

A szóprobléma eldöntése

Formális nyelvek, 8. gyakorlat

Célja: A szóprobléma megoldásának bemutatása a különböző Chomsky-osztályok esetén

Fogalmak: i . típusú nyelvtanok, Chomsky-normálforma, szóprobléma, elemzés, összes levezetések gráfja, szélességi bejárás, mélységi bejárás, gyakorlati megoldhatóság, CYK algoritmus, véges determinisztikus automata (VDA), az automatak megadásának lehetőségei.

Feladatok jellege: Konkrét nyelvtanra az összes levezetések gráfjának felírása, az utak és a levezetések közötti összefüggés bemutatása, a szélességi bejárás algoritmusának elkészítése struktogramként, a CYK algoritmus egy példán keresztül, utalva a műveleti igényre, automatakészítés néhány egyszerű nyelv esetében.

2005/06 II. félév

1.feladat:

$$S \rightarrow bA \mid aB$$

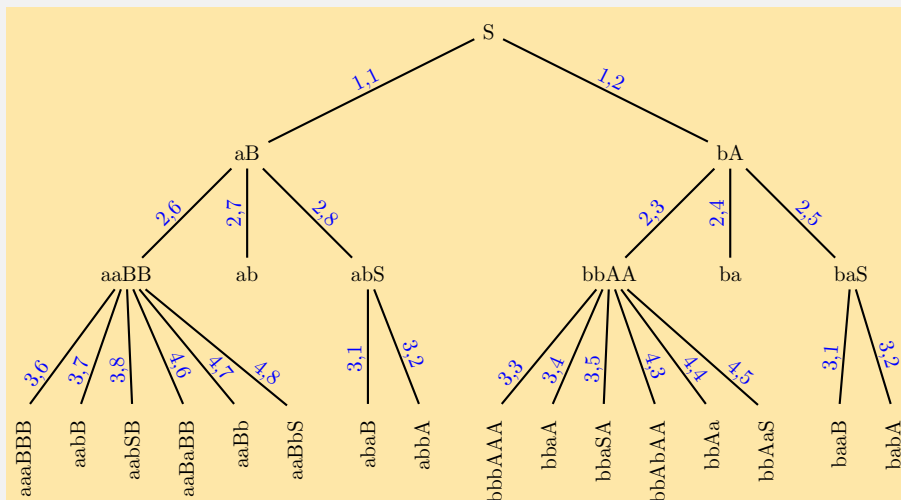
$$A \rightarrow bAA \mid a \mid aS$$

$$B \rightarrow aBB \mid b \mid bS$$

Rajzoljuk fel G összes levezetéseinek gráfjából az S által meghatározott rész első 3 szintjét!

Összes levezetések gráfja

$$S \rightarrow bA \mid aB \quad A \rightarrow bAA \mid a \mid aS \quad B \rightarrow aBB \mid b \mid bS$$



A levezethető szavakat kiíró algoritmus

Valamely $G = \langle T, N, \mathcal{P} = \{p_1 \rightarrow q_1, \dots, p_k \rightarrow q_k\}, S \rangle \in \mathcal{G}_0$ nyelvtan esetén a következő algoritmus szintfolytonosan bejárja az összes levezetések gráfjának $\alpha_0 \in (T \cup N)^*$ -ből levezethető részét és a levezethető szavakat kiírja.

Jelölések: $A h = (i, j)$ rendezett pár első, illetve második koordinátájára úgy hivatkozunk, hogy $h.1$, illetve $h.2$.

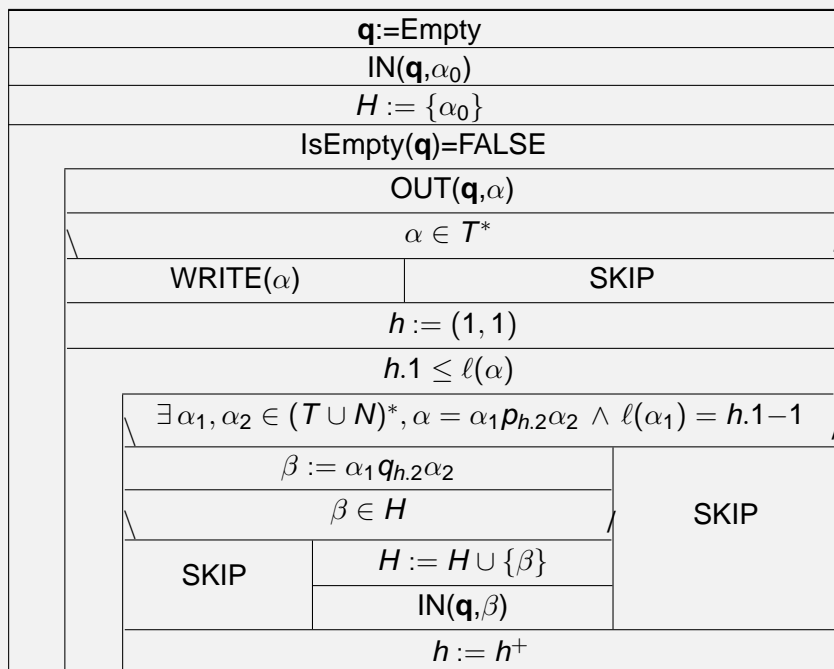
Ha $h = (h.1, h.2)$ akkor legyen h^+ a következő:

$$h^+ = \begin{cases} (h.1, h.2 + 1) & h.2 < k \\ (h.1 + 1, 1) & h.2 = k \\ \text{nem definiált} & \text{egyébként} \end{cases}$$

Az algoritmus használja a **sor** adatszerkezetet.

IN(q, x) beteszi az x elemet a q sor végére,
 OUT(q, x) kiveszi az első elemet a q sor elejéről,
 x -nek ezt az értéket adja és törli a sorból.

Empty az üres sor,
 IsEmpty(q) TRUE/FALSE attól függően, hogy a q sor üres-e.



A szóprobléma eldöntése

2.feladat:

Hogyan kell módosítani az előbbi algoritmust, ha egy adott $u \in T^*$ szórol szeretnénk eldönteni, hogy

- benne van-e $L(G)$ -ben?
- benne van-e $L(G)$ -ben, és ha igen mi egy levezetése?
- Mit kell módosítani az előbbi algoritmuson hosszúságot nem csökkentő nyelvtan esetén, ha azt akarjuk, hogy mindig termináljon?

Szóprobléma eldöntése

0. típusú nyelvtanok

Megoldás:

- IF $\alpha \in T^*$ THEN WRITE(α) helyett:
IF $\alpha = u$ THEN RETURN(Igen)
- Csinálunk egy $A[i, j]$ tömböt is, $1 \leq j \leq 4$. A tömb egy sorának típusa $(T \cup N)^* \times \mathbb{N} \times \mathbb{N} \times \mathbb{N}$ legyen. Amikor q -ba bekerül egy β elem, melyet az $\alpha = A[m, 1]$ -ből vezettünk le, akkor a legkisebb olyan h indexre melyre A még nem definiált legyen $A[h, 1] := \beta$, $A[h, 2]$ ahanyadik betűtől, $A[h, 3]$ pedig ahanyadik szabály helyettesítésével kapjuk α -ból β -t. Végül legyen $A[h, 4] := m$.

Az algoritmusunkat továbbá úgy módosítjuk, hogy ha $\alpha = u$, akkor előállítjuk a levezetést is, fordított sorrendben. Az A tömb tartalmazza azt az információt, mellyel megkapható a levezetés.

Szóprobléma eldöntése

1. típusú nyelvtanok

- Az első $f(t) := \sum_{i=0}^t |(T \cup N)|^i$ szintet bejárva, az eredeti algoritmus kiírja az összes legfeljebb t hosszú levezethető szót. Számolja a módosított algoritmusunk tehát azt, hogy hanyadik szinten járunk! A q sorba tehát először ne α_0 -t, hanem $(\alpha_0, 0)$ -t írjunk, illetve β helyett a $(\beta, t + 1)$ párt tegyük be, ha (α, t) -t vettünk ki.

Az első WHILE ciklus addig menjen csak amíg a kivett elem második koordinátája legfeljebb $f(\ell(u))$. Ha eddig nem vezettük le u -t, akkor már nem is fogjuk, álljunk le "Nem" válasszal.

CYK algoritmus

A szóprobléma eldöntése 2. típusú nyelvtanokra

Cocke-Younger-Kasami (CYK) algoritmus:

Adott egy környezetfüggetlen $G = \langle T, N, P, S \rangle$ nyelvtan Chomsky-normálformában adva.

Az algoritmus adott $u \in T^*$ esetén eldönti, hogy " $u \in L(G)$ "-e.

Legyen $u = t_1 \dots t_n$, $t_i \in T$. Jelölje α_i a $P_i \in P$ szabály bal-, β_i pedig a jobboldalát. ($\alpha_i \in N$, $\beta_i \in T \cup N^2$.)

A CYK algoritmus rekurzíven definiál $H_{i,j}$, $1 \leq i \leq j \leq n$ halmazokat ($j-i$) szerint növekvő sorrendben.

$$H_{i,i} := \{\alpha_j \mid \beta_j = t_i\}$$

$$H_{i,j} := \{\alpha_k \mid \beta_k \in \bigcup_{h=i}^{j-1} H_{i,h} H_{h+1,j}\} \quad (i < j)$$

Ha $S \in H_{1,n}$, akkor $u \in L(G)$, különben $u \notin L(G)$.

CYK algoritmus

3.feladat:

Elemezzük CYK algoritmussal az *aabbcc* szót az alábbi G nyelvtan esetén:

$S \rightarrow AB \mid BC$

$A \rightarrow XA \mid a$

$X \rightarrow a$

$C \rightarrow YC \mid c$

$Y \rightarrow c$

$B \rightarrow UV \mid VW$

$U \rightarrow XX$

$W \rightarrow YY$

$V \rightarrow ZZ$

$Z \rightarrow b$

CYK algoritmus

CYK tábla

Megoldás:

			{S}			
		{S}		{S}		
	{B}		∅		{B}	
	∅	∅	∅	∅	∅	
{A, U}	∅	{V}	∅		{C, W}	
{A, X}	{A, X}	{Z}	{Z}	{Y, C}		{Y, C}
a	a	b	b	c	c	

Tehát *aabbcc* $\in L(G)$.

Véges determinisztikus automaták

A szóprobléma eldöntése 3. típusú nyelvtanokra

Véges determinisztikus automata (VDA) alatt a következő 5-öst értjük:

$\mathcal{A} = \langle A, T, \delta, a_0, F \rangle$, ahol

- A az állapotok (véges) halmaza
- T egy ábécé, a bemenő ábécé
- $\delta : A \times T \rightarrow A$ az állapotátmeneti függvény
- $a_0 \in A$ kezdőállapot
- $F \subseteq A$ a végállapotok halmaza.

A VDA egy ütemben kiolvassa a központi egység állapotát, az input szó aktuális szimbólumát, ennek függvényében új állapotba kerül és az input szó következő betűjére áll az olvasófej (azaz, jobbra lép).

Konfiguráció (amitől a VDA további működése függ): $[a, v]$, $a \in A$, $v \in T^*$, a az aktuális állapot, v az input szó még olvasatlan része.

Az $u \in T^*$ input szóhoz tartozó **kezdőkonfiguráció**: $[a_0, u]$.

Véges determinisztikus automaták

A szóprobléma eldöntése 3. típusú nyelvtanokra

Közvetlen konfigurációátmenet: $[a, u] \xrightarrow{\mathcal{A}} [b, v]$, ha $u = tv$, és $b = \delta(a, t)$.

Közvetett konfigurációátmenet: a közvetlen konfigurációátmenet tranzitív, reflexív lezártja, jelölése: $\xrightarrow{\mathcal{A}}^*$.

$[a, v]$ **elfogadó konfiguráció:** ha $a \in F$ és $v = \varepsilon$

\mathcal{A} **elfogad** egy u szót ha az u -t végig beolvasó konfigurációátmenet elfogadó konfigurációval terminál.

VDA-k és 3. típusú nyelvtanok kölcsönösen megfeleltethetők egymásnak úgy, hogy az elfogadott nyelv illetve a generált nyelv ugyanaz lesz.


Tehát VDA-k remekül használhatók 3. típusú nyelvtanok szóproblémáinak eldöntésére.

Véges determinisztikus automaták

VDA-k megadása

3. Feladat: $T = \{a, b, c\}$. Adjunk VDA-t mely a legfeljebb 5 hosszú szavakat fogadja el!

Megoldás: I.



II.

	a	b	c
$\leftrightarrow q_0$	q_1	q_1	q_1
$\leftarrow q_1$	q_2	q_2	q_2
$\leftarrow q_2$	q_3	q_3	q_3
$\leftarrow q_3$	q_4	q_4	q_4
$\leftarrow q_4$	q_5	q_5	q_5
$\leftarrow q_5$	q_6	q_6	q_6
q_6	q_6	q_6	q_6

Házi feladat

1. Elemezzük CYK algoritmussal az 3. feladatban adott nyelvtan esetén a következő 2 szót: *aaabcc* és *abbccc*.
2. Adjunk VDA-t mely a legalább 4 hosszú szavakat fogadja el!
3. Adjunk VDA-t mely a 7-tel osztható számokat fogadja el!