

3.2 Säännölliset kielet ja yhteydettömät kieliopit

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

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

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.

Lause 3.1 Jokainen säännöllinen kieli voidaan tuottaa oikealle lineaarisella kieliopeilla.

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

Kielioffin G_M pääteakkosto on sama kuin M :n syöteakkosto Σ , ja sen välikaakkostoon otetaan yksi välika A_q kutakin M :n tilaa q kohden. Kielioffin lähtösymboli on A_{q_0} , ja sen produktiot vastaavat M :n siirtymiä:

(i) kutakin M :n lopputilaa $q \in F$ kohden kielioppiin otetaan produktio $A_q \rightarrow \varepsilon$;

(ii) kutakin M :n siirtymää $q \xrightarrow{a} q'$ (so. $q' \in \delta(q, a)$) kohden kielioppiin otetaan produktio $A_q \rightarrow aA_{q'}$.

Konstruktion oikeellisuuden tarkastamiseksi merkitään välikkeestä A_q tuotettavien päätejonojen joukkoa

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


Induktiolla merkijonon 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

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

Esimerkki. Automaatti:



Vastaava kielioppi:

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

Lause 3.2 Jokainen oikealle lineaarisella kielipillillä tuotettava kieli on säännöllinen.

Todistus. Olkoon $G = (V, \Sigma, P, S)$ oikealle lineaarinen kielipilli. Muodostetaan kielen $L(G)$ tunnistava epädeterministinen äärellinen automaatti $M_G = (Q, \Sigma, \delta, q_S, F)$ seuraavasti: M_G :n tilat vastaavat G :n välitteitä:

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

M_G :n alkutila on lähtösymbolia S vastaava tila q_S .

M_G :n syöteakosto on G :n pääteakosto Σ .

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

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

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

Konstruktion oikeellisuus voidaan jälleen tarkastaa induktiolla G :n tuottamien ja M_G :n hyväksymien merkkijonojen pituuden suhteen. \square

Johdot ja jäsenyspuut

Olkoon $\gamma \in V^*$ kielipilin $G = (V, \Sigma, P, S)$ lausejohdos.

Lähtösymbolista S merkkijonoon γ johtavaa suorien johtojen jonoa

$$S = \gamma_0 \Rightarrow \gamma_1 \Rightarrow \dots \Rightarrow \gamma_n = \gamma$$

sanotaan γ :n *johdoksi* G :ssä.

Johdon *pituus* on siihen kuuluvien suorien johtojen määrä (edellä n).

Esimerkki: lauseen $a + a$ johtoja kielipilissa G_{expr} :

$$\begin{array}{ll} \text{(i)} & E \Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \\ & \Rightarrow a + T \Rightarrow a + F \Rightarrow a + a \\ \text{(ii)} & E \Rightarrow E + T \Rightarrow E + F \Rightarrow T + F \\ & \Rightarrow F + F \Rightarrow F + a \Rightarrow a + a \\ \text{(iii)} & E \Rightarrow E + T \Rightarrow E + F \Rightarrow E + a \\ & \Rightarrow T + a \Rightarrow F + a \Rightarrow a + a. \end{array}$$

3.3 KIELIOPPIEN JÄSENYSONGELMA

Ratkaistava tehtävä:

“Annettu yhteydetön kielipilli G ja merkkijono x . Onko $x \in L(G)$?”

Ratkaisumenetelmä = *jäsenysalgoritmi*.

Useita vaihtoehtoisia menetelmiä, erityisesti kun G on jotain rajoitettua (käytännössä esiintyvää) muotoa.

Johto $\gamma \Rightarrow^* \gamma'$ on *vasen johto*, merkitään

$$\gamma \Rightarrow_{lm}^* \gamma',$$

jos kussakin johtoaskelella on produktiota sovellettu merkijonon vasemmanpuoleisimpaan välikkeeseen (edellä johto (i)).

Vastaavasti määritellään *oikea johto* (edellä (iii)), jota merkitään

$$\gamma \Rightarrow_{rm}^* \gamma'$$

Suuria vasempia ja oikeita johtoaskelia merkitään $\gamma \Rightarrow_{lm}^* \gamma'$ ja $\gamma \Rightarrow_{rm}^* \gamma'$.

Olkoon $G = (V, \Sigma, P, S)$ yhteydetön kielioppi.


Kieliopin G mukainen *jäsennyspanu* on järjestetty puu, jolla on seuraavat ominaisuudet:

(i) puun solmut on nimetty joukon $V \cup \{\varepsilon\}$ alkioilla siten, että sisäsolmujen nimet ovat välkkeitä (so. joukosta $N = V - \Sigma$) ja juurisolmun nimenä on lähtösymboli S ;

(ii) jos A on puun jonkin sisäsolmun nimi, ja X_1, \dots, X_k ovat sen jälkeläisten nimet järjestyksessä, niin $A \rightarrow X_1 \dots X_k$ on G :n produktio.

Jäsennyspanu τ *tuotos* on merkijono, joka saadaan liittämällä yhteen sen lehtrisolmujen nimet esijärjestyksessä ("vasemmalta oikealle").

Esimerkki. Lauseen $a + a$ jäsennyspanu kieliopissa G_{expr} :



Lauseen johto:

$$\begin{aligned} E &\Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \\ &\Rightarrow a + T \Rightarrow a + F \Rightarrow a + a \end{aligned}$$

Johtoa

$$S = \gamma_0 \Rightarrow \gamma_1 \Rightarrow \dots \Rightarrow \gamma_n = \gamma$$

vastaavan jäsennyspanuun muodostaminen:

(i) puun juuren nimeksi tulee S ; jos $n = 0$, niin puussa ei ole muita solmuja; muuten

(ii) jos ensimmäisessä johtoaskelella on sovellettu produktiota $S \rightarrow X_1 X_2 \dots X_k$, niin juurelle tulee k jälkeläissolmua, joiden nimet vasemmalta oikealle ovat X_1, X_2, \dots, X_k ;

(iii) jos seuraavassa askelella on sovellettu produktiota $X_i \rightarrow Y_1 Y_2 \dots Y_l$, niin juuren i :nnelle jälkeläissolmulle tulee l jälkeläistä, joiden nimet vasemmalta oikealle ovat Y_1, Y_2, \dots, Y_l ; ja niin edelleen.

Konstruktioista huomataan, että jos τ on jotakin johtoa $S \Rightarrow^* \gamma$ vastaava jäsennyspanu, niin τ :n tuotos on γ .

Olkoon τ kielioipin G mukainen jäsennyspuu, jonka tuotos on päätemerkkijono x .


Tällöin τ :sta saadaan vasen johto x :lle käymällä puun solmut läpi esijärjestyksessä ("ylhäältä alas, vasemmalta oikealle") ja laventamalla vastaan tulevat välikkeet järjestyksessä puun osoittamalla tavalla.

Oikea johto saadaan käymällä puu läpi käänteisessä esijärjestyksessä ("ylhäältä alas, oikealta vasemmalle").

Muodostamalla annetusta vasemmasta johdosta $S \xrightarrow{\text{lm}}^* x$ ensin jäsennyspuu edellä esitetyllä tavalla, ja sitten jäsennyspuusta vasen johto, saadaan takaisin alkuperäinen johto; vastaava tulos pätee myös oikeille johdoille.

Esimerkki. Lauseen $a + a$ vasemman johdon muodostaminen jäsennyspuusta.

Jäsennyspuu:



Solmut esijärjestyksessä:

$$E_1 E_2 T_2 F_1 a_1 + T_1 F_2 a_2$$

Vasen johto:

$$\begin{aligned} E &\Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \\ &\xrightarrow{\text{lm}} a + T \xrightarrow{\text{lm}} a + F \xrightarrow{\text{lm}} a + a \end{aligned}$$

Lause 3.3 Olkoon $G = (V, \Sigma, P, S)$ yhteydetön kielioipi.

Tällöin:

- (i) jokaisella G :n lausejohdoksella γ on G :n mukainen jäsennyspuu τ , jonka tuotos on γ ;
- (ii) jokaista G :n mukaista jäsennyspuuta τ , jonka tuotos on päätemerkkijono x , vastaavat yksikäsitteiset vasen ja oikea johto $S \xrightarrow{\text{lm}}^* x$ ja $S \xrightarrow{\text{rm}}^* x$.

Seuraus 3.4 Jokaisella G :n lauseella on vasen ja oikea johto.

Siis: yhteydetön kielioipin tuottamien lauseiden jäsennyspuut, vasemmat ja oikeat johdot vastaavat yksikäsitteisesti toisiaan.

Jäsennysongelman ratkaisuun katsotaan usein kuuluvan pelkän päätösongelman "Onko $x \in L(G)$?" ratkaisemisen lisäksi jonkin näistä jäsennysesityksistä tuottaminen.


Kielioipin moniselitteisyys

Lauseella voi olla kielioipissa useita jäsennyksiä.

Esimerkki. Tarkastellaan yksinkertaisten aritmeettisten lausekkeiden kielioipia:

$$G_{\text{expr}} = \{E \rightarrow E + E, E \rightarrow E * E, E \rightarrow a, E \rightarrow (E)\}.$$

Lauseella $a + a * a$ on tässä kielioipissa kaksi jäsennyttä:



Yhteydetön kielioipi G on *moniselitteinen*, jos jollakin G :n lauseella x on kaksi erilaista G :n mukaista jäsennyspuuta. Muuten kielioipi on *yksiselitteinen*.

Moniselitteisyys on tietojenkäsittelysovelluksissa yleensä ei-toivottu ominaisuus, koska se merkitsee että annetulla lauseella on kaksi vaihtoehtoista "tulkintaa."

Yhteydetön kieli, jonka tuottavat kieliooppi ovat kaikki moniselitteisiä, on *luonnostaan moniselitteinen*.

Esimerkiksi kieliooppi G'_{expr} on moniselitteinen, kieliooppi G_{expr} ja G_{match} yksiselitteisiä. Kieli $L_{\text{expr}} = L(G_{\text{expr}})$ ei ole luonnostaan moniselitteinen, koska sillä on myös yksiselitteinen kieliooppi G_{expr} . Luonnostaan moniselitteinen on esimerkiksi kieli

$$\{a^i b^j c^k \mid i = j \text{ tai } j = k\}.$$

(Todistus sivuutetaan.)

3.4 Osittava jäsentäminen

Yksi (yleisessä muodossa tehoton!) tapa etsiä vasenta johtoa (jäsennyspuuta) annetun kielioopin G mukaiselle lauseelle x on aloittaa G :n lähtösymbolista ja generoida systemaattisesti kaikki mahdolliset vasemmat johdot (jäsennyspuut), samalla sovittaen muodostetun lausejohdoksen päätemerkkejä (puun lehtiä) x :n merkkeihin. Ei-yhteensopivuuden ilmetessä peruutetaan viimeksi tehty produktiovalinta ja kokeillaan järjestyksessä seuraavaa vaihtoehtoa.

Tällaista lauseenjäsennystapaa sanotaan *osittavaksi*, koska siinä tarkasteltu lause yritetään johtaa kielioopin lähtösymbolista osittamalla se valittujen produktioiden mukaisiin rakennosiiniin ja yrittämällä näin, tarvittaessa toistuvasti edelleen osittamalla, sovittaa kielioopin tuottamaa rakennetta yhteen lauseen rakenteen kanssa.

Esim. Tarkastellaan kieliooppia G :

$$\begin{aligned} E &\rightarrow T + E \mid T - E \mid T \\ T &\rightarrow a \mid (E). \end{aligned}$$

Lauseen $a - a$ osittava jäsennyks G :n suhteen:

$$\begin{aligned} E &\Rightarrow T + E \Rightarrow a + T && [\text{ristiriita; peruutetaan}] \\ &\Rightarrow (E) + T && [\text{ristiriita; peruutetaan}] \\ &\Rightarrow T - E \Rightarrow a - E \Rightarrow a - T + E \Rightarrow a - a + E \\ &&& [\text{ristiriita; peruutetaan}] \\ &\Rightarrow T - E \Rightarrow a - E \Rightarrow a - T + E \Rightarrow a - (E) + E \\ &&& [\text{ristiriita; peruutetaan}] \\ &&& \Rightarrow a - T - E \Rightarrow a - a - E \\ &&& [\text{ristiriita; peruutetaan}] \\ &\Rightarrow a - T - E \Rightarrow a - (E) - E \\ &&& [\text{ristiriita; peruutetaan}] \\ &\Rightarrow a - T && \Rightarrow a - a \quad [\text{OK!}] \end{aligned}$$

Em. osittava jäsennystekniikka saadaan huomattavasti tehokkaammaksi, jos kieliozilla on sellainen ominaisuus, että jäsennyksen joka vaiheessa määrää tavoitteena olevan lauseen seuraava merkki yksikäsitteisesti sen, mikä lavennettavana olevaan välikkeeseen liittyvä produktio on valittava. Kieliooppia, jolla on tämä ominaisuus, sanotaan *LL(1)-tyyppiseksi*. Muokataan G :stä välikkeen E produktiot "tekijöimällä" ekvivalentti kielioppi G' :

$$\begin{aligned} E &\rightarrow TE' \\ E' &\rightarrow +E \mid -E \mid \varepsilon \\ T &\rightarrow a \mid (E). \end{aligned}$$

Esimerkiksi lauseen $a - a$ jäsentäminen G' :n suhteen (kulloisenkin produktiovalinnan määräävä syötemerkki on tässä merkitty vastaavan johtonuolen päälle):

$$E \Rightarrow TE' \xrightarrow{a} aE' \xrightarrow{-} a - E \Rightarrow a - TE' \xrightarrow{a} a - aE' \xrightarrow{\varepsilon} a - a.$$

LL(1)-tyyppiselle kieliopille on helppo kirjoittaa jäsennysohjelma suoraan rekursiivisina proseduureina. Esimerkiksi kieliopin G' pohjalta voidaan muodostaa seuraava C-kielinen funktiokokoelma, joka syötejonon jäsennyksen yhteydessä tulostaa sen tuottavan vasemman johdon produktiot järjestyksessä.

```
#include <stdio.h>

int next;
void E(void); void Eprime(void); void T(void);

void E(void)
{
    printf("E -> TE'\n");
    T(); Eprime();
}

```

```
void Eprime(void)
{
    if (next == '+') {
        printf("E' -> +E'\n");
        next = getchar();
        E();
    }
    else if (next == '-') {
        printf("E' -> -E'\n");
        next = getchar();
        E();
    }
    else
        printf("E' -> \n");
}

```

```
void T(void)
{
    if (next == 'a') {
        printf("T -> a'\n");
        next = getchar();
    }
    else if (next == '(') {
        printf("T -> (E)\n");
        next = getchar();
        E();
    }
    if (next != ')')
        ERROR(" expected.");
    next = getchar();
}
else ERROR("T cannot start with this.");
}

```

```
void ERROR(char *msg)
{
    printf("%s\n",msg); exit(1);
}

int main(void)
{
    next = getchar();
    E();
    exit(0);
}

```

Esimerkiksi syötejonoa $a-(a+a)$ käsitellessään ohjelma tulostaa seuraavat rivit:

$E \rightarrow TE'$

$T \rightarrow a$

$E' \rightarrow -E$

$E \rightarrow TE'$

$T \rightarrow (E)$

$E \rightarrow TE'$

$T \rightarrow a$

$E' \rightarrow +E$

$E \rightarrow TE'$

$T \rightarrow a$

$E' \rightarrow$

$E' \rightarrow$

Tulostus vastaa vasenta johtoa:

$$E \Rightarrow TE' \Rightarrow aE' \Rightarrow a - E \Rightarrow a - TE'$$

$$\Rightarrow a - (E)E' \Rightarrow a - (TE')E'$$

$$\Rightarrow a - (aE')E' \Rightarrow a - (a + E)E'$$

$$\Rightarrow a - (a + TE')E' \Rightarrow a - (a + aE')E'$$

$$\Rightarrow a - (a + a)E' \Rightarrow a - (a + a).$$