

# Számítási modellek

## 2: Alapok, Grammatikák, Nyelvek

# Alapok, terminológia

- **Ábécé:** szimbólumok/betűk egy véges, nemüres halmaza.
- **Szavak** vagy **sztringek** egy  $V$  ábécé felett: Egy  $V$  ábécé elemeiből képzett véges sorozatok.
- Egy  $u = t_1 \dots t_n$  **szó hossza:**  $u$ -ban lévő betűk száma  $n$ .  
Jelölés:  $|u| = n$
- Az **üres szó**  $\varepsilon$ : a 0 hosszú szó ( $|\varepsilon| = 0$ ).
- $V^*$  : szavak halmaza  $V$  felett, amely tartalmazza az üres szót ( $\varepsilon$ ) is.
- $V^+ = V^* \setminus \{\varepsilon\}$  : nemüres szavak halmaza  $V$  felett.
  
- Példa:  
Legyen  $V = \{a,b\}$ , ekkor  $ab$  és  $baaabb$  szavak  $V$  felett.

# Alapok, terminológia

- Legyen  $V$  egy ábécé és legyenek  $u$  és  $v$   $V$  feletti szavak. Ekkor az  $uv$  szót az  $u$  és  $v$  szavak **konkatenáltjának** nevezzük. (Az  $u$  szó betűi után írjuk a  $v$  szó betűit.)
- $|uv| = |u| + |v|$ .
- Példa:  
Legyen  $V = \{a,b\}$ ,  $u = abb$  és  $v = aaab$ .  
Ekkor  $uv = abbaaab$ ,  $vu = aaababb$ .

# Alapok, terminológia

## Tulajdonságok:

- A konkatenáció asszociatív, de általában nem kommutatív.
  - ha  $u, v \in V^*$ ,  $u \neq v$ , akkor  $uv$  különbözik  $vu$  szótól, kivéve ha  $V$  egyetlen betűt tartalmaz (nem kommutatív).
  - ha  $u, v, w \in V^*$ , akkor  $u(vw) = (uv)w$  (asszociatív).
- $V^*$  **zárt** a konkatenáció műveletre (azaz bármely  $u, v \in V^*$  esetén teljesül  $uv \in V^*$ ).
- A konkatenáció egységelemes művelet, az **egységelem** az  $\varepsilon$  (azaz minden  $u \in V^*$  esetén teljesül  $u = u\varepsilon = \varepsilon u$ ).

# Alapok, terminológia

- Legyen  $i$  nemnegatív egész szám és legyen  $u$  egy  $V$  ábécé feletti szó ( $u \in V^*$ ). Az  $u$  szó  **$i$ -edik hatványa**  $u^i$  az  $u$  szó  $i$  darab példányának konkatenáltja.
- Konvenció:  $u^0 = \varepsilon$ .
  
- Példa:  
Legyen  $V = \{a,b\}$  és  $u = abb$  egy szó  $V$  felett.  
Ekkor  $u^0 = \varepsilon$ ,  $u^1 = abb$ ,  $u^2 = abbabb$ ,  $u^3 = abbabbabb$ , ...

# Alapok, terminológia

- Legyenek  $u$  és  $v$  szavak  $V$  felett. A szavak  $u$  és  $v$  **azonosak**, ha mint szimbólumsorozatok elemről-elemre megegyeznek, azaz,  $|u|=|v|$  ha minden  $i = 1, \dots, |u|$ , az  $u$  szó  $i$ -edik betűje megegyezik a  $v$  szó  $i$ -edik betűjével.
- Legyen  $V$  egy ábécé és legyenek  $u$  és  $v$  szavak  $V$  felett. Az  $u$  **részszo**  $v$ -nek, ha  $v = xuy$  teljesül valamely  $x, y \in V^*$  szavakra.
- Az  $u$  szó **valódi részszo**  $v$ -nek, ha  $x$  és  $y$  közül legalább az egyik nem üres, vagyis ha  $xy \neq \varepsilon$ .
- Ha  $x = \varepsilon$ , akkor az  $u$  szó a  $v$  szó **prefixe**.
- Ha  $y = \varepsilon$ , akkor az  $u$  szó a  $v$  szó **szuffixe**.

# Alapok, terminológia

- Példa:  
Legyen  $V = \{a,b\}$  és  $u = abb$ .
  - Az  $u$  részszavai:  $\varepsilon, a, b, ab, bb, abb$ .
  - Az  $u$  valódi részszavai:  $\varepsilon, a, b, ab, bb$ .
  - Az  $u$  prefixei:  $\varepsilon, a, ab, abb$ .
  - Az  $u$  szuffixei:  $\varepsilon, b, bb, abb$ .

# Alapok, terminológia

- Legyen  $u$  egy szó  $V$  felett. Az  $u$  szó **tükörképe** vagy **fordítottja** az a  $u^{-1}$  szó, amelyet úgy kapunk, hogy  $u$  szimbólumait fordított sorrendben írjuk le.
- Legyen  $u = a_1 \dots a_n$ ,  $a_i \in V$ ,  $1 \leq i \leq n$ . Ekkor  $u^{-1} = a_n \dots a_1$ .
- $(u^{-1})^{-1} = u$ .
- $(u^{-1})^i = (u^i)^{-1}$  teljesül,  $i = 1, 2, \dots$
- Példa:  
Legyen  $V = \{a,b\}$ ,  $u = abba$  és  $v = aabbba$   
Ekkor  $u^{-1} = abba$  (palindrom) és  $v^{-1} = abbbaa$ .



# Alapok, terminológia

- Legyen  $V$  egy ábécé és  $L$  egy tetszőleges részhalmaza  $V^*$ -nek. Ekkor  $L$ -t egy  $V$  feletti nyelvnek nevezzük.
- Az **üres nyelv** (egy olyan nyelv, amely nem tartalmaz egyetlen szót sem) jelölése  $\emptyset$ .
- Egy  $V$  ábécé feletti  $L$  nyelv **véges nyelv**, ha véges számú szót tartalmaz, egyébként **végtelen**.
- Példa:  
Legyen  $V = \{a, b\}$  egy ábécé.  
 $L_1 = \{a, b, \varepsilon\}$ .  
 $L_2 = \{a^i b^j \mid i \geq 0\}$ .  
 $L_3 = \{uu^{-1} \mid u \in V^*\}$ .  
 $L_4 = \{(a^n)^2 \mid n \geq 1\}$ .  
 $L_5 = \{u \mid u \in \{a, b\}^+, N_a(u) = N_b(u)\}$ , ahol  $N_a(u)$  és  $N_b(u)$  az  $a$  és a  $b$  szimbólumok  $u$ -beli előfordulásainak számát jelöli.

$L_1$  egy véges nyelv, a többi végtelen.

# Alapok, terminológia

- Egy **generatív grammatika**  $G$  egy  $(N, T, P, S)$  4-es, ahol
  - $N$  és  $T$  diszjunkt véges ábécék (azaz  $N \cap T = \emptyset$ ).
  - $N$  elemeit **nemterminális** szimbólumoknak nevezzük
  - $T$  elemeit **terminális** szimbólumoknak nevezzük.
  - $S \in N$  a **kezdő szimbólum** (axióma).
  - $P$  rendezett  $(x,y)$  párok véges halmaza, ahol  $x,y \in (N \cup T)^*$  és  $x$  legalább egy nemterminális szimbólumot tartalmaz.
  - $P$  elemeit **átírási szabályoknak** (produkciós **szabályoknak**) vagy röviden **szabályoknak** nevezik.  $x \rightarrow y$  használható  $(x,y)$  helyett, ahol  $\rightarrow \notin (N \cup T)$ .

# Alapok, terminológia

- Példa:
  - $G_1 = (\{S, A, B\}, \{a, b, c\}, \{S \rightarrow c, S \rightarrow AB, A \rightarrow aA, B \rightarrow \varepsilon, abb \rightarrow aSb\}, S)$  nem generatív grammatika.
  - $G_2 = (\{S, A, B, C\}, \{a, b, c\}, \{S \rightarrow a, S \rightarrow AB, A \rightarrow Ab, B \rightarrow \varepsilon, aCA \rightarrow aSc\}, S)$  generatív grammatika.

# Alapok, terminológia

- Legyen  $G = (N, T, P, S)$  egy generatív grammatika és  $u, v \in (N \cup T)^*$ .  
A  $v$  szó **közvetlenül** vagy **egy lépésben levezethető** az  $u$  szóból  $G$ -ben, ha  $u = u_1xu_2$  és  $v = u_1yu_2$ , ahol  $u_1, u_2 \in (N \cup T)^*$  és  $x \rightarrow y \in P$ .  
Jelölés:  $u \Rightarrow_G v$ .
- Legyen  $G = (N, T, P, S)$  egy generatív grammatika és  $u, v \in (N \cup T)^*$ .  
A  $v$  szó **levezethető** az  $u$  szóból  $G$ -ben, jelölés  $u \Rightarrow_G^* v$ ,
  - ha  $u = v$ , vagy
  - van olyan szó  $z \in (N \cup T)^*$ , amelyre  $u \Rightarrow_G^* z$  és  $z \Rightarrow_G v$ .
  - $\Rightarrow^*$  a  $\Rightarrow$  reflexív és tranzitív lezártja.
  - $\Rightarrow^+$  a  $\Rightarrow$  tranzitív lezártja.

# Alapok, terminológia

- Legyen  $G = (N, T, P, S)$  egy generatív grammatika és  $u, v \in (N \cup T)^*$ .  
A  $v$  szó  **$k$  lépésben levezethető**  $u$  szóból  $G$ -ben,  $k \geq 1$ , ha van olyan szavakból álló sorozat  $u_1, \dots, u_{k+1} \in (N \cup T)^*$ , amelyre  $u = u_1$ ,  $v = u_{k+1}$ , és  $u_i \Rightarrow_G u_{i+1}$ ,  $1 \leq i \leq k$ .
- A  $v$  szó **levezethető**  $u$  szóból  $G$ -ben, ha
  - vagy  $u = v$ ,
  - vagy van olyan  $k \geq 1$  szám, amelyre  $v$  levezethető  $u$ -ból  $k$  lépésben.

# Alapok, terminológia

- Legyen  $G = (N, T, P, S)$  egy generatív grammatika.  
A  $G$  által **generált nyelv**  $L(G)$ :  
$$L(G) = \{W \mid S \Rightarrow_G^* W, W \in T^*\}$$
- Azaz,  $L(G)$  olyan szavakból áll, amelyek levezethetők  $S$ -ből és  $T^*$ -beliek.

# Alapok, terminológia

- Példa:

Legyen  $G = (N, T, P, S)$  egy generatív grammatika, ahol

$N = \{S, A, B\}$ ,  $T = \{a, b\}$ ,

$P = \{S \rightarrow aSb, S \rightarrow ab, S \rightarrow ba\}$ .

Ekkor  $L(G) = \{a^nabb^n, a^nbab^n \mid n \geq 0\}$ .

- Példa:

Legyen  $G = (N, T, P, S)$  egy generatív grammatika, ahol

$N = \{S, X, Y\}$ ,  $T = \{a, b, c\}$ ,

$P = \{S \rightarrow abc, S \rightarrow aXbc, Xb \rightarrow bX, Xc \rightarrow Ybcc, bY \rightarrow Yb, aY \rightarrow aaX, aY \rightarrow aa\}$ .

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

# Alapok, terminológia

- Minden grammatika generál egy nyelvet, de ugyanaz a nyelv több különböző grammatika által is generálható.
- Két grammatika **ekvivalens**, ha ugyanazt a nyelvet generálják.
- Két nyelv **gyengén ekvivalens**, ha legfeljebb az üres szóban különböznek.



# Chomsky hierarchia

- Legyen  $G = (N, T, P, S)$  egy generatív grammatika.  
A  $G$  grammatika  $i$ -típusú,  $i = 0, 1, 2, 3$ , ha  $P$  szabályhalmazra a következők teljesülnek:
  - $i = 0$ : nincs korlátozás.
  - $i = 1$ :  $P$  minden szabálya  $u_1Au_2 \rightarrow u_1vu_2$  alakú, ahol  $u_1, u_2, v \in (N \cup T)^*$ ,  $A \in N$ , és  $v \neq \varepsilon$ , kivéve a  $S \rightarrow \varepsilon$  szabályt, ha létezik ilyen szabály  $P$ -ben.  
Ha  $P$  tartalmazza az  $S \rightarrow \varepsilon$  szabályt, akkor  $S$  nem fordul elő egyetlen szabály jobb oldalán sem.
  - $i = 2$ :  $P$  minden szabálya  $A \rightarrow v$  alakú, ahol  $A \in N$  és  $v \in (N \cup T)^*$ .
  - $i = 3$ :  $P$  minden szabálya vagy  $A \rightarrow uB$  vagy  $A \rightarrow u$  alakú, ahol  $A, B \in N$  és  $u \in T^*$ .

# Chomsky hierarchia

- Egy  $L$  nyelv  $i$ -típusú,  $i = 0, 1, 2, 3$ , ha  $i$ -típusú grammatikával generálható.
- $\mathcal{L}_i$ ,  $i = 0, 1, 2, 3$ , jelöli az  $i$ -típusú nyelvek osztályát (családját).

# Chomsky hierarchia

- 0-típusú grammatikákat **mondatszerkezetű (phrase-structured)** grammatikáknak is nevezzük.
- 1-típusú grammatikák a **környezetfüggő (context-sensitive)** grammatikák. Egy  $A$  nemterminális valamely előfordulása  $v$  szóval csak  $u_1$  és  $u_2$  kontextus jelenlétében helyettesíthető.
- 2-típusú grammatikákat **környezetfüggetlen (context-free)** grammatikáknak nevezzük. Egy  $A$  nemterminális  $v$ -vel való helyettesítése bármely kontextusban megengedett.
- 3-típusú grammatikákat **reguláris (regular)** vagy **véges állapotú (finite state)** grammatikáknak hívjuk, a véges állapotú automatákkal való kapcsolatuk miatt.
- A 0,1,2,3-típusú nyelvek osztályait rendre **rekurzívan felsorolható, környezetfüggő, környezetfüggetlen**, valamint **reguláris nyelvosztálynak** nevezzük.

# Chomsky hierarchia

Nyelvészeti háttér

”The cunning fox hastily ate the leaping frog.”

- $S \rightarrow A + B$  ( $S$ : sentence,  $A$ : noun phrase,  $B$ : verb phrase)
- $A \rightarrow C + D + E$  ( $C$ : article,  $D$ : adjective,  $E$ : noun)
- $B \rightarrow G + B$  ( $G$ : adverb)
- $B \rightarrow F + A$  ( $F$ : verb)
- $C \rightarrow$  the
- $D \rightarrow$  cunning
- $E \rightarrow$  fox
- $G \rightarrow$  hastily
- $F \rightarrow$  ate
- $D \rightarrow$  leaping
- $E \rightarrow$  frog

# Chomsky hierarchia

## Nyelvészeti háttér

- + (space)
- cunning – leaping , fox – frog (felcserélhető, de más lesz a jelentés)
- szintaktikailag helyes mondat

# Chomsky hierarchia

- Nyilvánvaló, hogy  $\mathcal{L}_3 \subseteq \mathcal{L}_2 \subseteq \mathcal{L}_0$  and  $\mathcal{L}_1 \subseteq \mathcal{L}_0$ .
- Megmutatható, hogy a következő is fennáll (Chomsky hierarchia):  
 $\mathcal{L}_3 \subset \mathcal{L}_2 \subset \mathcal{L}_1 \subset \mathcal{L}_0$ .
- Az  $\mathcal{L}_2$  és  $\mathcal{L}_1$  nyelvosztály közötti tartalmazási reláció nem látható azonnal a grammatikák definíciójából.
- Szintén  $\mathcal{L}_1$ -et generálják az u.n. hossznemcsökkentő grammatikák. Ezek  $p \rightarrow q$  szabályaira  $|p| \leq |q|$  teljesül, kivéve az  $S \rightarrow \varepsilon$  alakú szabályt, feltéve, hogy  $P$ -ben létezik ilyen szabály. Ha  $S \rightarrow \varepsilon \in P$ , akkor  $S$  nem fordul elő  $P$  egyetlen szabályának jobb oldalán sem.

# Nyelvekre vonatkozó műveletek

- Legyen  $V$  egy ábécé és legyenek  $L_1, L_2$  nyelvek  $V$  felett (azaz,  $L_1 \subseteq V^*, L_2 \subseteq V^*$ )
  - **unió:**  $L_1 \cup L_2 = \{u \mid u \in L_1 \text{ vagy } u \in L_2\}$ .
  - **metszet:**  $L_1 \cap L_2 = \{u \mid u \in L_1 \text{ és } u \in L_2\}$ .
  - **különbség:**  $L_1 - L_2 = \{u \mid u \in L_1 \text{ és } u \notin L_2\}$ .
- Példa:  
Legyen  $V = \{a,b\}$  egy ábécé és  $L_1 = \{a,b\}$  és  $L_2 = \{\varepsilon, a, bbb\}$  nyelvek  $V$  felett. Ekkor
  - $L_1 \cup L_2 = \{\varepsilon, a, b, bbb\}$
  - $L_1 \cap L_2 = \{a\}$
  - $L_1 - L_2 = \{b\}$

# Nyelvekre vonatkozó műveletek

- Az  $L \subseteq V^*$  nyelv **komplementere** a  $V$ -re az  $\bar{L} = V^* - L$  nyelv.
- Példa:  
Legyen  $V = \{a\}$  egy ábécé és legyen  $L = \{a^{4n} \mid n \geq 0\}$ .  
Ekkor  $\bar{L} = V^* - \{a^{4n} \mid n \geq 0\}$ .



# Nyelvekre vonatkozó műveletek

- Legyen  $V$  egy ábécé és  $L_1, L_2$  nyelvek  $V$  felett (azaz,  $L_1 \subseteq V^*, L_2 \subseteq V^*$ ).  $L_1$  és  $L_2$  **konkatenációja**  $L_1L_2 = \{u_1u_2 \mid u_1 \in L_1, u_2 \in L_2\}$ .
- Megjegyzés:  
A következő egyenlőségek minden  $L$  nyelvre érvényesek:
  - $\emptyset L = L \emptyset = \emptyset$  és
  - $\{\varepsilon\}L = L\{\varepsilon\} = L$ .

# Nyelvekre vonatkozó műveletek

- $L^i$  jelöli az  $L$  nyelv  **$i$ -edik iterációját** (a konkatenáció műveletre nézve), ahol  $i \geq 1$ . Konvenció:  $L^0 = \{\varepsilon\}$ .
- Az  $L$  nyelv **iteratív lezártja** (vagy **Kleene lezártja**):  
 $L^* = \bigcup_{i \geq 0} L^i$ .
- $L$  **pozitív lezártja**:  $L^+ = \bigcup_{i \geq 1} L^i$ .
  
- Megjegyzés:  
Ha  $\varepsilon \in L$ , akkor  $L^+ = L^*$ . Máskülönben,  $L^+ = L^* - \{\varepsilon\}$ .

# Nyelvekre vonatkozó műveletek

- Példa (konkatenáció):  
Legyen  $V = \{a, b\}$  és  $L_1 = \{a, b\}$ ,  $L_2 = \{\varepsilon, a, bbb\}$ ,  
 $L_3 = \{a^{4n}b^{4n} \mid n \geq 0\}$  és  $L_4 = \{a^{7n}b^{7n} \mid n \geq 0\}$ . Ekkor
  - $L_1L_2 = \{a, b, aa, ba, abbb, bbbb\}$ ,
  - $L_3L_4 = \{a^{4n}b^{4n}a^{7m}b^{7m} \mid n \geq 0, m \geq 0\}$ .

# Nyelvekre vonatkozó műveletek

- Legyen  $V$  egy ábécé és  $L \subseteq V^*$ . Ekkor az  $L$  nyelv **tükörképe** (vagy **fordítottja**)  $L^{-1} = \{u^{-1} \mid u \in L\}$ .
- Megjegyzések:
  - $(L^{-1})^{-1} = L$ ,
  - $(L_1L_2 \dots L_n)^{-1} = L_n^{-1} \dots L_2^{-1}L_1^{-1}$ ,
  - $(L^i)^{-1} = (L^{-1})^i$ , ahol  $i \geq 0$ ,
  - $(L^*)^{-1} = (L^{-1})^*$ .

# Nyelvekre vonatkozó műveletek

- Példa (tükör, fordított):  
Legyen  $V = \{a,b\}$  és  $L = \{\varepsilon, a, abb\}$  egy nyelv  $V$  felett. Ekkor  $L^{-1} = \{\varepsilon, a, bba\}$ .

# Nyelvekre vonatkozó műveletek

- Egy  $L \subseteq V^*$  nyelv **prefix nyelve**  
 $\text{PRE}(L) = \{ u \mid u \in V^*, uv \in L \text{ valamely } v \in V^*\text{-re} \}$ .
- Megjegyzés:  
Definíció szerint,  $L \subseteq \text{PRE}(L)$  minden  $L \in V^*$  nyelvre.
- Egy  $L \subseteq V^*$  nyelv **szuffix nyelve**  
 $\text{SUF}(L) = \{ u \mid u \in V^*, vu \in L \text{ valamely } v \in V^*\text{-re} \}$ .

# Nyelvekre vonatkozó műveletek

- Legyen  $V_1$  és  $V_2$  két ábécé. A  $h : V_1^* \rightarrow V_2^*$  leképezést **homomorfizmusnak** nevezzük, ha a következő feltételek teljesülnek:
  - minden  $u \in V_1^*$  szóra pontosan egy  $v \in V_2^*$  szó létezik, amelyre  $h(u) = v$ .
  - $h(uv) = h(u)h(v)$ , minden  $u, v \in V_1^*$ -ra.
- Megjegyzések:
  - A fenti feltételekből következik, hogy  $h(\varepsilon) = \varepsilon$ .  
Valamint, minden  $u \in V_1^*$ -ra  $h(u) = h(\varepsilon u) = h(u\varepsilon)$ .
  - Minden  $u = a_1 a_2 \dots a_n$ ,  $a_i \in V_1$ ,  $1 \leq i \leq n$ , szóra teljesül, hogy  $h(u) = h(a_1)h(a_2) \dots h(a_n)$ .  
Ez azt jelenti, hogy elegendő a  $h$  leképezést  $V_1$  elemeire megadni, ez automatikusan kiterjesztődik  $V_1^*$ -ra.

# Nyelvekre vonatkozó műveletek

- Egy homomorfizmus  $h : V_1^* \rightarrow V_2^*$   **$\varepsilon$ -mentes** ha minden  $u \in V_1^+$ -ra  $h(u) \neq \varepsilon$ .
- Legyen  $h : V_1^* \rightarrow V_2^*$  egy homomorfizmus.  
Egy  $L \subseteq V_1^*$  nyelv  **$h$ -homomorf képe** a következő nyelv:  
$$h(L) = \{w \in V_2^* \mid w = h(u), u \in L\}$$
- Példa (homomorfizmus):  
Legyen  $V_1 = V_2 = \{a,b\}$  két ábécé. Legyen  $h : V_1^* \rightarrow V_2^*$  egy homomorfizmus, ahol  $h(a) = bbb$ ,  $h(b) = ab$  és  $L = \{a, abba\}$ .  
Ekkor  $h(L) = \{bbb, bbbababbbb\}$ .



# Nyelvekre vonatkozó műveletek

- Egy  $h$  homomorfizmus egy **izomorfizmus**, ha teljesül:  
 $\forall u, v \in V_1^*$ : ha  $h(u) = h(v)$ , akkor  $u = v$ .
- Példa (izomorfizmus, decimális számok bináris reprezentációja):  
 $V_1 = \{0, 1, 2, \dots, 9\}$ ,  $V_2 = \{0, 1\}$ ,  
 $h(0) = 0000$ ,  $h(1) = 0001$ ,  $\dots$ ,  $h(9) = 1001$

# Irodalom

- Handbook of Formal Languages, G. Rozenberg, A. Salomaa, (eds.), Springer–Verlag, Berlin–Heidelberg, 1997.
- Gy. E. Révész, Introduction to Formal Languages, Dover Publications, Inc., New York, 2012.