2.6 SÄÄNNÖLLISET LAUSEKKEET

Automaattimalleista poikkeava tapa kuvata yksinkertaisia kieliä.

Olkoot A ja B aakkoston Σ kieliä. Perusoperaatioita:

(i) *Yhdiste:*

$$A \cup B = \{x \in \Sigma^* \mid x \in A \text{ tai } x \in B\};$$

(ii) *Katenaatio:*

$$AB = \{xy \in \Sigma^* \mid x \in A,\ y \in B\};$$

(iii) *Potenssit:*

$$\begin{cases} A^0 &= \{\varepsilon\}, \\ A^k &= AA^{k-1} = \{x_1 \ldots x_k \mid x_i \in A \quad \forall i = 1, \ldots, k\} \end{cases}$$

(iv) *Sulkeuma t. "Kleenen tähti":*

$$\begin{aligned} A^* &= \bigcup_{k \geq 0} A^k \\ &= \{x_1 \ldots x_k \mid k \geq 0,\ x_i \in A \quad \forall i = 1, \ldots, k\}. \end{aligned}$$

Määritelmä 2.3 Aakkoston Σ *säännölliset lausekkeet* määritellään induktiivisesti säännöillä:

(i) $\boldsymbol{\emptyset}$ ja $\boldsymbol{\varepsilon}$ ovat Σ:n säännöllisiä lausekkeita;

(ii) $\boldsymbol{a}$ on Σ:n säännöllinen lauseke kaikilla $a \in \Sigma$;

(iii) jos r ja s ovat Σ:n säännöllisiä lausekkeita, niin $(r \cup s)$, (rs) ja r^* ovat Σ:n säännöllisiä lausekkeita;

(iv) muita Σ:n säännöllisiä lausekkeita ei ole.

Kukin Σ:n säännöllinen lauseke r *kuvaa* kielen $L(r)$, joka määritellään:

(i) $L(\boldsymbol{\emptyset}) = \emptyset$;

(ii) $L(\boldsymbol{\varepsilon}) = \{\varepsilon\}$;

(iii) $L(\boldsymbol{a}) = \{a\}$ kaikilla $a \in \Sigma$;

(iv) $L((r \cup s)) = L(r) \cup L(s)$;

(v) $L((rs)) = L(r)L(s)$;

(vi) $L(r^*) = (L(r))^*$.

Aakkoston $\{a, b\}$ säännöllisiä lausekkeita:

$$r_1 = ((\boldsymbol{ab})\boldsymbol{b}), \quad r_2 = (\boldsymbol{ab})^*,$$

$$r_3 = (\boldsymbol{ab}^*), \quad r_4 = (\boldsymbol{a}(\boldsymbol{b} \cup (\boldsymbol{bb})))^*.$$

Lausekkeiden kuvaamat kielet:

$$\begin{aligned} L(r_1) &= (\{a\}\{b\})\{b\} = \{ab\}\{b\} = \{abb\}; \\ L(r_2) &= \{ab\}^* = \{\varepsilon, ab, abab, ababab, \ldots\} \\ &= \{(ab)^i \mid i \geq 0\}; \\ L(r_3) &= \{a\}(\{b\})^* = \{a, ab, abb, abbb, \ldots\} \\ &= \{ab^i \mid i \geq 0\}; \\ L(r_4) &= (\{a\}\{b, bb\})^* = \{ab, abb\}^* \\ &= \{\varepsilon, ab, abb, abab, ababb, \ldots\} \\ &= \{x \in \{a, b\}^* \mid \text{ kutakin } a\text{-kirjainta } x\text{:ssä} \\ &\qquad \text{seuraa 1 tai 2 } b\text{-kirjainta } \}. \end{aligned}$$

Sulkumerkkien vähentämissääntöjä:

Operaattoreiden prioriteetti:

$$* \quad \succ \quad \cdot \quad \succ \quad \cup$$

Yhdiste- ja tulo-operaatioiden assosiatiivisuus:

$$\begin{aligned} L(((r{\cup}s){\cup}t)) &= L((r{\cup}(s{\cup}t))) \\ L(((rs)t)) &= L((r(st))) \end{aligned}$$

$\Rightarrow$ peräkkäisiä yhdisteitä ja tuloja ei tarvitse suluttaa.

Käytetään tavallisia kirjasimia, mikäli sekaannuksen vaaraa merkkijonoihin ei ole.

Yksinkertaisemmin siis:

$r_1 = abb, \quad r_2 = (ab)^*, \quad r_3 = ab^*, \quad r_4 = (a(b{\cup}bb))^*.$

Määritelmä 2.4 Kieli on *säännöllinen*, jos se voidaan kuvata säännöllisellä lausekkeella.

Säännöllisten lausekkeiden sieventäminen

Säännöllisillä kielillä on yleensä useita vaihtoehtoisia kuvauksia, esim.:

$$\begin{aligned} \Sigma^* &= L((a \cup b)^*) \\ &= L((a^*b^*)^*) \\ &= L(a^*b^* \cup (a \cup b)^*ba(a \cup b)^*). \end{aligned}$$

Määritelmä. Säännölliset lausekkeet r ja s ovat *ekvivalentit*, merk. $r = s$, jos $L(r) = L(s)$.

Lausekkeen sieventäminen = "yksinkertaisimman" ekvivalentin lausekkeen määrittäminen.

Säännöllisten lausekkeiden ekvivalenssitestaus on epätriviaali, mutta periaatteessa mekaanisesti ratkeava ongelma.

Sievennyssääntöjä:

$$\begin{aligned} r \cup (s \cup t) &= (r \cup s) \cup t \\ r(st) &= (rs)t \\ r \cup s &= s \cup r \\ r(s \cup t) &= rs \cup rt \\ (r \cup s)t &= rt \cup st \\ r \cup r &= r \\ r \cup \emptyset &= r \\ \varepsilon r &= r \\ \emptyset r &= \emptyset \\ r^* &= \varepsilon \cup r^* r \\ r^* &= (\varepsilon \cup r)^* \end{aligned}$$

Mikä tahansa säännöllisten lausekkeiden tosi ekvivalenssi voidaan johtaa näistä laskulaeista, kun lisätään päättelysääntö:

jos $r = rs \cup t$, niin $r = ts^*$, edellyttäen että $\varepsilon \notin L(s)$.

2.7 ÄÄRELLISET AUTOMAATIT JA SÄÄNNÖLLISET KIELET

Lause 2.3 Jokainen säännöllinen kieli voidaan tunnistaa äärellisellä automaatilla.

Todistus. Seuraavan kalvon induktiivisen konstruktion avulla voidaan mielivaltaisen säännöllisen lausekkeen r rakennetta seuraten muodostaa ε-automaatti M_r, jolla $L(M_r) = L(r)$. Tästä automaatista voidaan poistaa ε-siirtymät Lemman 2.4 mukaisesti, ja tarvittaessa voidaan syntyvä epädeterministinen automaatti determinisoida Lauseen 2.2 konstruktiolla.

Esitettävästä konstruktiosta on syytä huomata, että muodostettaviin ε-automaateihin tulee aina yksikäsitteiset alku- ja lopputila. □

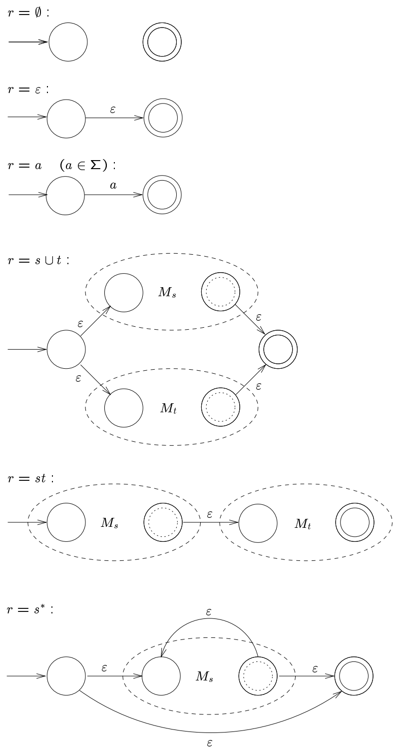

Esimerkiksi lausekkeesta $r = (a(b \cup bb))^*$ saadaan näiden sääntöjen mukaan seuraava ε-automaatti:

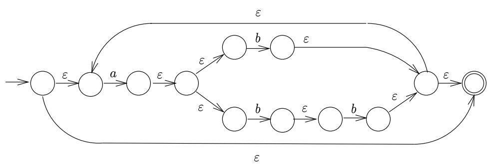

Automaatti on selvästi hyvin redundantti. Käsin automaatteja suunniteltaessa ne kannattaakin usein muodostaa suoraan. Esim. lausekkeen $r = (a(b \cup bb))^*$ perusteella on helppo muodostaa seuraava yksinkertainen epädeterministinen tunnistaja-automaatti:

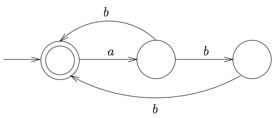

Lause 2.4 Jokainen äärellisellä automaatilla tunnistettava kieli on säännöllinen.

Todistus. Tarvitaan vielä yksi äärellisten automaattien laajennus: *lausekeautomaatissa* voidaan siirtymien ehtoina käyttää mielivaltaisia säännöllisiä lausekkeita.

Formalisointi: Merk. RE_Σ = aakkoston Σ säännöllisten lausekkeiden joukko. *Lausekeautomaatti* on viisikko

$$M = (Q, \Sigma, \delta, q_0, F),$$

missä siirtymäfunktio δ on äärellinen kuvaus

$$\delta : Q \times \mathrm{RE}_\Sigma \to \mathcal{P}(Q)$$

(so. $\delta(q, r) \neq \emptyset$ vain äärellisen monella parilla $(q, r) \in Q \times \mathrm{RE}_\Sigma$).

Yhden askeleen tilannejohto määritellään:

$$(q, w) \underset{M}{\vdash} (q', w')$$

jos on $q' \in \delta(q, r)$ jollakin sellaisella $r \in \mathsf{RE}_\Sigma$, että $w = zw'$, $z \in L(r)$. Muut määritelmät samat kuin aiemmin.

Todistetaan: jokainen lausekeautomaatilla tunnistettava kieli on säännöllinen.

Olkoon M jokin lausekeautomaatti. Säännöllinen lauseke, joka kuvaa M:n tunnistaman kielen, muodostetaan kahdessa vaiheessa:

1. Tiivistetään M ekvivalentiksi enintään 2-tilaiseksi lausekeautomaatiksi seuraavilla muunnoksilla:

(i) Yhdistetään M:n lopputilat yhdeksi seuraavan kuvan mukaisesti:

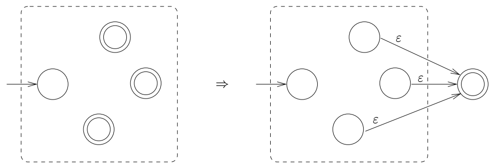

(ii) Poistetaan M:n muut kuin alku- ja lopputila yksi kerrallaan seuraavasti. Olk. q jokin M:n tila, joka ei ole alku- eikä lopputila; tarkastellaan kaikkia "reittejä", jotka M:ssä kulkevat q:n kautta. Olk. q_i ja q_j q:n välittömät edeltäjä- ja seuraajatila jollakin tällaisella reitillä. Poistetaan q reitiltä $q_i \to q_j$ oheisen kuvan (i) muunnoksella, jos tilasta q ei ole siirtymää itseensä, ja kuvan (ii) muunnoksella, jos tilasta q on siirtymä itseensä:

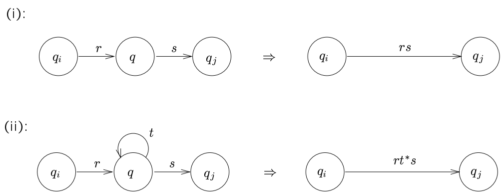

Samalla yhdistetään rinnakkaiset siirtymät seuraavasti:

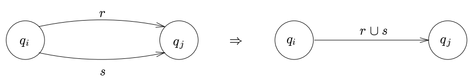

2. Tiivistyksen päättyessä jäljellä olevaa enintään 2-tilaista automaattia vastaava säännöllinen lauseke muodostetaan seuraavan kuvan esittämällä tavalla:

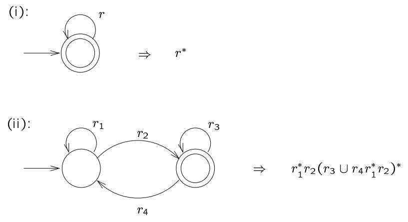

□

Esimerkki:

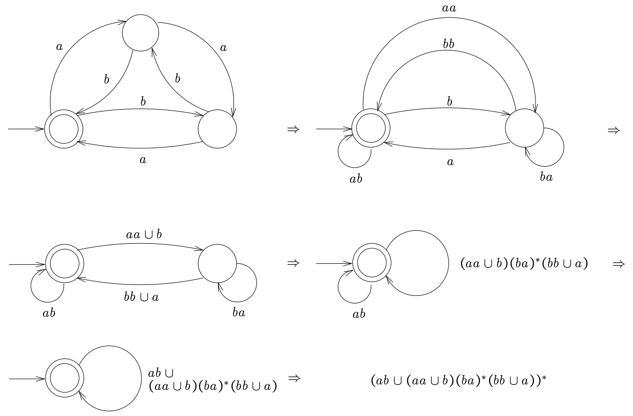

a
a
b
b
b
a
⇒
aa
bb
b
a
ab
ba
⇒
aa ∪ b
bb ∪ a
ab
ba
⇒
(aa ∪ b)(ba)*(bb ∪ a)
ab
⇒
ab ∪
(aa ∪ b)(ba)*(bb ∪ a)
⇒
(ab ∪ (aa ∪ b)(ba)*(bb ∪ a))*