

2.8 Säännöllisten kielten rajoituksista

Kardinaliteettisistä on oltava olemassa (paljon) ei-säännöllisiä kieliä: kieliä on ylinumerointuva määrä, säännöllisiä lausekkeita vain numeroituvasti.

Voidaan löytää konkreettinen, *mielenkiintoisen* esimerkki kielestä, joka ei olisi säännöllinen? Helposti.


Säännöllisten kielten perusrajoitus: äärellisillä automaateilla on vain rajallinen "muisti". Siten ne eivät pysty ratkaisemaan ongelmia, joissa vaaditaan mielivaltaisen suurten lukujen tarkkaa muistamista.

Esimerkki: sulkulausekekieli

$$L_{\text{match}} = \{()^k \mid k \geq 0\}.$$

Formalisointi: "pumppauslemma".


114




115

Lemma 2.6 (Pumppauslemma) Olkoon A säännöllinen kieli. Tällöin on olemassa sellainen $n \geq 1$, että mikä tahansa $x \in A$, $|x| \geq n$, voidaan jakaa osiin $x = uvw$ siten, että $|uv| \leq n$, $|v| \geq 1$, ja $uv^i w \in A$ kaikilla $i = 0, 1, 2, \dots$

Todistus. Olkoon M jokin A :n tunnistava deterministinen äärellinen automaatti, ja olkoon n M :n tilojen määrä. Tarkastellaan M :n läpi-käymä tiloja syötteellä $x \in A$, $|x| \geq n$. Koska M jokaisella x :n merkillä siirtyy tilasta toiseen, sen tätyy kulkea jonkin tilan kautta (ainakin) kaksi kertaa — itse asiassa jo x :n n :n ensimmäisen merkin aikana. Olkoon q ensimmäinen toistettu tila.



Esimerkki. Tarkastellaan em. sulkulausekekieltä (merk. '(' = a , ')' = b):



$$L = L_{\text{match}} = \{a^k b^k \mid k \geq 0\}.$$

Oletetaan, että L olisi säännöllinen. Tällöin pitäisi pumppausleman mukaan olla jokin $n \geq 1$, jota pitempiä L :n merkkijonoja voidaan pumpata. Valitaan $x = a^n b^n$, jolloin $|x| = 2n > n$. Lemman mukaan x voidaan jakaa pumpattavaksi osiin $x = uvw$, $|uv| \leq n$, $|v| \geq 1$; siis on oltava

$$u = a^i, v = a^j, w = a^{n-(i+j)} b^n, \quad i \leq n-1, j \geq 1.$$

Mutta esimerkiksi "0-kertaisesti" pumpattaessa:

$$uv^0 w = a^i a^{n-(i+j)} b^n = a^{n-j} b^n \notin L.$$

Siten L ei voi olla säännöllinen.

116

117

3. KIELIOPIT JA MERKKIJONOJEN TUOTAMINEN

Kielioffi = muunnossysteemi merkkijonojen (kielen "sanojen") tuottamiseen tietystä lähtöjonoista alkaen, osajonoja toistuvasti annettujen sääntöjen mukaan uudelleenkirjoittamalla.

Kielioffi on *yhteydetön*, jos kussakin uudelleenkirjoitusaskelessa korvataan yksi erityinen muuttuja- t. *välikesimboldi* jollakin siihen liitettyllä korvausjonolla, ja korvaus voidaan aiina tehdä symbolia ympäröivän merkkijonon rakenteesta riippumatta.

Sovelluksia: rakenteisten tekstien kuvaaminen (esim. ohjelmointikielten BNF-syntaksikuvaukset, XML:n DTD/Schema-määrittelyt), yleisemmin rakenteisten "olioiden" kuvaaminen (esim. syntaktinen hahmontunnistus).

118

Yhteydettömillä kieliopeilla voidaan kuvata (tuottaa) myös ei-säännöllisiä kieliä.

Esimerkki: yhteydetön kielioffi kielelle L_{match} (lähtösymboli S):

- (i) $S \rightarrow \epsilon$,
- (ii) $S \rightarrow (S)$.

Esimerkiksi merkkijonon ((()) tuottaminen:

$$S \Rightarrow (S) \Rightarrow ((S)) \Rightarrow (((S))) \Rightarrow (((\epsilon))) = ((())).$$

119

Määritelmä 3.1 Yhteydetön kielioffi on neilikko

$$G = (V, \Sigma, P, S),$$

missä

- V on kielion aakkosto;
- $\Sigma \subseteq V$ on kielion päätemerkkien joukko; sen komplementti $N = V - \Sigma$ on kielion välkemerkkien t. -symbolien joukko;
- $P \subseteq N \times V^*$ on kielion sääntöjen t. produktoiden joukko;
- $S \in N$ on kielion lähtösymboli.

Toinen esimerkki: kielioffi C-tyypisen ohjelmointikielen aritmeettisille lausekkeille (yksinkertaistettu).

$$\begin{array}{lcl} E & \rightarrow & T \quad | \quad E + T \\ T & \rightarrow & F \quad | \quad T * F \\ F & \rightarrow & a \quad | \quad (E). \end{array}$$

Esimerkiksi lausekkeen $(a+a)*a$ tuottaminen:

$$\begin{array}{lcl} E & \Rightarrow & T \\ & \Rightarrow & (\underline{E}) * F \\ & \Rightarrow & (\underline{(E)} + T) * F \\ & \Rightarrow & (\underline{(E+T)}) * F \\ & \Rightarrow & (a + \underline{T}) * F \\ & \Rightarrow & (a + \underline{(E)}) * F \\ & \Rightarrow & (a + a) * F \\ & \Rightarrow & (a + a) * a. \end{array}$$

120

Produktiota $(A, \omega) \in P$ merkitään tavallisesti $A \rightarrow \omega$.

121

Merkkijono $\gamma \in V^*$ tuottaa t. johtaa suoraan merkkijonon $\gamma' \in V^*$ kielipissa G , merkitään

$$\gamma \xrightarrow{G} \gamma'$$

jos voidaan kirjoittaa $\gamma = \alpha A \beta$, $\gamma' = \alpha \omega \beta$ ($\alpha, \beta, \omega \in V^*$, $A \in N$), ja kielipissa G on produktio $A \rightarrow \omega$.

Jos kielippi G on yhteydestä selvä, merkitään yksinkertaisesti $\gamma \Rightarrow \gamma'$.

Merkkijono $\gamma \in V^*$ tuottaa t. johtaa merkkijonon $\gamma' \in V^*$ kielipissa G , merkitään

$$\gamma \xrightarrow{G}^* \gamma'$$

jos on olemassa jono V :n merkkijonoja $\gamma_0, \gamma_1, \dots, \gamma_n$ ($n \geq 0$), siten että

$$\gamma = \gamma_0 \xrightarrow{G} \gamma_1 \xrightarrow{G} \dots \xrightarrow{G} \gamma_n = \gamma'.$$

Erikoistapauksena $n = 0$ saadaan $\gamma \xrightarrow{G}^* \gamma$ millä tahansa $\gamma \in V^*$. Jälleen, jos G on yhteydestä selvä, merkitään yksinkertaisesti $\gamma \Rightarrow^* \gamma'$.

122

Merkkijono $\gamma \in V^*$ on kielipin G lausejohdos, jos on $S \xrightarrow{G}^* \gamma$.

Pelkästään päätemerkeistä koostuva G :n lausejohdos $x \in \Sigma^*$ on G :n lause.

Kielipin G tuottama t. kuvaama kieli koostuu G :n lauseista:

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

Formaali kieli $L \subseteq \Sigma^*$ on yhteydetön, jos se voidaan tuottaa jollakin yhteydettömällä kielipilla.

123

Esimerkiksi tasapainoisten sulkujonojen muodostaman kielen $L_{\text{match}} = \{(^k)^k \mid k \geq 0\}$ tuottaa kielippi

$$G_{\text{match}} = (\{S, (,)\}, \{(,)\}, \{S \rightarrow \varepsilon, S \rightarrow (S)\}, S).$$

Yksinkertaisten aritmeettisten lausekkeiden muodostaman kielen L_{expr} tuottaa kielippi

$$G_{\text{expr}} = (V, \Sigma, P, E),$$

missä

$$\begin{aligned} V &= \{E, T, F, a, +, *, (,)\}, \\ \Sigma &= \{a, +, *, (,)\}, \\ P &= \{E \rightarrow T, E \rightarrow E + E, E \rightarrow E * E, E \rightarrow a, E \rightarrow (E)\}, \\ F &\rightarrow a, F \rightarrow (E)\}. \end{aligned}$$

Toinen kielippi kielen L_{expr} tuottamiseen on

$$G'_{\text{expr}} = (V, \Sigma, P, E),$$

missä

$$\begin{aligned} V &= \{E, a, +, *, (,)\}, \\ \Sigma &= \{a, +, *, (,)\}, \\ P &= \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow a, E \rightarrow (E)\}. \end{aligned}$$

Huom: Vaikka kielippi G'_{expr} näyttää yksinkertaisemmalta kuin kielippi G_{expr} , sen ongelmana on ns. rakenteellinen moniselitteisyys, mikä on monesti ei-toivottu ominaisuus.

124

125

Produktiot, joilla on yhteinen vasen puoli A , voidaan kirjoittaa yhteen: joukon

$$A \rightarrow \omega_1, A \rightarrow \omega_2, \dots A \rightarrow \omega_k$$

sijaan kirjoitetaan

$$A \rightarrow \omega_1 | \omega_2 | \dots | \omega_k.$$

Kielioppi esitetään usein pelkkänä sääntöjoukkona:

$$\begin{array}{l} A_1 \rightarrow \omega_{11} | \dots | \omega_{1k_1} \\ A_2 \rightarrow \omega_{21} | \dots | \omega_{2k_2} \\ \vdots \\ A_m \rightarrow \omega_{m1} | \dots | \omega_{mk_m}. \end{array}$$

Tällöin päätellään välikesymboleita edellisten merkintäsopimusten mukaan tai siitä, että ne esiintyvät sääntöjen vasempina puolina; muut esiintyvät merkit ovat päätemerkkejä. *Lähtösymboli* on tällöin *ensimmäisen säännön vasempa-na puolena* esiintyvä välike; tässä siis A_1 .

Vakiintuneita merkintätapoja

Välikesymboleita: A, B, C, \dots, S, T .

Päätemerkkejä: kirjaimet a, b, c, \dots, s, t ; numerot $0, 1, \dots, 9$; erikoismerkit; lihavoidut tai alleviivatut varatut sanat (**if**, **for**, **end**, \dots).

Mielivaltaisia merkkejä (kun välikkeitä ja pääteitä ei erotella): X, Y, Z .

Päätemerkkijonoja: u, v, w, x, y, z .

Sekamerkkijonoja: $\alpha, \beta, \gamma, \dots, \omega$.

126

127

Eräitä konstruktioita

Olkoon $L(T)$ välikkeestä T johdettavissa olevien päätejonojen joukko. Olkoon meillä produktiokokoelma P , jossa ei esiinny välikettä A , ja jolla B :stä voidaan johtaa $L(B)$ (ja vastaavasti C :stä $L(C)$).

Lisäämällä P :hen produktio saadaan:

$A \rightarrow B | C$: yhdiste $L(A) = L(B) \cup L(C)$,

$A \rightarrow BC$: katenaatio $L(A) = L(B)L(C)$, ja

$A \rightarrow AB | \epsilon$ (vasen rekursio) tai

$A \rightarrow BA | \epsilon$ (oikea rekursio):

Kleenin sulkeuma $L(A) = L(B)^*$.

Välikkeiden keskeisupotus on yhteydettömille kieliopeille ominainen konstruktio: lisäämällä $A \rightarrow BAC | \epsilon$ saadaan

$$L(A) = \bigcup_{i=0}^{\infty} L(B)^i L(C)^i.$$

Keskeisupotus tekee usein (muttei aina) kielessä epäsäännöllisen.

3.2 Säännölliset kielet ja yhteydettömät kieliopit

Yhteydettömillä kieliopeilla voidaan siis kuvata joitakin ei-säännöllisiä kielitä (esimerkiksi kielet L_{match} ja L_{expr}). Osoitetaan, että myös kaikki säännölliset kielet voidaan kuvata yhteydettömillä kieliopeilla. Yhteydettömät kielet ovat siten säännollisten kielten aito yliluokka.

Yhteydetön kielioppi on *oikealle lineaarinen*, jos sen kaikki produktiot ovat muotoa $A \rightarrow aB$ tai $A \rightarrow \epsilon$, ja *vasemmalle lineaarinen*, jos sen kaikki produktiot ovat muotoa $A \rightarrow Ba$ tai $A \rightarrow \epsilon$.

Osoittautuu, että sekä vasemmalle että oikealle lineaarisilla kieliopeilla voidaan tuottaa täsmälleen säännölliset kielet, minkä takia näitä kieliopeja nimitetään myös yhteisesti *säännöllisiksi*. Todistetaan tässä väite vain oikealle lineaarisille kieliopeille.

128

129

Lause 3.1 Jokainen säännöllinen kieli voidaan tuottaa oikealle lineaarisella kielipilla.

Todistus. Olkoon L aakkoston Σ säännöllinen kieli, ja olkoon $M = (Q, \Sigma, \delta, q_0, F)$ sen tunnistava (deterministinen tai epä deterministinen) äärellinen automaatti. Muodostetaan kielippi G_M , jolla on $L(G_M) = L(M) = L$.

Kielipin G_M pääteaakkosto on sama kuin M :n syöteaakkosto Σ , ja sen välikeaakkostoon otetaan yksi välike A_q kutakin M :n tilaa q kohden. Kielipin lähtösymboli on A_{q_0} , ja sen produktoit vastaavat M :n siirtymiä:

- (i) kutakin M :n lopputilaa $q \in F$ kohden kielipiin otetaan produktio $A_q \rightarrow \varepsilon$;
- (ii) kutakin M :n siirtymää $q \xrightarrow{a} q'$ (so. $q' \in \delta(q, a)$) kohden kielipiin otetaan produktio $A_q \rightarrow aA_{q'}$.

130

Konstruktion oikeellisuuden tarkastamiseksi merkitään välikkeestä A_q tuotettavien päätejonojen joukkoa

$$L(A_q) = \{x \in \Sigma^* \mid A_q \xrightarrow{G_M} x\}.$$

Induktiolla merkkijonon x pituuden suhteen voidaan osoittaa, että kaikilla q on

$$x \in L(A_q) \text{ joss } (q, x) \vdash_M^*(q_f, \varepsilon) \text{ jollakin } q_f \in F.$$

Erityisesti on siis

$$\begin{aligned} L(G_M) &= L(A_{q_0}) = \{x \in \Sigma^* \mid (q_0, x) \vdash_M^*(q_f, \varepsilon) \\ &\quad \text{jollakin } q_f \in F\} \\ &= L(M) = L. \quad \square \end{aligned}$$

131

Lause 3.2 Jokainen oikealle lineaarisella kielipilla tuottettava kieli on säännöllinen.

Todistus. Olkoon $G = (V, \Sigma, P, S)$ oikealle lineaarinen kielippi. Muodostetaan kielessä $L(G)$ tunnistava epä deterministinen äärellinen automaatti $M_G = (Q, \Sigma, \delta, q_S, F)$ seuraavasti:

M_G :n tilat vastaavat G :n välikkeitä:


$$Q = \{q_A \mid A \in V - \Sigma\}.$$

M_G :n alkutila on lähtösymbolia S vastaava tila q_S .

M_G :n syöteaakkosto on G :n pääteaakkosto Σ .

M_G :n siirtymäfunktio δ jäljittelee G :n produktoita siten, että kutakin produktiota $A \rightarrow aB$ kohden automaatissa on siirtymä $q_A \xrightarrow{a} q_B$ (so. $q_B \in \delta(q_A, a)$).

Esimerkki. Automaatti:



Vastaava kielippi:

$$\begin{aligned} A_1 &\rightarrow aA_1 \mid bA_1 \mid bA_2 \\ A_2 &\rightarrow \varepsilon \mid bA_2. \end{aligned}$$

132

133

M_G :n lopputiloja ovat ne tilat, joita vastaaviin välikkeisiin liittyy G :ssä ε -produktio:

$$F = \{q_A \in Q \mid A \rightarrow \varepsilon \in P\}.$$

Konstruktion oikeellisuus voidaan jälleen tar-
kastaa induktiolla G :n tuottamien ja M_G :n hy-
väksymien merkkijonojen pituuden suhteen. \square