedelmeskedik-e a szintaxisnak, vagyis szintaktikusan helyes-e?

Röviden: igaz-e, hogy $\langle program \rangle \Rightarrow^* w$?

Több algoritmus is létezik, lásd a "Szintaktikus elemzési módszerek" c. kurzus anyagát.

Általános fogalmak, jelölések

Ábécé: szimbólumoknak egy tetszőleges véges, nemüres halmaza. Általában Σ -val jelöljük.

Σ **ábécé feletti szó:** egy $a_1 \dots a_k$ alakú sorozat, ahol $k \geq 0$ és $a_1, \dots, a_k \in \Sigma$.

$k = 0$ eset: **üres szónak** nevezzük, jele ε .

Példa ábécére és szavakra: $\Sigma = \{a, b\}$, $\varepsilon, a, b, aba, aababba$, stb.

Programozásban: ASCII, Unicode ábécék, BEGIN, END, IF, ALMA, K1, további kulcsszavak, azonosítók, 123, -412.2, K1+123, egyéb számok, kifejezések stb pedig szavak.

11/141

12/141

Általános fogalmak, jelölések

Összes szavak halmaza:

$$\Sigma^* = \{a_1 \dots a_k \mid k \geq 0, a_1, \dots, a_k \in \Sigma\}$$

$$\Sigma^+ = \{a_1 \dots a_k \mid k \geq 1, a_1, \dots, a_k \in \Sigma\} = \Sigma^* - \{\varepsilon\}$$

Példa: $\Sigma^* = \{\varepsilon, a, b, aa, ab, ba, bb, aaa, \dots\}$,

$\Sigma^+ = \{a, b, aa, ab, ba, bb, aaa, \dots\}$

Konkatenáció: az $u, v \in \Sigma^*$ szavak egymás után írásával kapott $uv \in \Sigma^*$ szó.

Példa: ha $u = abb$, $v = ba$, akkor $uv = abbba$, $u\varepsilon = \varepsilon u = u$.

A konkatenáció asszociatív: $u(vw) = (uv)w$ minden

$u, v, w \in \Sigma^*$ -ra

Hatványozás: $u^n = \overbrace{uu \dots u}^n$, $u^0 = \varepsilon$, $u = abb$ -re $u^3 = abbabbabb$.

13/141

Általános fogalmak, jelölések

Nyelv: Σ^* tetszőleges részhalmazát Σ feletti nyelvnek nevezzük.

Példa $\{a, b\}$ feletti nyelvekre:

- ▶ $\{aa, bab, abba\}$ (véges nyelv),
- ▶ $\{w \in \Sigma^* \mid |w| \text{ páros}\}$,
- ▶ $\{\varepsilon, ab, aabb, aaabbb, \dots\} = \{a^n b^n \mid n \geq 0\}$.

A már ismert aritmetikai kifejezések halmaza egy nyelv az $\{A, B, C, 0, 1, +, *, (\,)\}$ ábécé felett.

Az összes Σ feletti nyelvek halmaza: $\mathcal{P}(\Sigma^*)$ (kontinuum számosságú).

15/141

Általános fogalmak, jelölések

Ha $w = xy$, akkor x a w prefixe, y a w suffixe.

Példa: abb prefixei ε, a, ab, abb , suffixei abb, bb, b, ε

Egy w szó hosszán a benne előforduló betűk multiplicitással vett számát értjük. A jele $|w|$, a pontos definíció a következő:

(i) ha $w = \varepsilon$, akkor $|w| = 0$,

(ii) ha $w = av$, valamely $a \in \Sigma$ és $v \in \Sigma^*$ -ra, akkor $|w| = 1 + |v|$.

Példa: $|\varepsilon| = 0$, $|a| = 1$, $|ab| = 2$, $|abb| = 3$.

14/141

Műveletek nyelvekkel

Legyenek $L, L_1, L_2 \subseteq \Sigma^*$ nyelvek. Az

$$L_1 \cup L_2, L_1 \cap L_2 \text{ és } L_1 - L_2$$

az ismert halmazelméleti műveletek. Továbbá

- ▶ $\bar{L} = \Sigma^* - L$ az L komplementere,
- ▶ $L_1 L_2 = \{uv \mid u \in L_1, v \in L_2\}$ az L_1 és L_2 konkatenációja,

Minden lehetséges módon választunk L_1 -ből és L_2 -ből szavakat és "összeláncoljuk" (konkatenáljuk) őket:

$$\{\varepsilon, ab, bab\} \{b, ba\} = \{b, ba, abb, abba, babb, babba\}$$

$\Sigma^* \{aba\} = \{waba \mid w \in \Sigma^*\}$, az aba -ra végződő szavak halmaza.

16/141

Műveletek nyelvekkel

A nyelvek konkatenációja is asszociatív:

$$L_1(L_2L_3) = (L_1L_2)L_3,$$

ezért a zárójelezés elhagyható.

- ▶ *Hatványozás:* $L^n = \overbrace{LL\dots L}^n$, $L^0 = \{\varepsilon\}$
- ▶ $L^* = \{\varepsilon\} \cup L \cup LL \cup LLL \cup \dots$ az L iteráltja,

Tetszőleges számú (0 is megengedett) L -beli szó konkatenációjaként megkapható szavak halmaza.

$$\{ab, ba\}^* = \{\varepsilon, ab, ba, abab, abba, baab, baba, ababab, \dots\}$$

- ▶ $L^+ = L \cup LL \cup LLL \cup \dots$ (a 0 eset kizárva).

17/141

Műveletek nyelvekkel

Megjegyzés: $\emptyset^* = \{\varepsilon\}$ és minden L nyelvre $\varepsilon \in L^*$.

Továbbá: $L^* = \{\varepsilon\} \cup L^+$.

Az \cup , \cap és komplementer műveleteket Boole műveleteknek, az \cup , konkatenáció és iteráció műveleteket pedig reguláris műveleteknek nevezzük.

18/141

Műveletek nyelvekkel

Néhány, nyelv műveletekre vonatkozó azonosság:

$$L_1 \cup (L_2 \cup L_3) = (L_1 \cup L_2) \cup L_3 \quad L_1(L_2L_3) = (L_1L_2)L_3$$

$$L_1 \cup L_2 = L_2 \cup L_1 \quad L\{\varepsilon\} = \{\varepsilon\}L = L$$

$$L \cup L = L$$

$$L \cup \emptyset = \emptyset \cup L = L \quad L\emptyset = \emptyset L = \emptyset$$

Továbbá:

$$L_1(L_2 \cup L_3) = L_1L_2 \cup L_1L_3$$

$$(L_1 \cup L_2)L_3 = L_1L_3 \cup L_2L_3$$

$$(L_1 \cup L_2)^* = (L_1^*L_2)^*L_1^*$$

$$(L_1L_2)^* = \{\varepsilon\} \cup L_1(L_2L_1)^*L_2$$

19/141

Generatív nyelvtanok

Egy olyan, könnyen leírható eszközzel ismerkedünk meg, amely alkalmas (általában végtelen) nyelvek megadására. Az eszköz neve generatív nyelvtan (vagy generatív grammatika).

Más szóval: a generatív nyelvtanok olyan végesen specifikálható eszközök, melyekkel nyelveket tudunk reprezentálni.

20/141

Generatív nyelvtanok

Generatív nyelvtan: egy $G = (N, \Sigma, P, S)$ négyes, ahol:

- ▶ N egy ábécé, a *nemterminális ábécé*,
- ▶ Σ egy ábécé, a *terminális (befejező, végső) ábécé*, amire $N \cap \Sigma = \emptyset$,
- ▶ $S \in N$ a *kezdő szimbólum (vagy start szimbólum)*,
- ▶ P pedig $\alpha \rightarrow \beta$ alakú ún. *átírási szabályok* véges halmaza, ahol $\alpha, \beta \in (N \cup \Sigma)^*$ és α -ban van legalább egy nemterminális betű.


(α a szabály bal oldala, β a jobb oldala.)

21/141

Generatív nyelvtanok

Közvetlen levezetés (*deriváció*):

tetszőleges $\gamma, \delta \in (N \cup \Sigma)^*$ esetén $\gamma \Rightarrow_G \delta$, ha van olyan $\alpha \rightarrow \beta \in P$ szabály és vannak olyan $\alpha', \beta' \in (N \cup \Sigma)^*$ szavak, amelyekre fennállnak, hogy $\gamma = \alpha' \alpha \beta'$, $\delta = \alpha' \beta \beta'$.



23/141

Generatív nyelvtanok

Példa:

$$G_1 = (\{S, A\}, \{a, b\}, \{S \rightarrow aAb, aA \rightarrow aaAb, A \rightarrow \varepsilon\}, S)$$

egy nyelvtan, ahol

- ▶ $\{S, A\}$ a *nemterminális ábécé*,
- ▶ $\{a, b\}$ a *terminális ábécé*,
- ▶ S a *kezdő (start) szimbólum*,
- ▶ $\{S \rightarrow aAb, aA \rightarrow aaAb, A \rightarrow \varepsilon\}$ a *szabályok halmaza*.

$aA \rightarrow aaAb$ egy szabály, aminek a bal oldala aA , a jobb oldala pedig $aaAb$

22/141

Generatív nyelvtanok

Példa:

$$G_1 = (\{S, A\}, \{a, b\}, \{S \rightarrow aAb, aA \rightarrow aaAb, A \rightarrow \varepsilon\}, S)$$

$b\underline{a}Aa \Rightarrow b\underline{aaAb}Aa$ az $aA \rightarrow aaAb$ szabállyal

$b\underline{aaAb}Aa \Rightarrow b\underline{aaAba}$ az $A \rightarrow \varepsilon$ szabállyal

24/141

Generatív nyelvtanok

Levezetések:

$\gamma \Rightarrow_G \delta$: egy lépés

$\gamma \Rightarrow_G^n \delta$: $n \geq 0$ lépés ($\gamma \Rightarrow_G^0 \delta \iff \gamma = \delta$)

$\gamma \Rightarrow_G^+ \delta$: legalább egy lépés

$\gamma \Rightarrow_G^* \delta$: valamennyi (esetleg 0) lépés

Ha nem okoz félreértést, \Rightarrow_G helyett \Rightarrow -t írunk.

25/141

Generatív nyelvtanok

$G = (N, \Sigma, P, S)$ nyelvtan által generált nyelv:

$$L(G) = \{u \in \Sigma^* \mid S \Rightarrow_G^* u\}.$$

A $G_1 = (\{S, A\}, \{a, b\}, \{S \rightarrow aAb, aA \rightarrow aaAb, A \rightarrow \varepsilon\}, S)$ példában

$$L(G_1) = \{a^n b^n \mid n \geq 1\}.$$

Egy nyelvet általában nem csak egy nyelvtannal lehet generálni: a $G = (N, \Sigma, P, S)$ és $G' = (N', \Sigma', P', S')$ nyelvtanok ekvivalensek, ha $L(G) = L(G')$.

27/141

Generatív nyelvtanok

Példa:

$$G_1 = (\{S, A\}, \{a, b\}, \{S \rightarrow aAb, aA \rightarrow aaAb, A \rightarrow \varepsilon\}, S)$$

$$\begin{aligned} S &\Rightarrow aAb && \Rightarrow aaAbb \\ &\Rightarrow aaaAbbb && \Rightarrow aaabbbb \end{aligned}$$

Tehát: $S \Rightarrow^* aaabbbb$, $S \Rightarrow^+ aaabbbb$, $S \Rightarrow^4 aaabbbb$ mind teljesülnek.

Továbbá: $aAb \Rightarrow aaAbb$, $aAb \Rightarrow^2 aaaAbbbb$, tehát $aAb \Rightarrow^* aaAbb$, $aAb \Rightarrow^* aaaAbbbb$.

Leginkább azok a levezetések érdekelnek bennünket, amelyek a kezdő szimbólumból indulnak ki és terminális szóban végződnek.

26/141

Generatív nyelvtan

Példa:

Az előbbi G_1 nyelvtan ekvivalens a

$$G_2 = (\{S\}, \{a, b\}, \{S \rightarrow aSb, S \rightarrow ab\}, S)$$

nyelvtannal, mert ugyancsak

$$L(G_2) = \{a^n b^n \mid n \geq 1\}.$$

28/141

Generatív nyelvtanok

Példa: $G_{ar} = (N, \Sigma, P, S)$, ahol

- ▶ $N = \{K, T, F\}$,
- ▶ $\Sigma = \{+, *, (,), a\}$,
- ▶ $S = K$,
- ▶ $P = \{$
 - $K \rightarrow K + T, K \rightarrow T,$
 - $T \rightarrow T * F, T \rightarrow F,$
 - $F \rightarrow (K), F \rightarrow a\}$.

Ekkor $L(G_{ar})$ az a -ból valamint a $(,), +$ és $*$ jelekből képezhető aritmetikai kifejezések halmaza.

29/141

Általános jelölések

- ▶ Az a, b, c, d, \dots szimbólumok Σ elemeit,
- ▶ az A, B, C, D, \dots , és S szimbólumok N elemeit,
- ▶ az \dots, U, V, W, X, Y, Z szimbólumok $N \cup \Sigma$ elemeit,
- ▶ az $\alpha, \beta, \gamma, \delta, \dots$ szimbólumok $(N \cup \Sigma)^*$ elemeit,
- ▶ és az \dots, u, v, w, x, y, z szimbólumok Σ^* elemeit

fogják jelölni.

31/141

Generatív nyelvtan

Az $A \rightarrow \alpha_1, \dots, A \rightarrow \alpha_n$ szabályok felírását a következőképpen rövidítjük: $A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$.

Például, a G_{ar} nyelvtan szabályai megadhatók így is:

- $K \rightarrow K + T \mid T,$
- $T \rightarrow T * F \mid F,$
- $F \rightarrow (K) \mid a.$

Egy levezetés G_{ar} -ban:

$K \Rightarrow T \Rightarrow T * F \Rightarrow F * F \Rightarrow (K) * F \Rightarrow (K + T) * F \Rightarrow^*$

$(F + F) * F \Rightarrow^* (a + a) * a$

30/141

Chomsky nyelvosztályok

A $G = (N, \Sigma, P, S)$ nyelvtan

- ▶ 0 típusú (vagy *általános*), ha rá semmilyen korlátozás nincs.
- ▶ 1 típusú (vagy *környezetfüggő*), ha P -ben minden szabály $\alpha A \beta \rightarrow \alpha \delta \beta$ alakú, ahol $\delta \neq \varepsilon$. Kivétel, az $S \rightarrow \varepsilon$ szabály, ekkor azonban az S nem szerepelhet semelyik szabály jobb oldalán.
- ▶ 2 típusú (vagy *környezetfüggetlen*), ha P -ben minden szabály $A \rightarrow \alpha$ alakú.
- ▶ 3 típusú (vagy *reguláris*), ha P -ben minden szabály $A \rightarrow xB$ vagy $A \rightarrow x$ alakú.

32/141

Chomsky nyelvosztályok

Egy adott G nyelvtan esetén a legnagyobb olyan $i \in \{0, 1, 2, 3\}$ az érdekes, melyre a nyelvtan i típusú.

Pl. a G_1 , G_2 és G_{ar} nyelvtanok rendre 0, 2 és 2 típusúak.

Egy adott $L \subseteq \Sigma^*$ nyelvet i típusúnak mondunk valamely $i \in \{0, 1, 2, 3\}$ -re, ha van olyan i típusú G nyelvtan, amelyre $L = L(G)$. Itt is a legnagyobb olyan i az érdekes, melyre a nyelv i típusú.

Pl. az $L(G_1)$, $L(G_2)$ és $L(G_{ar})$ nyelvek mindegyike 2 típusú és be lehet bizonyítani, hogy egyik sem 3 típusú.

33/141

Chomsky nyelvosztályok

Az $i \in \{0, 1, 2, 3\}$ típusú nyelvek osztályát \mathcal{L}_i -vel jelöljük.

Az nyilvánvaló, hogy $\mathcal{L}_3 \subseteq \mathcal{L}_2$ és $\mathcal{L}_1 \subseteq \mathcal{L}_0$, mert minden 3-típusú nyelvtan 2-típusú is és minden 1-típusú nyelvtan 0-típusú is.

Később látni fogjuk, hogy érvényes a *Chomsky nyelvhierarchia*:

$$\mathcal{L}_3 \subseteq \mathcal{L}_2 \subseteq \mathcal{L}_1 \subseteq \mathcal{L}_0,$$

sőt az erősebb

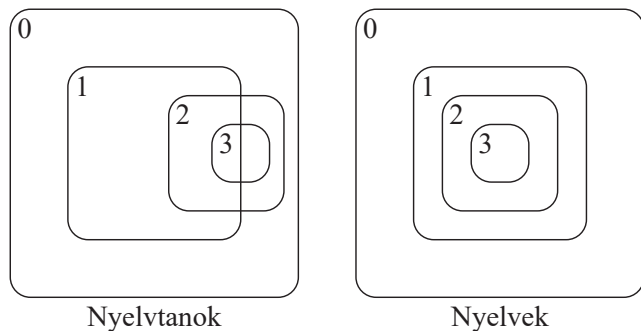
$$\mathcal{L}_3 \subset \mathcal{L}_2 \subset \mathcal{L}_1 \subset \mathcal{L}_0$$

alakja is.

34/141

Chomsky nyelvosztályok

Összefoglalás



A bal oldali az eddigiek alapján világos, a jobb oldalit fokozatosan, teljesen a félév végére látjuk be.

35/141

Véges automaták, reguláris kifejezések

További program:

Először a reguláris nyelveket (vagyis a reguláris nyelvtanokkal generálható nyelveket) vizsgáljuk.

Bevezetünk további két olyan eszközt, amelyekkel reguláris nyelveket lehet megadni (reprezentálni): a véges automatákat és a reguláris kifejezéseket.

Megmutatjuk, hogy mind a véges automatákkal felismerhető nyelvek, mind a reguláris kifejezésekkel reprezentálható nyelvek megegyeznek a reguláris nyelvekkel.

36/141

Véges automaták

Az $M = (Q, \Sigma, \delta, q_0, F)$ rendszert *determinisztikus automatának* nevezzük, ahol:

1. Q egy nem üres, véges halmaz, az *állapotok halmaza*,
2. Σ egy ábécé, az *input ábécé*,
3. $q_0 \in Q$ a *kezdő állapot*,
4. $F \subseteq Q$ a *végállapotok halmaza*,
5. $\delta : Q \times \Sigma \rightarrow Q$ egy leképezés, az *átmenetfüggvény*.

37/141

Véges automaták

Példa: $M_3 = (Q, \Sigma, \delta, q_0, F)$ egy automata, ahol

- ▶ $Q = \{q_0, q_1, q_2\}$,
- ▶ $\Sigma = \{a, b\}$,
- ▶ $F = \{q_0\}$, továbbá
 - ▶ $\delta(q_0, a) = q_1, \delta(q_0, b) = q_0$,
 - ▶ $\delta(q_1, a) = q_2, \delta(q_1, b) = q_1$,
 - ▶ $\delta(q_2, a) = q_0, \delta(q_2, b) = q_2$.


39/141

Véges automaták

Automata megadása irányított gráfként:

Az állapotok a gráf csúcsai,

ha $\delta(q, a) = p$, akkor a q csúcsból egy élet irányítunk a p csúcsba és az élet ellátjuk az a címkével,



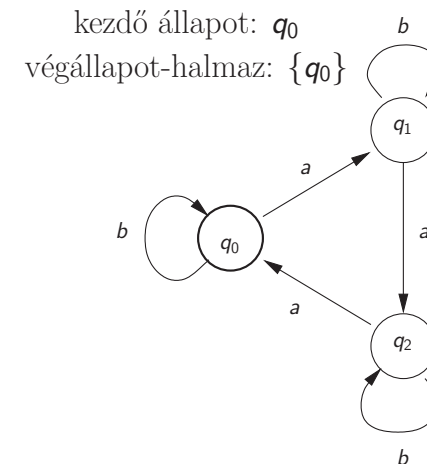
és azt mondjuk, hogy az automata a q állapotból az a input szimbólum hatására átmegy a p állapotba.

A kezdő és a végállapotokat reprezentáló csúcsokat megjelöljük.

38/141

Véges automaták

Az M_3 automata megadása irányított gráfként:



40/141

Véges automaták

Automata megadható táblázat formában is. A kezdő állapotot a táblázat első sorába írjuk, a végállapotokat pedig megjelöljük.

Az M_3 automata megadása táblázattal:

δ	a	b
$*q_0$	q_1	q_0
q_1	q_2	q_1
q_2	q_0	q_2


Véges automaták

Az $M = (Q, \Sigma, \delta, q_0, F)$ automata által felismert nyelven az

$$L(M) = \{w \in \Sigma^* \mid (q_0, w) \vdash_M^* (q, \varepsilon) \text{ és } q \in F\}$$

nyelvet értjük.

Szavakkal: q_0 -ból a w hatására valamelyik $q \in F$ végállapotba jutunk.



41/141

Véges automaták

M konfigurációinak halmaza: $C = Q \times \Sigma^*$.

A $(q, a_1 \dots a_n)$ konfiguráció azt jelenti, hogy M a q állapotban van és az $a_1 \dots a_n$ szót kapja inputként.

Átmeneti reláció:

$(q, w), (q', w') \in C$ esetén $(q, w) \vdash_M (q', w')$ ha $w = aw'$, valamely $a \in \Sigma$ -ra és $\delta(q, a) = q'$.

$(q, w) \vdash_M (q', w')$, egy lépés

$(q, w) \vdash_M^n (q', w')$, $n \geq 0$ lépés


$(q, w) \vdash_M^+ (q', w')$, legalább egy lépés

$(q, w) \vdash_M^* (q', w')$, valamennyi (esetleg 0) lépés

42/141

Véges automaták

Átmenetek az M_3 automatában:



$(q_1, aabb) \vdash_{M_3} (q_2, abb) \vdash_{M_3} (q_0, bb) \vdash_{M_3}^2 (q_0, \varepsilon)$,

$(q_0, babaa) \vdash_{M_3} (q_0, abaa) \vdash_{M_3} (q_1, baa) \vdash_{M_3} (q_1, aa) \vdash_{M_3}$

$(q_2, a) \vdash_{M_3} (q_0, \varepsilon)$ és


$(q_0, abb) \vdash_{M_3} (q_1, bb) \vdash_{M_3} (q_1, b) \vdash_{M_3} (q_1, \varepsilon)$

43/141

44/141

Véges automaták

Az M_3 automata által felismert $L(M_3)$ nyelv azon szavakból áll, amelyekben az a betűk száma osztható hárommal.



$babaa \in L(M_3)$, mert: $(q_0, babaa) \vdash_{M_3} (q_0, abaa) \vdash_{M_3} (q_1, baa) \vdash_{M_3} (q_1, aa) \vdash_{M_3} (q_2, a) \vdash_{M_3} (q_0, \varepsilon)$

$abb \notin L(M_3)$, mert: $(q_0, abb) \vdash_{M_3} (q_1, bb) \vdash_{M_3} (q_1, b) \vdash_{M_3} (q_1, \varepsilon)$

45/141

Véges automaták

A determinisztikus automata általánosítása: nemdeterminisztikus automata.

Az $M = (Q, \Sigma, \delta, q_0, F)$ rendszert *nemdeterminisztikus automatának* nevezzük, ahol:

1. Q egy nem üres, véges halmaz, az *állapotok halmaza*,
2. Σ egy ábécé, az *input ábécé*,
3. $q_0 \in Q$ a *kezdő állapot*,
4. $F \subseteq Q$ a *végállapotok halmaza*,
5. $\delta : Q \times \Sigma \rightarrow \mathcal{P}(Q)$ egy leképezés, az *átmenetfüggvény*.


Egy input szimbólum hatására egy állapotból több állapotba is átmehet. Az általánosítás valójában nem növeli meg a felismerő kapacitást.

46/141

Véges automaták

A nemdeterminisztikus automata egy input szimbólum hatására egy állapotból több állapotba is átmehet:

$$\delta(q, a) = \{q_1, \dots, q_n\}$$



Az is megengedett, hogy $\delta(q, a) = \emptyset$.


47/141

Véges automaták

Példa: $M_{aba} = (Q, \Sigma, \delta, q_0, F)$ egy nemdeterminisztikus automata, ahol

- ▶ $Q = \{q_0, q_1, q_2, q_3\}$,
- ▶ $\Sigma = \{a, b\}$,
- ▶ $F = \{q_3\}$, továbbá

- ▶ $\delta(q_0, a) = \{q_0, q_1\}$, $\delta(q_0, b) = \{q_0\}$,
- ▶ $\delta(q_1, a) = \emptyset$, $\delta(q_1, b) = \{q_2\}$,
- ▶ $\delta(q_2, a) = \{q_3\}$, $\delta(q_2, b) = \emptyset$,
- ▶ $\delta(q_3, a) = \delta(q_3, b) = \{q_3\}$.




48/141

Véges automaták

Az M_{aba} automata megadása táblázattal:

δ	a	b
q_0	q_0, q_1	q_0
q_1		q_2
q_2	q_3	
$*q_3$	q_3	q_3

Véges automaták



$L(M_{aba}) = \{uabav \mid u, v \in \Sigma^*\}$, tehát M_{aba} pontosan azon Σ^* -beli szavakat ismeri fel amelyekben előfordul az aba rész-szó.

M_{aba} nemdeterminisztikus!

49/141

Véges automaták

Az átmeneti reláció és a felismert nyelv nemdeterminisztikus automatákra:

Átmeneti reláció:

$(q, w), (q', w') \in C$ esetén $(q, w) \vdash_M (q', w')$ ha $w = aw'$, valamely $a \in \Sigma$ -ra és $q' \in \delta(q, a)$.

Az $M = (Q, \Sigma, \delta, q_0, F)$ automata által felismert nyelven az

$$L(M) = \{w \in \Sigma^* \mid (q_0, w) \vdash_M^* (q, \varepsilon) \text{ valamely } q \in F\text{-re}\}$$

nyelvet értjük.

Szavakkal: q_0 -ból a w hatására elérhető valamely $q \in F$ végállapot (ugyanakkor esetleg nem végállapotok is elérhetők).

50/141

Véges automaták

Lehetnek olyan szavak, amelyeket egy nemdeterminisztikus automata nem tud végig olvasni, mert a $\delta(q, a) = \emptyset$ alakú átmenetek miatt "elakadhat". A teljesen definiált automaták viszont minden szót végig tudnak olvasni.

Az $M = (Q, \Sigma, \delta, q_0, F)$ nemdeterminisztikus automata *teljesen definiált* (vagy: *teljes*), ha minden $q \in Q$ és $a \in \Sigma$ esetén $\delta(q, a)$ legalább egy elemű.

A determinisztikus automaták teljesen definiáltak. Továbbá, minden nemdeterminisztikus automata könnyen teljessé tehető egy ún. "csapda" állapot bevezetésével, anélkül, hogy a felismert nyelv megváltozna.

51/141

52/141

Véges automaták

Tétel. Tetszőleges $M = (Q, \Sigma, \delta, q_0, F)$ nondeterminisztikus automatához megadható olyan $M' = (Q', \Sigma, \delta', q_0, F)$ teljesen definiált automata, melyre $L(M) = L(M')$.

Bizonyítás. Ha M teljesen definiált, akkor legyen $M' = M$. Különben, legyen $Q' = Q \cup \{q_c\}$, ahol $q_c \notin Q$, vagyis egy új állapot (a "csapda" állapot).


Továbbá, minden $q \in Q$ és $a \in \Sigma$ esetén, legyen

$$\delta'(q, a) = \begin{cases} \delta(q, a) & \text{ha } \delta(q, a) \neq \emptyset \\ \{q_c\} & \text{ha } \delta(q, a) = \emptyset. \end{cases}$$

Végül, minden $a \in \Sigma$ -ra, legyen $\delta'(q_c, a) = \{q_c\}$.

Véges automaták

Példa. Az M_{aba} automata teljessé tétele.



53/141

54/141

Véges automaták

Tétel. Egy nyelv akkor és csak akkor ismerhető fel nondeterminisztikus automatával, ha felismerhető determinisztikus automatával.

Bizonyítás. a) Ha egy nyelv felismerhető determinisztikus automatával akkor felismerhető nondeterminisztikus automatával is.


b) Fordítva: legyen $M = (Q, \Sigma, \delta, q_0, F)$ egy nondeterminisztikus automata. Megadunk egy $M' = (Q', \Sigma, \delta', q'_0, F')$ determinisztikus automatát, amelyre $L(M') = L(M)$.

A konstrukció neve: hatványhalmaz konstrukció.

Véges automaták

$M' = (Q', \Sigma, \delta', q'_0, F')$, ahol

- ▶ $Q' = \mathcal{P}(Q) (= \{S \mid S \subseteq Q\})$, a hatványhalmaz,
- ▶ $q'_0 = \{q_0\}$,
- ▶ $F' = \{S \subseteq Q \mid S \cap F \neq \emptyset\}$,
- ▶ $\delta' : Q' \times \Sigma \rightarrow Q'$ az a leképezés amelyre tetszőleges $S \in Q'$ és $a \in \Sigma$ esetén $\delta'(S, a) = \bigcup_{q \in S} \delta(q, a)$.



55/141

56/141

Véges automaták

M' állapotai az M állapotaiból képzett halmazok. Nyilvánvaló, hogy M' determinisztikus. Az $L(M') = L(M)$ bizonyítása:

Állítás. Minden $w \in \Sigma^*$ -ra és $S \subseteq Q$ -ra

$$(\{q_0\}, w) \vdash_{M'}^* (S, \varepsilon) \text{ akkor és csak akkor, ha} \\ S = \{q \in Q \mid (q_0, w) \vdash_M^* (q, \varepsilon)\}.$$


Szavakkal: Az M -ben a w hatására elérhető állapotok halmaza megegyezik azzal az állapottal, melybe M' a w hatására jut. Az állítás könnyen igazolható $|w|$ szerinti indukcióval.

Az állításból azonnal következik, hogy $L(M') = L(M)$, mert mindkét automata akkor ismeri fel w -t, ha S -ben van legalább egy F -beli állapot.

57/141

Véges automaták

Az M és M' felismeri $w = a_1 \dots a_k$ szót.



58/141

Véges automaták

Egy fontos megjegyzés:


A hatványhalmaz konstrukcióval kapott determinisztikus automata állapotainak a száma exponenciálisan növekedhet az eredeti nemdeterminisztikus automata állapotaikhoz képest (n -ről 2^n -re). Ez nagy állapotszámú rendszerek esetén állapottér robbanást eredményez.

Szerencsére a helyzet általában ennél sokkal jobb. A gyakorlatban úgy járunk el, hogy a determinisztikus automata $\{q_0\}$ kezdőállapotából kiindulva csak azokat az állapotokat konstruáljuk meg, amelyek ezen kezdőállapotból elérhetők. Ez a trükk általában a 2^n -nél jóval kevesebb állapotot eredményez. (Lásd a következő példát.)

59/141

Véges automaták

Példa. Determinizáljuk az M_{aba} nemdeterminisztikus automatát!




$$L(M_{aba}) = \{uabav \mid u, v \in \Sigma^*\}$$

60/141

Véges automaták


Példa. Átmenetek a $\{q_0, q_1\}$ állapotból:



61/141

Véges automaták

Példa. Az M_{aba} automata determinizálása:




A kapott automata determinisztikus és 6 állapota van (16 helyett).

62/141

Véges automaták

Példa. Észrevesszük, hogy a 3 végállapot összevonható egyetlen p végállapottá:



Az így kapott automatának már csak 4 állapota van.

63/141

Véges automaták

A nemdeterminisztikus automata általánosítása: nemdeterminisztikus automata ε -átmenettel, röviden nemdeterminisztikus ε -automata.

Az $M = (Q, \Sigma, \delta, q_0, F)$ rendszert *nemdeterminisztikus ε -automatának* nevezzük, ahol:

1. Q egy nem üres, véges halmaz, az *állapotok halmaza*,
2. Σ egy ábécé, az *input ábécé*,
3. $q_0 \in Q$ a *kezdő állapot*,
4. $F \subseteq Q$ a *végállapotok halmaza*,
5. $\delta : Q \times (\Sigma \cup \{\varepsilon\}) \rightarrow \mathcal{P}(Q)$ egy leképezés, az *átmenetfüggvény*.

Olyan átmenet is lehetséges, amelyik "nem fogyasztja az inputot". Előnye, hogy néha kényelmes alkalmazni. Ugyanakkor, a nemdeterminizmusához hasonlóan, nem növeli meg a felismerő kapacitást.

64/141

Véges automaták

Egy ε -átmenet



Átmeneti reláció:


$(q, w), (q', w') \in C$ esetén $(q, w) \vdash_M (q', w')$ ha $w = aw'$,
valamely $a \in (\Sigma \cup \{\varepsilon\})$ -ra és $q' \in \delta(q, a)$.

A felismert nyelv definíciója ugyanaz, mint a nemdeterminisztikus
esetben: az M automata a w szót felismeri, ha q_0 -ból a w
hatására elérhető valamely $q \in F$ végállapot (esetleg a
 ε -átmenetek "segítségével").

65/141

Véges automaták

Egy példa:



Felismert nyelv: $\{1, 11, 0, 01, 00\}\{0\}^*$

δ	0	1	ε
$\rightarrow A$	E	B	
B		C	D
C			D
*D	F		
E	F		B, C
F			D

66/141

Véges automaták

Tétel. Egy nyelv akkor és csak akkor ismerhető fel
nemdeterminisztikus ε -automatával, ha felismerhető
nemdeterminisztikus automatával.

Bizonyítás. a) Ha egy nyelv felismerhető nemdeterminisztikus
automatával akkor felismerhető nemdeterminisztikus
 ε -automatával is.

b) Fordítva: legyen $M = (Q, \Sigma, \delta, q_0, F)$ egy nemdeterminisztikus
 ε -automata. Megadunk egy $M' = (Q, \Sigma, \delta', q_0, F')$
nemdeterminisztikus automatát, amelyre $L(M') = L(M)$.

Véges automaták

Az $M = (Q, \Sigma, \delta, q_0, F)$ nemdeterminisztikus ε -automatához
megadunk egy $M' = (Q, \Sigma, \delta', q_0, F')$ nemdeterminisztikus
automatát, amelyre $L(M') = L(M)$.

M' megadásához, ki kell számolni az állapotok ε -lezárását M -ben.
Egy $q \in Q$ állapot ε -lezárása azon állapotokból áll, amelyek
elérhetők q -ból ε -átmenetekkel:

$$Cl(q) = \{p \in Q \mid (q, \varepsilon) \vdash_M^* (p, \varepsilon)\}.$$

A $\{q\}$ halmazból kiindulva, hozzávesszük a q -ból egy ε -átmenettel
elérhető állapotokat, és ezt az eljárást addig folytatjuk, amíg a
halmaz bővíthető. Tehát $q \in Cl(q)$.

67/141

68/141

Véges automaták

Az $M = (Q, \Sigma, \delta, q_0, F)$ nemdeterminisztikus ε -automatához megadunk egy $M' = (Q, \Sigma, \delta', q_0, F')$ nemdeterminisztikus automatát, amelyre $L(M') = L(M)$.

A $CI(q)$ lezárások ismeretében, legyen:


- ▶ $\delta'(q, a) = \bigcup_{p \in CI(q)} \delta(p, a)$ és
- ▶ $F' = \{q \in Q \mid CI(q) \cap F \neq \emptyset\}$.

Tehát M' a q állapotból az a hatására azon állapotokba megy át, amelyekbe M' valamennyi ε -átmenettel, majd egy a -átmenettel jut el. Továbbá M' végállapotai azon állapotok, amelyekből M valamennyi ε -átmenettel egy F -beli állapotba jut, vagyis felismer. (A "valamennyi" mindkét esetben lehet nulla is.)

Ezért $L(M') = L(M)$.

Véges automaták

Egy példa:




- ▶ $CI(A) = \{A\}$, $CI(B) = \{B, D\}$, $CI(C) = \{C, D\}$,
- ▶ $CI(D) = \{D\}$, $CI(E) = \{E, B, C, D\}$, $CI(F) = \{F, D\}$
- ▶ $F' = \{E, B, C, F, D\}$

69/141

70/141

Véges automaták

Egy példa:



Az ekvivalens nemdeterminisztikus automata.
Felismert nyelv: $\{1, 11, 0, 01, 00\}^*$.

Véges automaták

Összefoglalás:

Véges automatákkal nyelveket lehet definiálni, oly módon, hogy minden M automata felismer egy $L(M)$ nyelvet. A következő három fajta automatát ismertük meg:

- ▶ determinisztikus automata, nemdeterminisztikus automata, nemdeterminisztikus ε -automata.

A felismerő kapacitása mindhárom fajta automatának ugyanaz. Ugyanakkor, a nemdeterminisztikus automatákkal "könnyebb bánni", például egy adott nyelvhez általában könnyebb megadni az öt felismerő nemdeterminisztikus automatát, mint a determinisztikusát. Ez még inkább igaz a nemdeterminisztikus ε -automatákra. Például két automatához nagyon könnyű megadni egy olyan nemdeterminisztikus ε -automatát, amely az eredeti automaták által felismert nyelvek egyesítését vagy konkatenációját ismeri fel.

71/141

72/141

Reguláris kifejezések

Program:

Nyelvek megadásának egy újabb formájával ismerkedünk meg.

Veszünk egy ábécét és hozzáveszünk néhány segédszimbólumot. Ezekből ún. reguláris kifejezéseket építünk fel bizonyos szabályok szerint. Minden reguláris kifejezés meghatároz (vagy: reprezentál) egy nyelvet. Az összes ilyen nyelvet vizsgáljuk.

Ki fog derülni, hogy a reguláris kifejezésekkel reprezentálható nyelvek nem mások, mint a reguláris nyelvek.

Reguláris kifejezések

Az R reguláris kifejezés által meghatározott (reprezentált) $|R|$ nyelvet a következőképpen definiáljuk:

- (i) Ha $R = \emptyset$ (áthúzott nulla), akkor $|R| = \emptyset$ (üres nyelv);
- (ii) Ha $R = \varepsilon$ (mint szimbólum), akkor $|R| = \{\varepsilon\}$ (mint nyelv);
- (iii) Ha $R = a$ (mint szimbólum), akkor $|R| = \{a\}$ (mint nyelv);
- (iv) a) Ha $R = (R_1) + (R_2)$, akkor $|R| = |R_1| \cup |R_2|$;
- (iv) b) Ha $R = (R_1)(R_2)$, akkor $|R| = |R_1||R_2|$;
- (iv) c) Ha $R = (R_1)^*$, akkor $|R| = |R_1|^*$.

Egy $L \subseteq \Sigma^*$ nyelv reprezentálható reguláris kifejezéssel, ha van olyan Σ feletti R reguláris kifejezés, melyre $|R| = L$.

73/141

75/141

Reguláris kifejezések

Egy Σ ábécé feletti reguláris kifejezések halmaza a $(\Sigma \cup \{\emptyset, \varepsilon, (,), +, * \})^*$ halmaz legsűkebb olyan U részhalmaza, amelyre az alábbi feltételek teljesülnek:

- (i) az \emptyset (áthúzott nulla) szimbólum eleme U -nak;
- (ii) a ε szimbólum eleme U -nak;
- (iii) Minden $a \in \Sigma$ -ra az a szimbólum eleme U -nak;
- (iv) Ha $R_1, R_2 \in U$, akkor $(R_1) + (R_2)$, $(R_1)(R_2)$, és $(R_1)^*$ is elemei U -nak.

Példa: Legyen $\Sigma = \{a, b\}$. Akkor például a $(\emptyset)^*$, $((a) + (b))^*$ és $((a)(b))((a)^*)$, Σ feletti reguláris kifejezések.

74/141

Reguláris kifejezések

A (gyakran zavaró) zárójelezés az egyértelmű kiolvashatóság miatt szükséges.

A zárójelek száma csökkenthető, ha megállapodunk abban, hogy a prioritási sorrend legyen $*$, konkatenáció, $+$. Továbbá, az \cup és konkatenáció művelet asszociatív, azért a $+$ és az egymás után írás zárójelezése elhagyható. Végül (a) helyett a -t, (\emptyset) helyett \emptyset -et írunk.

Így a reguláris kifejezések zárójelezése az alábbi módon egyszerűsödik:

$(\emptyset)^*$ helyett \emptyset^*
 $((a) + (b))^*$ helyett $(a + b)^*$
 $((a)(b))((a)^*)$ helyett aba^*
írhatunk $(a + b)^*aba(a + b)^*$ -t, $a(a + b)^*b(a + b)^*$ -t, stb.

76/141

Reguláris kifejezések

Példák

- ▶ $|\emptyset^*| = |\emptyset|^* = \emptyset^* = \{\varepsilon\}$;
- ▶ $|(a + b)^*| = |a + b|^* = (|a| \cup |b|)^* = (\{a\} \cup \{b\})^* = \{a, b\}^*$;
- ▶ $|aba^*| = |ab|a^*| = |a||b||a^*| = |a||b||a|^* = \{a\}\{b\}\{a\}^* = \{ab\}\{\varepsilon, a, aa, \dots\} = \{ab, aba, abaa, \dots\}$.

Tehát a $\{\varepsilon\}$, $\{a, b\}^*$ és $\{ab, aba, abaa, \dots\}$ nyelvek reprezentálhatók reguláris kifejezéssel.

Minden $\Sigma = \{a_1, \dots, a_n\}$ ábécé esetén a Σ^* nyelv reprezentálható reguláris kifejezéssel, mert $\Sigma^* = |(a_1 + \dots + a_n)^*|$.

77/141

Reguláris kifejezések

További példák: $\Sigma = \{a, b\}$

c) Az $(a + ba)^*(\varepsilon + b)$ reguláris kifejezésre

$$|(a + ba)^*(\varepsilon + b)| = \{w \in \{a, b\}^* \mid w\text{-ben nem fordul elő a } bb \text{ rész-szó}\}$$

Adjunk meg ehhez a nyelvhez egy determinisztikus automatát! Melyik az egyszerűbb?

79/141

Reguláris kifejezések

További példák: $\Sigma = \{a, b\}$

a) $L = \{uabav \mid u, v \in \Sigma^*\}$ ($w \in L \iff w$ -ben előfordul az aba rész-szó) reprezentálható, mert

$$L = |(a + b)^*aba(a + b)^*|.$$

Gondoljunk az ugyanezen nyelvet felismerő determinisztikus automatára. Melyiket könnyebb megadni?

b) $L = \{aubva \mid u, v \in \Sigma^*\}$ ($w \in L \iff w$ a -val kezdődik és végződik és van benne legalább egy b) reprezentálható, mert

$$L = |a(a + b)^*b(a + b)^*a|.$$

78/141

Reguláris kifejezések

További példák reprezentálható nyelvekre:

d) Minden véges nyelv reprezentálható reguláris kifejezéssel. Valóban, legyen $L = \{x_1, \dots, x_n\}$, $n \geq 1$. Akkor

$$L = |R_1 + \dots + R_n|,$$

ahol

$$R_i = \begin{cases} a_{i_1} \dots a_{i_{n_i}} & \text{ha } x_i = a_{i_1} \dots a_{i_{n_i}} \\ \varepsilon & \text{ha } x_i = \varepsilon. \end{cases}$$

Például $|\varepsilon + a + abaa + abba| = \{\varepsilon, a, abaa, abba\}$. Adjunk meg ehhez a nyelvhez is egy determinisztikus automatát!

80/141

Reguláris kifejezések

e) Reguláris kifejezések a UNIX-ban: az ábécé az ASCII és különböző rövidítéseket enged meg.

Rövidítések karakter halmazokra:

- A $.$ (pont) a "tetszőleges karakter" rövidítése.
- Elhagyja a $+$ jeleket: az $a_1 + \dots + a_n$ reguláris kifejezést $[a_1 \dots a_n]$ formában rövidíti. Például a $< + > + =$ helyett $[< > =]$ -t ír.
- Kihaszználva, hogy az ASCII rendezett, halmazokat rövidítve definiál. Például $[0-9]$ jelenti a $0 + \dots + 9$ reguláris kifejezést. További példák: $[A-Z]$ és $[A-Za-z0-9]$.
- "Makrókat" használ. Például $[:digit:]$ a $[0-9]$ helyett és $[:alnum:]$ a $[A-Za-z0-9]$ helyett.

81/141

Az ekvivalencia tétel

Tétel. Tetszőleges $L \subseteq \Sigma^*$ nyelv esetén a következő három állítás ekvivalens:

- (1) L reguláris (generálható 3-típusú nyelvtannal).
- (2) L felismerhető automatával.
- (3) L reprezentálható reguláris kifejezéssel.

Bizonyítás. Megmutatjuk, hogy

1. Lemma: (3) \implies (1)
2. Lemma: (1) \implies (2)
3. Lemma: (2) \implies (3)

Akkor (1) \iff (2) \iff (3). \diamond

83/141

Reguláris kifejezések

e) Reguláris kifejezések a UNIX-ban: az ábécé az ASCII és különböző rövidítéseket és kiterjesztéseket enged meg.

Rövidítések műveletekre:

- A $+$ helyett $|$ jelet ír.
- A $?$ azt jelenti, hogy legfeljebb egy. Tehát az $R?$ UNIX kifejezés a $\varepsilon + R$ rövidítése.
- A $+$ viszont azt jelenti, hogy legalább egy. Tehát az $R+$ UNIX kifejezés az RR^* rövidítése.
- Az $\{n\}$ rövidítés azt jelenti, hogy n példány. Tehát az $R\{5\}$ UNIX kifejezés az $RRRRR$ rövidítése.

Példák: $.?$, $[:digit:]+|[:alnum:]\{3\}$, stb.

82/141

A reguláris nyelvek 3-típusúak

1. Lemma. (3) \implies (1): Ha $L \subseteq \Sigma^*$ nyelv reprezentálható reguláris kifejezéssel, akkor generálható 3-típusú nyelvtannal.

Bizonyítás. Az L -et reprezentáló R reguláris kifejezés struktúrája szerinti indukcióval.

Az indukció alapja.

(i) $R = \emptyset$ Ekkor $L = |R| = \emptyset$, mely generálható a $G = (\{S\}, \Sigma, \emptyset, S)$, 3-típusú nyelvtannal.

(ii) és (iii) $R = a$, ahol $a \in \Sigma$ vagy $a = \varepsilon$ Ekkor $L = |R| = \{a\}$, mely generálható a $G = (\{S\}, \Sigma, \{S \rightarrow a\}, S)$, 3-típusú nyelvtannal.

84/141

A reguláris nyelvek 3-típusúak

Indukciós lépés.

(iv) a) $R = (R_1) + (R_2)$

Ekkor $L = |R| = L_1 \cup L_2$, ahol $L_1 = |R_1|$ és $L_2 = |R_2|$.

Indukciós feltevés: L_i generálható a $G_i = (N_i, \Sigma, P_i, S_i)$, 3-típusú nyelvtannal, $i = 1, 2$. ($N_1 \cap N_2 = \emptyset$.)

85/141

A reguláris nyelvek 3-típusúak

Indukciós lépés.

(iv) b) $R = (R_1)(R_2)$

Ekkor $L = |R| = L_1 L_2$, ahol $L_1 = |R_1|$ és $L_2 = |R_2|$.

Indukciós feltevés: L_i generálható a $G_i = (N_i, \Sigma, P_i, S_i)$, 3-típusú nyelvtannal, $i = 1, 2$. ($N_1 \cap N_2 = \emptyset$.)

Akkor L generálható a $G = (N_1 \cup N_2, \Sigma, P, S_1)$, 3-típusú nyelvtannal, ahol P a legszűkebb olyan szabályhalmaz amire teljesülnek a következő feltételek:

87/141

A reguláris nyelvek 3-típusúak

Akkor L generálható a

$$G = (N_1 \cup N_2 \cup \{S\}, \Sigma, P_1 \cup P_2 \cup \{S \rightarrow S_1, S \rightarrow S_2\}, S),$$

3-típusú nyelvtannal, ahol S egy új szimbólum.

$$S \Rightarrow_G^* w$$

akkor és csak akkor, ha

$$S_1 \Rightarrow_{G_1}^* w \text{ vagy } S_2 \Rightarrow_{G_2}^* w.$$

86/141

A reguláris nyelvek 3-típusúak

- ▶ Ha $A \rightarrow xB \in P_1$, akkor $A \rightarrow xB \in P$,
- ▶ Ha $A \rightarrow x \in P_1$, akkor $A \rightarrow xS_2 \in P$,
- ▶ P_2 minden eleme P -nek is eleme.

$$S_1 \Rightarrow_{G_1}^* w_1 \text{ és } S_2 \Rightarrow_{G_2}^* w_2$$

akkor és csak akkor, ha

$$S_1 \Rightarrow_G^* w_1 S_2 \Rightarrow_G^* w_1 w_2.$$

88/141

A reguláris nyelvek 3-típusúak

Indukciós lépés.

(iv) c) $R = (R_1)^*$

Ekkor $L = |R| = L_1^*$, ahol $L_1 = |R_1|$.

Indukciós feltevés: L_1 generálható a $G_1 = (N_1, \Sigma, P_1, S_1)$, 3-típusú nyelvtannal.

Akkor L generálható a $G = (N_1 \cup \{S\}, \Sigma, P, S)$, 3-típusú nyelvtannal, ahol S egy új szimbólum, P pedig a legszűkebb olyan szabályhalmaz amire teljesülnek a következő feltételek:

A reguláris nyelvek 3-típusúak

- ▶ $S \rightarrow S_1, S \rightarrow \varepsilon \in P$,
- ▶ Ha $A \rightarrow xB \in P_1$, akkor $A \rightarrow xB \in P$,
- ▶ Ha $A \rightarrow x \in P_1$, akkor $A \rightarrow xS \in P$.

$$S \Rightarrow_G \varepsilon$$

$$S \Rightarrow_G S_1 \Rightarrow_G^* w_1 S \Rightarrow_G w_1 \quad (\in L_1)$$

$$w_1 S \Rightarrow_G w_1 S_1 \Rightarrow_G^* w_1 w_2 S \Rightarrow_G w_1 w_2 \quad (\in L_1 L_1)$$

$$w_1 w_2 S \Rightarrow_G w_1 w_2 S_1 \dots$$

89/141

90/141

Az ekvivalencia tétel

Tétel. Tetszőleges $L \subseteq \Sigma^*$ nyelv esetén a következő három állítás ekvivalens:

- (1) L reguláris (generálható 3-típusú nyelvtannal).
- (2) L felismerhető automatával.
- (3) L reprezentálható reguláris kifejezéssel.

Bizonyítás.

1. Lemma: (3) \implies (1) \checkmark
2. Lemma: (1) \implies (2)
3. Lemma: (2) \implies (3)

A 3-típusú nyelvek felismerhetők automatával

2. Lemma. (1) \implies (2): Ha $L \subseteq \Sigma^*$ nyelv reguláris, akkor felismerhető automatával.

Bizonyítás. Legyen L egy reguláris nyelv és tegyük fel, hogy $L = L(G)$, ahol G egy 3-típusú nyelvtan.

2.1. Lemma. Minden $G = (N, \Sigma, P, S)$, 3-típusú nyelvtanhoz megadható vele ekvivalens $G' = (N', \Sigma, P', S)$, 3-típusú nyelvtan, úgy hogy P' -ben minden szabály $A \rightarrow B$, $A \rightarrow aB$ vagy $A \rightarrow \varepsilon$ alakú, ahol $A, B \in N$ és $a \in \Sigma$.

2.2. Lemma. Minden olyan $G = (N, \Sigma, P, S)$, 3-típusú nyelvtanhoz melynek csak $A \rightarrow B$, $A \rightarrow aB$ vagy $A \rightarrow \varepsilon$ alakú szabályai vannak megadható olyan $M = (Q, \Sigma, \delta, q_0, F)$ nemdeterminisztikus ε -automata, amelyre $L(M) = L(G)$.

91/141

92/141

A 3-típusú nyelvek felismerhetők automatával

2.1. Lemma. Minden $G = (N, \Sigma, P, S)$, 3-típusú nyelvtanhoz megadható vele ekvivalens $G' = (N', \Sigma, P', S)$, 3-típusú nyelvtan, úgy hogy P' -ben minden szabály $A \rightarrow B$, $A \rightarrow aB$ vagy $A \rightarrow \varepsilon$ alakú, ahol $A, B \in N$ és $a \in \Sigma$.

Bizonyítás. Konstruáljuk meg P' -t a következőképpen:

(i) Minden $A \rightarrow B$, $A \rightarrow aB$ és $A \rightarrow \varepsilon$ alakú P -beli szabályt vegyünk fel P' -be.

A 3-típusú nyelvek felismerhetők automatával

(ii) Minden $A \rightarrow a_1 \dots a_n B$, P -beli szabály esetén (ahol $n > 1$, $a_1, \dots, a_n \in \Sigma$) vegyünk fel P' -be az

$$A \rightarrow a_1 A_1, A_1 \rightarrow a_2 A_2, \dots, A_{n-1} \rightarrow a_n B$$

szabályokat, ahol A_1, \dots, A_{n-1} új nemterminális szimbólumok.

(iii) Minden $A \rightarrow a_1 \dots a_n$, P -beli szabály esetén (ahol $n \geq 1$, $a_1, \dots, a_n \in \Sigma$) vegyünk fel P' -be az

$$A \rightarrow a_1 A_1, A_1 \rightarrow a_2 A_2, \dots, A_{n-1} \rightarrow a_n A_n, A_n \rightarrow \varepsilon$$

szabályokat, ahol A_1, \dots, A_n új nemterminálisok.

Legyen $N' = N \cup \{ \text{új nemterminálisok} \}$.

93/141

94/141

A 3-típusú nyelvek felismerhetők automatával

Minden $A \in N$ -re és $w \in \Sigma^*$ -ra

$$A \Rightarrow_G^* w \text{ akkor és csak akkor, ha } A \Rightarrow_{G'}^* w.$$

Ugyanis

$A \rightarrow a_1 \dots a_n B \in P$ akkor és csak akkor, ha
 $A \Rightarrow_{G'} a_1 A_1 \Rightarrow_{G'} \dots \Rightarrow_{G'} a_1 \dots a_{n-1} A_{n-1} \Rightarrow_{G'} a_1 \dots a_n B$

és

$A \rightarrow a_1 \dots a_n \in P$ akkor és csak akkor, ha
 $A \Rightarrow_{G'} a_1 A_1 \Rightarrow_{G'} \dots \Rightarrow_{G'} a_1 \dots a_n A_n \Rightarrow_{G'} a_1 \dots a_n$.

Az $A = S$ választással kapjuk, hogy $L(G) = L(G')$.

A 3-típusú nyelvek felismerhetők automatával

Példa a szabályok szétdarabolására

$$G : \begin{array}{l|l} S & \rightarrow abA \quad | \quad bB \\ A & \rightarrow bbB \quad | \quad \varepsilon \\ B & \rightarrow ab \quad | \quad bA \end{array}$$

$$G' : \begin{array}{l} S \rightarrow aA_1, \quad A_1 \rightarrow bA, \quad S \rightarrow bB \\ A \rightarrow bA_2, \quad A_2 \rightarrow bB, \quad A \rightarrow \varepsilon \\ B \rightarrow aA_3, \quad A_3 \rightarrow bA_4, \quad A_4 \rightarrow \varepsilon \\ B \rightarrow bA \end{array}$$

95/141

96/141

A 3-típusú nyelvek felismerhetők automatával

2.2. Lemma. Minden olyan $G = (N, \Sigma, P, S)$, 3-típusú nyelvtanhoz melynek csak $A \rightarrow B$, $A \rightarrow aB$ vagy $A \rightarrow \varepsilon$ alakú szabályai vannak megadható olyan $M = (Q, \Sigma, \delta, q_0, F)$ nemdeterminisztikus ε -automata, amelyre $L(M) = L(G)$.

Bizonyítás. Konstruáljuk meg M -et a következőképpen:

- ▶ $Q = N$,
- ▶ $q_0 = S$,
- ▶ $F = \{B \in N \mid B \rightarrow \varepsilon \in P\}$,
- ▶ minden $A \in N$ és $a \in (\Sigma \cup \{\varepsilon\})$ esetén legyen

$$\delta(A, a) = \{B \in N \mid A \rightarrow aB \in P\}.$$

A 3-típusú nyelvek felismerhetők automatával


G-ben:

$$A \rightarrow aB \in P$$

\Leftrightarrow

$$B \rightarrow \lambda \in P$$

M-ben:



$$B \in F$$

Az ábrán $a \in \Sigma$ vagy $a = \varepsilon$.

97/141

98/141

A 3-típusú nyelvek felismerhetők automatával

Ekkor minden $n \geq 1$, $A, B \in N$ és $w \in \Sigma^*$ esetén

$$A \Rightarrow_G^n wB \text{ akkor és csak akkor ha } (A, w) \vdash_M^n (B, \varepsilon).$$

Részletesebben:

$$A \Rightarrow_G a_1 A_1 \Rightarrow_G \dots \Rightarrow_G a_1 \dots a_{n-1} A_{n-1} \Rightarrow_G a_1 \dots a_n B$$

akkor és csak akkor, ha

$$(A, a_1 \dots a_n) \vdash_M (A_1, a_2 \dots a_n) \vdash_M \dots \vdash_M (B, \varepsilon).$$

Az $A = S$, $B \in F$ választással adódik, hogy $L(M) = L(G)$.

A 3-típusú nyelvek felismerhetők automatával

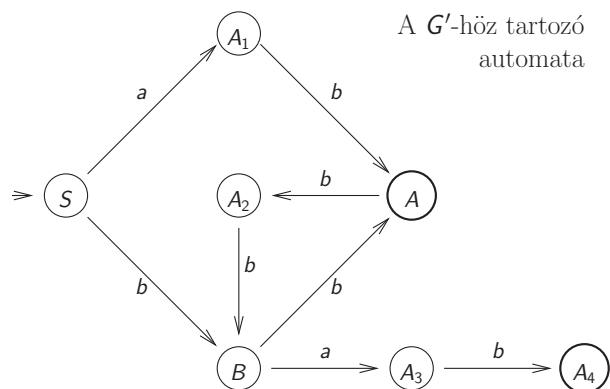
Például, vegyük az előbbi G' nyelvtant:

$$G' : \begin{array}{l} S \rightarrow aA_1, \quad A_1 \rightarrow bA, \quad S \rightarrow bB \\ A \rightarrow bA_2, \quad A_2 \rightarrow bB, \quad A \rightarrow \varepsilon \\ B \rightarrow aA_3, \quad A_3 \rightarrow bA_4, \quad A_4 \rightarrow \varepsilon \\ B \rightarrow bA \end{array}$$

99/141

100/141

A 3-típusú nyelvek felismerhetők automatával



101/141

Az ekvivalencia tétel

Tétel. Tetszőleges $L \subseteq \Sigma^*$ nyelv esetén a következő három állítás ekvivalens:

- (1) L reguláris (generálható 3-típusú nyelvtannal),
- (2) L felismerhető automatával.
- (3) L reprezentálható reguláris kifejezéssel.

Bizonyítás.

1. Lemma: (3) \implies (1) \checkmark
2. Lemma: (1) \implies (2) \checkmark
3. Lemma: (2) \implies (3)

103/141

A 3-típusú nyelvek felismerhetők automatával

Egy megjegyzés a 2.2 Lemmához:

A lemma bizonyításában alkalmazott konstrukció könnyen "megfordítható", vagyis tetszőleges M nemdeterminisztikus ε -automatához meg tudunk adni egy olyan G reguláris nyelvtant, amelyre $L(G) = L(M)$.

Valóban, a nyelvtan nemterminálisai az automata állapotai lesznek. Továbbá, ha az automatában valamely q állapotból egy $a \in (\Sigma \cup \{\varepsilon\})$ szimbólum hatására egy p állapotba jutunk (azaz $p \in \delta(q, a)$), akkor a nyelvtanba felvesszük a $q \rightarrow ap$ szabályt. Végül minden q végállapot esetén a nyelvtanba felvesszük a $q \rightarrow \varepsilon$ szabályt.

Ezzel a bizonyítottuk, hogy (2) \implies (1). A tétel bizonyításához viszont még a (2) \implies (3) lépés hiányzik.

102/141

Az automatával felismerhető nyelvek regulárisak

Lemma 3. (2) \implies (3): Minden, automatával felismerhető nyelv reprezentálható reguláris kifejezéssel. (S. C. Kleene tétele, 1956.)

Bizonyítás. Legyen $L = L(M)$, ahol $M = (Q, \Sigma, \delta, q_0, F)$ determinisztikus automata. Megadunk egy olyan reguláris kifejezést, amely L -et reprezentálja.

Tételezzük fel, hogy $Q = \{1, \dots, n\}$ és $q_0 = 1$.

Minden $0 \leq k \leq n$ és $1 \leq i, j \leq n$ esetén definiáljuk a $L_{i,j}^{(k)} \subseteq \Sigma^*$ nyelvet a következőképpen:

$$x \in L_{i,j}^{(k)} \iff (i, x) \vdash_M^* (j, \varepsilon) \text{ és}$$


minden $(i, x) \vdash_M^+ (i', x') \vdash_M^+ (j, \varepsilon)$ esetén

$$i' \in \{1, \dots, k\}.$$

104/141

Az automatával felismerhető nyelvek regulárisak

Az $L_{i,j}^{(k)}$ nyelvet alkotó x szavak:



105/141

Az automatával felismerhető nyelvek regulárisak

Mivel

$$L(M) = \bigcup_{j \in F} L_{1,j}^{(n)},$$

elegendő megadni minden $j \in F$ -re egy $L_{1,j}^{(n)}$ -t reprezentáló reguláris kifejezést.

Ha ugyanis $L_{1,j}^{(n)} = |R_{1,j}^{(n)}|$, akkor

$$L(M) = |R_{1,j_1} + \dots + R_{1,j_l}|,$$

ahol $F = \{j_1, \dots, j_l\}$.

Többet bizonyítunk: minden $0 \leq k \leq n$ -ra és $1 \leq i, j \leq n$ -re megadunk egy $R_{i,j}^{(k)}$ reguláris kifejezést, melyre


$$|R_{i,j}^{(k)}| = L_{i,j}^{(k)}.$$

106/141

Az automatával felismerhető nyelvek regulárisak

$R_{i,j}^{(k)}$ megadása k szerinti indukcióval. $k = 0$:

$$L_{i,j}^{(0)} = \begin{cases} \{a \in \Sigma \mid \delta(i, a) = j\}, & \text{ha } i \neq j \\ \{a \in \Sigma \mid \delta(i, a) = j\} \cup \{\varepsilon\}, & \text{ha } i = j. \end{cases}$$



$$R_{i,j}^{(0)} = a_1 + \dots + a_t \text{ vagy } R_{i,j}^{(0)} = a_1 + \dots + a_t + \varepsilon$$

Mindkét esetben $|R_{i,j}^{(0)}| = L_{i,j}^{(0)}$.

107/141

Az automatával felismerhető nyelvek regulárisak

$k \Rightarrow k + 1$:

tfh minden i, j -re megadtuk $R_{i,j}^{(k)}$ -t, melyre $|R_{i,j}^{(k)}| = L_{i,j}^{(k)}$
 \implies megadjuk minden i, j -re $R_{i,j}^{(k+1)}$ -t


Először is észrevesszük (!), hogy

$$L_{i,j}^{(k+1)} = L_{i,j}^{(k)} \cup L_{i,k+1}^{(k)} (L_{k+1,k+1}^{(k)})^* L_{k+1,j}^{(k)}.$$

108/141

Az automatával felismerhető nyelvek regulárisak

$$L_{i,j}^{(k+1)} = L_{i,j}^{(k)} \cup L_{i,k+1}^{(k)} (L_{k+1,k+1}^{(k)})^* L_{k+1,j}^{(k)}$$



109/141

Az ekvivalencia tétel

Tétel. Tetszőleges $L \subseteq \Sigma^*$ nyelv esetén a következő három állítás ekvivalens:

- (1) L reguláris (generálható 3-típusú nyelvtannal),
- (2) L felismerhető automatával.
- (3) L reprezentálható reguláris kifejezéssel.

Bizonyítás.

1. Lemma: (3) \implies (1) \checkmark
2. Lemma: (1) \implies (2) \checkmark
3. Lemma: (2) \implies (3) \checkmark

Tehát (1) \iff (2) \iff (3). \diamond

111/141

Az automatával felismerhető nyelvek regulárisak

Legyen

$$R_{i,j}^{(k+1)} = R_{i,j}^{(k)} + R_{i,k+1}^{(k)} (R_{k+1,k+1}^{(k)})^* R_{k+1,j}^{(k)}$$

Ekkor

$$\begin{aligned} |R_{i,j}^{(k+1)}| &= |R_{i,j}^{(k)}| \cup |R_{i,k+1}^{(k)}| |R_{k+1,k+1}^{(k)}|^* |R_{k+1,j}^{(k)}| \\ &= L_{i,j}^{(k)} \cup L_{i,k+1}^{(k)} (L_{k+1,k+1}^{(k)})^* L_{k+1,j}^{(k)} = L_{i,j}^{(k+1)} \end{aligned}$$

Mint láttuk, $L(M) = |R_{1,j_1}| + \dots + |R_{1,j_l}|$.

110/141

Az ekvivalencia tétel

Összefoglalás:

A következő eszközök mindegyikével a reguláris nyelveket reprezentálhatjuk:

- ▶ reguláris (3-típusú) nyelvtanok,
- ▶ reguláris nyelvtanok, amelyek minden szabálya $A \rightarrow B$, $A \rightarrow aB$ vagy $A \rightarrow \varepsilon$ alakú,
- ▶ determinisztikus automaták,
- ▶ nondeterminisztikus automaták,
- ▶ nondeterminisztikus ε -automaták,
- ▶ reguláris kifejezések.

A továbbiakban, ha veszünk egy reguláris nyelvet valamilyen probléma megoldására, akkor mindig azt a reprezentációt választjuk, ami a leghatékonyabb az adott probléma szempontjából.

112/141

A Chomsky nyelvosztályok gépi reprezentációi

Gépi reprezentáció:

Nyelvosztály	Gépi repr.	Det. vs nemdet.
\mathcal{L}_3 (reguláris nyelvek)	véges automaták	det. = nemdet.
\mathcal{L}_2 (k. független nyelvek)	?	?
\mathcal{L}_1 (k. függő nyelvek)	?	?
\mathcal{L}_0 (általános nyelvek)	?	?

Pumpáló lemma reguláris nyelvekre

Lemma. (Pumpáló lemma reguláris nyelvekre.)

Minden $L \subseteq \Sigma^*$ reguláris nyelv esetén

- megadható olyan (L -től függő) $k > 0$ egész szám, hogy
- minden $w \in L$ -re,
- ha $|w| \geq k$, akkor van olyan $w = w_1 w_2 w_3$ felbontás, melyre

- 1) $0 < |w_2|$ és $|w_1 w_2| \leq k$,
- 2) minden $n \geq 0$ -ra, $w_1 w_2^n w_3 \in L$.

(Szükséges feltétele annak, hogy egy nyelv reguláris legyen. Ha egy nyelv nem teljesíti ezt a feltételt, akkor az nem reguláris.)

113/141

114/141

Pumpáló lemma reguláris nyelvekre

Bizonyítás. Mivel L reguláris, van olyan $M = (Q, \Sigma, \delta, q_0, F)$ determinisztikus automata, melyre $L = L(M)$.

Legyen $k = ||Q||$ (az állapotok száma). Ez a k jó lesz.

Vegyünk egy $w \in L$ szót úgy, hogy $|w| \geq k$. Akkor $w = a_1 a_2 \dots a_K$, ahol $K \geq k$ és vannak olyan $q_1, q_2, \dots, q_K \in Q$ állapotok, melyekre

$$\begin{aligned} (q_0, a_1 \dots a_K) &\vdash (q_1, a_2 \dots a_K) \\ &\vdash (q_2, a_3 \dots a_K) \\ &\dots \\ &\vdash (q_{K-1}, a_K) \\ &\vdash (q_K, \varepsilon), \end{aligned}$$

továbbá $q_K \in F$.

Pumpáló lemma reguláris nyelvekre

Mivel $K \geq ||Q||$, a q_0, q_1, \dots, q_K sorozaban legalább egy állapot kétszer is szerepel (skatulya elv = pigeon hole principle). Legyen q_j a legelső olyan állapot, amelyik a sorozatban már korábban is előfordul: van olyan $i < j$, hogy $q_i = q_j$.

Legyenek $w_1 = a_1 \dots a_i$, $w_2 = a_{i+1} \dots a_j$ és $w_3 = a_{j+1} \dots a_K$.
(Ha $i = 0$ akkor $w_1 = \varepsilon$, ha $j = K$ akkor $w_3 = \varepsilon$)

Nyilvánvaló, hogy $w = w_1 w_2 w_3$. Továbbá,

1) $0 < |w_2|$, mert $i < j$ és $|w_1 w_2| \leq k$, mert q_j a legelső olyan állapot, amelyik a sorozatban már korábban is előfordul.


és ...

115/141

116/141

Pumpáló lemma reguláris nyelvekre

2) Minden $n \geq 0$ -ra $w_1 w_2^n w_3 \in L$:



117/141

Pumpáló lemma reguláris nyelvekre

Intuáció:

Egy automata nem képes számolni, hogy két betű ugyanannyiszor szerepel-e.

De kezeljük ezt óvatosan! Az alábbi nyelv reguláris:

$\{w \in \{a, b\}^* \mid$
 $w\text{-ben az } ab \text{ és a } ba \text{ alakú rész-szavak száma megegyezik}\}.$

Bizonyítás HF.

119/141

Pumpáló lemma reguláris nyelvekre

A Pumpáló lemma egy következménye:

Lemma. Az $L = \{a^n b^n \mid n \geq 0\}$ nyelv nem reguláris.

Bizonyítás. Tegyük fel, hogy igen (indirekt bizonyítás).

Legyen k a pumpáló lemma szerint az L -hez tartozó szám, és vegyük az $a^k b^k \in L$ szót, melynek hossza $2k \geq k$.

A pumpáló lemma miatt létezik $a^k b^k = w_1 w_2 w_3$ felbontás, melyre $0 < |w_2|$, $|w_1 w_2| \leq k$ és minden $n \geq 0$ -ra $w_1 w_2^n w_3 \in L$.

Mivel $|w_1 w_2| \leq k$, a középső $|w_2|$ szó csak a betűkből áll. Továbbá a $0 < |w_2|$ feltétel miatt a $w_1 w_2^2 w_3$, $w_1 w_2^3 w_3$, stb szavakban az a -k száma nagyobb mint a b -k száma, tehát ezen szavak egyike sincs L -ben. Ellentmondás, tehát L nem reguláris.

118/141

Pumpáló lemma reguláris nyelvekre

A Pumpáló lemma egy további következménye:

van olyan környezetfüggetlen nyelv, amelyik nem reguláris.

Tétel. $\mathcal{L}_3 \subset \mathcal{L}_2$.

Bizonyítás.

a) $\mathcal{L}_3 \subseteq \mathcal{L}_2$, mivel minden reguláris nyelvtan környezetfüggetlen.

b) Az $\{a^n b^n \mid n \geq 0\}$ nyelv \mathcal{L}_2 -beli, mivel generálható az

$$S \rightarrow aSb \mid \varepsilon$$

szabályokból álló környezetfüggetlen nyelvtannal. Ugyanakkor, mint láttuk $L \notin \mathcal{L}_3$.

120/141

Reguláris nyelvek zártsági tulajdonságai

Műveletekre való zártság általában:

Legyen \mathcal{C} nyelvek egy osztálya (pl. reguláris nyelvek, környezetfüggetlen nyelvek) és

$$\bullet: \mathcal{P}(\Sigma^*) \times \mathcal{P}(\Sigma^*) \rightarrow \mathcal{P}(\Sigma^*), \quad (L_1, L_2) \mapsto L_1 \bullet L_2$$

egy kétváltozós művelet nyelvekkel. (Például: egyesítés, konkatenáció, stb.)

Azt mondjuk, hogy \mathcal{C} zárt a \bullet műveletre, ha tetszőleges $L_1, L_2 \in \mathcal{C}$ esetén, $L_1 \bullet L_2 \in \mathcal{C}$.

Az egyváltozós műveletekre (pl. komplementer, iteráció) való zártság hasonlóan definiálható.

121/141

Reguláris nyelvek zártsági tulajdonságai

Boole műveletek: \cup , \cap , komplementer.

Tétel. A reguláris nyelvek osztálya zárt a Boole műveletekre.

Bizonyítás. A reguláris nyelveket most determinisztikus automatákkal reprezentáljuk.

A bizonyításban az automaták direkt szorzata konstrukciót alkalmazzuk.

123/141

Reguláris nyelvek zártsági tulajdonságai

Reguláris műveletek: \cup , konkatenáció, $*$.

Tétel. A reguláris nyelvek osztálya zárt a reguláris műveletekre.

Bizonyítás. A reguláris nyelveket reguláris kifejezésekkel reprezentáljuk. Először az \cup -ra való zártságot bizonyítjuk.

Legyenek L_1, L_2 reguláris nyelvek. Megadunk egy olyan R reguláris kifejezést, melyre $|R| = L_1 \cup L_2$.

Mivel L_1, L_2 reguláris, vannak olyan R_1, R_2 reguláris kifejezések, melyekre $L_1 = |R_1|$ és $L_2 = |R_2|$. Legyen $R = (R_1) + (R_2)$. Ekkor $|R| = |R_1 + R_2| = |R_1| \cup |R_2| = L_1 \cup L_2$, tehát $L_1 \cup L_2$ reguláris.

A konkatenációra és a $*$ -ra való zártság hasonlóan bizonyítható.

122/141

Reguláris nyelvek zártsági tulajdonságai

Automaták direkt szorzata:

Az $M_1 = (Q_1, \Sigma, \delta_1, q_1, F_1)$ és $M_2 = (Q_2, \Sigma, \delta_2, q_2, F_2)$ determinisztikus automaták egy direkt szorzata az $M = (Q_1 \times Q_2, \Sigma, \delta, [q_1, q_2], F)$ automata, ahol minden $p_1 \in Q_1$ és $p_2 \in Q_2$ állapot és $a \in \Sigma$ input szimbólum esetén

$$\delta([p_1, p_2], a) = [\delta_1(p_1, a), \delta_2(p_2, a)],$$

továbbá $F \subseteq Q_1 \times Q_2$ (később adjuk meg pontosan).

Az M állapotai tehát $[p_1, p_2]$ alakú párok. Az M_1 és M_2 automatákat párhuzamosan működtetjük: ha M_1 p_1 -ből az a hatására r_1 -be, M_2 p_2 -ből az a hatására r_2 -be megy át, akkor M $[p_1, p_2]$ -ből az a hatására $[r_1, r_2]$ -be megy át.

124/141

Reguláris nyelvek zártági tulajdonságai

Ekkor minden $p_1, r_1 \in Q_1$, $p_2, r_2 \in Q_2$ és $x \in \Sigma^*$ esetében

$$\begin{aligned} & ([p_1, p_2], x) \vdash_M^* ([r_1, r_2], \varepsilon) \\ & \quad \updownarrow \\ & (p_1, x) \vdash_{M_1}^* (r_1, \varepsilon) \text{ és } (p_2, x) \vdash_{M_2}^* (r_2, \varepsilon). \end{aligned}$$

Vagyis M a szavakon is M_1 és M_2 párhuzamos működését szimulálja.

125/141

Reguláris nyelvek zártági tulajdonságai

Egy megjegyzés:

A komplementerre való zártág egyszerűbben is bizonyítható. Valóban, ha az L nyelv reguláris, akkor felismerhető egy $M = (Q, \Sigma, \delta, q_0, F)$ determinisztikus automatával. De akkor az $M' = (Q, \Sigma, \delta, q_0, Q - F)$ automata az \bar{L} nyelvet ismeri fel, mert pontosan azok a szavak viszik végállapotba, amelyek M -et $Q - F$ -be, vagyis nem végállapotba viszik. Ezért az \bar{L} nyelv is reguláris.

127/141

Reguláris nyelvek zártági tulajdonságai

A Boole műveletekre való zártág bizonyítása: legyenek $L_1 = L(M_1)$ és $L_2 = L(M_2)$ reguláris nyelvek, ahol M_1 és M_2 a fenti determinisztikus automaták. Konstruáljuk meg az M direkt szorzat automatát.

a) Ha $F = F_1 \times F_2$, akkor $L(M) = L(M_1) \cap L(M_2)$. Tehát $L_1 \cap L_2$ is reguláris.

b) Ha $F = F_1 \times (Q_2 - F_2)$, akkor $L(M) = L(M_1) - L(M_2)$. Tehát $L_1 - L_2$ is reguláris.

Következmény: Mivel a Σ^* nyelv reguláris (nyilvánvaló), az $\overline{L_1} = \Sigma^* - L_1$ is reguláris.

c) Ha $F = (F_1 \times Q_2) \cup (Q_1 \times F_2)$, akkor $L(M) = L(M_1) \cup L(M_2)$. Tehát $L_1 \cup L_2$ reguláris. (Újabb bizonyítás.)

126/141

Reguláris nyelvek zártági tulajdonságai

Összefoglalás:

Művelet	Zártág
\cup	igen
konkatenáció	igen
*	igen
\cap	igen
komplementer	igen

128/141

Eldöntési kérdések reguláris nyelvekre

Az eldöntési kérdésekről általában.

Egy eldöntési kérdés mindig egy nyelvosztályra (pl reguláris nyelvek, környezetfüggetlen nyelvek) és egy nyelvekre vonatkozó tulajdonságra (pl. üresség, végeesség) értendő és úgy szól, hogy létezik-e olyan algoritmus, amelynek inputja a nyelv osztály tetszőleges eleme, outputja pedig "Igen" ha a nyelv rendelkezik az adott tulajdonsággal, különben pedig "Nem".

Például, létezik-e olyan algoritmus, amelynek inputja egy tetszőleges reguláris nyelv (vagyis e nyelvet reprezentáló determinisztikus automata), outputja pedig "Igen" ha a nyelv végtelen, különben pedig "Nem". Ugyanez kérdezhető a környezetfüggetlen nyelvekre is.

A kérdésnek csak akkor van értelme, ha az input nyelvet valamilyen eszközzel reprezentáljuk.

129/141

Eldöntési kérdések reguláris nyelvekre

Elem-e probléma

Probléma: Eldönthető-e tetszőleges w szó és L reguláris nyelv esetén, hogy teljesül-e $w \in L$?

Tétel. Az elem-e probléma reguláris nyelvekre eldönthető.

Input: Egy w szó és egy $M = (Q, \Sigma, \delta, q_0, F)$ automatával megadott L reguláris nyelv (tehát $L = L(M)$).

Output: "Igen" ha $w \in L$, különben "Nem".

Algoritmus: Határozzuk meg azt a q állapotot, amelybe az automata q_0 -ból a w hatására kerül. Ha $q \in F$, akkor a válasz "Igen", különben "Nem".

131/141

Eldöntési kérdések reguláris nyelvekre

Ebben a részben a reguláris nyelvek osztályára vonatkozó eldöntési kérdésekkel foglalkozunk.

A fejezet során a reguláris nyelveket determinisztikus automatákkal reprezentáljuk.

Tehát, ha azt mondjuk, hogy adott egy L reguláris nyelv, akkor ez alatt azt értjük, hogy adott egy determinisztikus M automata, amelyre $L = L(M)$.

Mint látni fogjuk, a reguláris nyelvek valamennyi, általunk vizsgált tulajdonsága eldönthető. Magasabb nyelv osztályok esetén pedig egyre több olyan tulajdonság lesz, ami nem eldönthető.

130/141

Eldöntési kérdések reguláris nyelvekre

Ürességi probléma

Probléma: Eldönthető-e tetszőleges L reguláris nyelv esetén, hogy teljesül-e $L = \emptyset$?

Tétel. Az ürességi probléma reguláris nyelvekre eldönthető.

Input: Egy $M = (Q, \Sigma, \delta, q_0, F)$ automatával megadott L reguláris nyelv.

Output: "Igen", ha $L = \emptyset$, különben "Nem".

132/141

Eldöntési kérdések reguláris nyelvekre

Ürességi probléma

Algoritmus:

- (1) Számoljuk ki a q_0 -ból elérhető állapotok Q' halmazát a Q_0, Q_1, \dots állapot-halmaz-sorozat segítségével.
 - (i) Legyen $Q_0 = \{q_0\}$ és $i = 0$.
 - (ii) Legyen $Q_{i+1} = Q_i \cup \{\delta(q, a) \mid q \in Q_i \text{ és } a \in \Sigma\}$.
 - (iii) Ha $Q_i = Q_{i+1}$, akkor $Q' = Q_i$ (és stop), különben $i = i + 1$ és goto (ii).
- (2) Ha $Q' \cap F = \emptyset$, akkor a válasz "Igen", különben "Nem".

133/141

Eldöntési kérdések reguláris nyelvekre

Végtelen-e probléma

Probléma: Eldönthető-e tetszőleges L reguláris nyelv esetén, hogy L végtelen-e?

Tétel. A végtelen-e probléma reguláris nyelvekre eldönthető.

Input: Egy $M = (Q, \Sigma, \delta, q_0, F)$ automatával megadott L reguláris nyelv.

Output: "Igen", ha L végtelen, különben "Nem".

135/141

Eldöntési kérdések reguláris nyelvekre

Végtelen-e probléma

Lemma. Legyen $M = (Q, \Sigma, \delta, q_0, F)$ egy automata és legyen $k = \|Q\|$. Az $L(M)$ nyelv akkor és csak akkor végtelen, ha van olyan $x \in L(M)$, melyre $k \leq |x| < 2k$.

Bizonyítás. \Leftarrow -irány: Tfh $\exists x \in L(M)$, melyre $|x| \geq k$. Akkor a pumpáló lemma szerint $\exists x = x_1 x_2 x_3$ felbontás, melyre $0 < |x_2| \leq k$ és minden $n \geq 0$ -ra $x_1 x_2^n x_3 \in L(M)$.

Következésképpen $L(M)$ végtelen.

\Rightarrow -irány: Tfh $L(M)$ végtelen. Akkor $\exists x \in L(M)$ melyre $|x| \geq 2k$. Mivel $|x| \geq k$, a pumpáló lemma miatt $\exists x = x_1 x_2 x_3$ felbontás, melyre $0 < |x_2| \leq k$ és $x' = x_1 x_3 \in L(M)$. Ha ekkor $|x'| \geq 2k$, akkor ismételjük az eljárást x' -re addig, amíg $|x'| < 2k$ nem lesz.

134/141

Eldöntési kérdések reguláris nyelvekre

Végtelen-e probléma

Algoritmus: Legyen $k = \|Q\|$. Számoljuk ki minden $0 \leq i < 2k$ esetén a q_0 -ból az i hosszúságú szavakkal elérhető állapotok Q_i halmazát:

- (i) Ha $i = 0$ akkor $Q_i = \{q_0\}$, különben
- (ii) $Q_i = \{\delta(q, a) \mid q \in Q_{i-1} \text{ és } a \in \Sigma\}$.

Ezután minden i -re, melyre $k \leq i < 2k$, vizsgáljuk meg, hogy $Q_i \cap F \neq \emptyset$ teljesül-e. Ha valamely i -re teljesül, akkor $L(M)$ végtelen, tehát a válasz "Igen", különben a válasz "Nem".

136/141

Eldöntési kérdések reguláris nyelvekre

Tartalmazási probléma

Probléma: Eldönthető-e tetszőleges L_1, L_2 reguláris nyelvek esetén, hogy $L_1 \subseteq L_2$ teljesül-e?

Tétel. A tartalmazási probléma reguláris nyelvekre eldönthető.

Input: Az $M_1 = (Q_1, \Sigma, \delta_1, q_1, F_1)$ és $M_2 = (Q_2, \Sigma, \delta_2, q_2, F_2)$ automatákkal adott $L_1 = L(M_1)$ és $L_2 = L(M_2)$ reguláris nyelvek.

Output: "Igen", ha $L_1 \subseteq L_2$, különben "Nem".

137/141

Eldöntési kérdések reguláris nyelvekre

Ekvivalencia probléma

Probléma: Eldönthető-e tetszőleges L_1, L_2 reguláris nyelvek esetén, hogy $L_1 = L_2$ teljesül-e?

Tétel. Az ekvivalencia probléma reguláris nyelvekre eldönthető.

Input: Az $M_1 = (Q_1, \Sigma, \delta_1, q_1, F_1)$ és $M_2 = (Q_2, \Sigma, \delta_2, q_2, F_2)$ automatákkal adott $L_1 = L(M_1)$ és $L_2 = L(M_2)$ reguláris nyelvek.

Output: "Igen", ha $L_1 = L_2$, különben "Nem".

139/141

Eldöntési kérdések reguláris nyelvekre

Tartalmazási probléma

Algoritmus: Konstruáljuk meg az $M = (Q_1 \times Q_2, \Sigma, \delta, (q_1, q_2), F)$ automatát, ahol $F = F_1 \times (Q_2 - F_2)$. (Ismert, hogy ekkor $L(M) = L_1 - L_2$.) Döntsük el, hogy $L(M) = \emptyset$ teljesül-e (a reguláris nyelvek üressége eldönthető). Ha teljesül, akkor a válasz "Igen", különben a válasz "Nem".

(Az algoritmus azon a tényen alapul, hogy $L_1 \subseteq L_2$ akkor és csak akkor, ha $L_1 - L_2 = \emptyset$.) \diamond

138/141

Eldöntési kérdések reguláris nyelvekre

Ekvivalencia probléma

Algoritmus: Alkalmazzuk kétszer a tartalmazás eldöntési algoritmusát és döntsük el, hogy az $L_1 \subseteq L_2$ és az $L_2 \subseteq L_1$ tartalmazások teljesülnek-e. Ha mindkettő teljesül, akkor a válasz "Igen", különben a válasz "Nem".

(Az algoritmus azon a tényen alapul, hogy $L_1 = L_2$ akkor és csak akkor, ha $L_1 \subseteq L_2$ és $L_2 \subseteq L_1$.)

140/141

Eldöntési kérdések reguláris nyelvekre

Összefoglalás

Kérdés	Eldönthető-e?
Elem-e	igen
Ürességi	igen
Végtelen-e	igen
Tartalmazás	igen
Ekvivalencia	igen