

3.6 Cocke-Younger-Kasami -jäsennysalgoritmi

Osittava jäsentäminen on selkeä ja tehokas jäsennysmenetelmä LL(1)-kieloille: n merkin mittaisen syötemerkkijonon käsittely sujuu ajassa $O(n)$. LL(1)-kieliot ovat kuitenkin melko rajoitettu luokka; yleisen jäsennysongelman ratkaisu ei ole yhtä helppoa. Periaatteessa ongelma voidaan ratkaista esim. soveltamalla yleistä (peruuttavaa) osittavaa jäsennystä, mutta käytännössä vaikeudeksi muodostuu erilaisten kokeiltavien johtovaihtoehtojen suuri määrä. (Tyypillisesti $O(c^n)$ kpl jollakin $c \geq 2$.)

Cocke-Younger-Kasami -algoritmi on yleiseen ns. dynaamisen ohjelmoinnin tekniikkaan (t. osaratkaisujen taulukointiin) perustuva menetelmä mielivaltaisen yhteydettömän kielioin tuottamien merkkijonojen tunnistamiseen. Menetelmä toimii ajassa $O(n^3)$, missä n on tutkittavan merkkijonon pituus. Algoritmia varten määritellään ensin joitakin kielioppimuunnoksia.

1. ϵ -produktioiden poistaminen

Olkoon $G = (V, \Sigma, P, S)$ yhteydetön kielioppi. Välike $A \in V - \Sigma$ on *tyhjentävä*, jos $A \xRightarrow{*} \epsilon$.

Lemma 3.5. Mistä tahansa yhteydettömästä kielioipista G voidaan muodostaa ekvivalentti kielioppi G' , jossa enintään lähtösymboli on tyhjentävä.

Todistus. Olkoon $G = (V, \Sigma, P, S)$. Selvitetään ensin G :n tyhjentävät välikkeet seuraavasti:

(i) asetetaan aluksi

$$\text{NULL} := \{A \in V - \Sigma \mid A \rightarrow \epsilon \text{ on } G\text{:n produktio}\};$$

(ii) toistetaan sitten seuraavaa NULL-joukon laajennusoperaatiota, kunnes joukko ei enää kasva:

$$\text{NULL} := \text{NULL} \cup$$

$$\{A \in V - \Sigma \mid A \rightarrow B_1 \dots B_k \text{ on } G\text{:n prod.,} \\ B_i \in \text{NULL kaikilla } i = 1, \dots, k\}.$$

Tämän jälkeen korvataan kukin G :n produktio $A \rightarrow X_1 \dots X_k$ kaikkien sellaisten produktioiden joukolla, jotka ovat muotoa

$$A \rightarrow \alpha_1 \dots \alpha_k, \text{ missä } \alpha_j = \begin{cases} X_j, & \text{jos } X_j \notin \text{NULL}; \\ X_j \text{ tai } \varepsilon, & \text{jos } X_j \in \text{NULL}. \end{cases}$$

Lopuksi poistetaan kaikki muotoa $A \rightarrow \varepsilon$ olevat produktiot. Jos poistettavana on myös produktio $S \rightarrow \varepsilon$, otetaan muodostettavaan kieloppiin G' uusi lähtösymboli S' ja sille produktiot $S' \rightarrow S$ ja $S' \rightarrow \varepsilon$. \square

Esimerkki. Poistetaan ε -produktiot kieliopista:

$$\begin{aligned} S &\rightarrow A \mid B \\ A &\rightarrow aBa \mid \varepsilon \\ B &\rightarrow bAb \mid \varepsilon \end{aligned} \quad \Rightarrow \quad (\text{NULL} = \{A, B, S\})$$

$$\begin{aligned} S &\rightarrow A \mid B \mid \varepsilon \\ A &\rightarrow aBa \mid aa \mid \varepsilon \\ B &\rightarrow bAb \mid bb \mid \varepsilon \end{aligned} \quad \Rightarrow$$

$$\begin{aligned} S' &\rightarrow S \mid \varepsilon \\ S &\rightarrow A \mid B \\ A &\rightarrow aBa \mid aa \\ B &\rightarrow bAb \mid bb. \end{aligned}$$

2. Yksikköproduktioiden poistaminen

Produktio muotoa $A \rightarrow B$, missä A ja B ovat välitteitä, on *yksikköproduktio*.

Lemma 3.6. Mistä tahansa yhteydettömästä kieliopista G voidaan muodostaa ekvivalentti kielioppi G' , jossa ei ole yksikköproduktioita.

Todistus. Olkoon $G = (V, \Sigma, P, S)$. Selvitetään ensin G :n kunkin välitteeseen "yksikköseuraajat" seuraavasti:

(i) asetetaan aluksi kullekin $A \in V - \Sigma$:

$$F(A) := \{B \in V - \Sigma \mid A \rightarrow B \text{ on } G\text{:n produktio}\};$$

(ii) toistetaan sitten seuraavia F -joukkojen laajennusoperaatioita, kunnes joukot eivät enää kasva:

$$F(A) := F(A) \cup \bigcup \{F(B) \mid A \rightarrow B \text{ on } G\text{:n produktio}\}.$$

Tämän jälkeen poistetaan G :stä kaikki yksikköproduktiot ja lisätään niiden sijaan kaikki mahdolliset produktiot muotoa $A \rightarrow \omega$, missä $B \rightarrow \omega$ on G :n ei-yksikköproduktio jollakin $B \in F(A)$. \square

Esimerkki. Poistetaan yksikköproduktiot aiemmin muodostetusta kiellopista:

$$\begin{aligned} S' &\rightarrow S \mid \varepsilon \\ S &\rightarrow A \mid B \\ A &\rightarrow aBa \mid aa \\ B &\rightarrow bAb \mid bb. \end{aligned}$$

Välikkeiden yksikköseuraajat ovat:

$$\begin{aligned} F(S') &= \{S, A, B\}, F(S) = \{A, B\}, \\ F(A) &= F(B) = \emptyset. \end{aligned}$$

Korvaamalla yksikköproduktiot edellä esitetyllä tavalla saadaan kielloppi:

$$\begin{aligned} S' &\rightarrow aBa \mid aa \mid bAb \mid bb \mid \varepsilon \\ S &\rightarrow aBa \mid aa \mid bAb \mid bb \\ A &\rightarrow aBa \mid aa \\ B &\rightarrow bAb \mid bb. \end{aligned}$$

(Huomataan, että välike S on nyt itse asiassa "turha", so. se ei voi esiintyä minkään kiellopin lauseen johdossa. Myös turhat välikkeet voidaan haluttaessa poistaa kiellopista samantapaisella algoritmilla (HT).)

Chomskyn normaalimuoto

Yhteydetön kielloppi $G = (V, \Sigma, P, S)$ on Chomskyn normaalimuodossa, jos sen välikkeistä enintään S on tyhjentävä, ja mahdollista produktiota $S \rightarrow \varepsilon$ lukuunottamatta muut produktiot ovat muotoa

$$A \rightarrow BC \quad \text{tai} \quad A \rightarrow a,$$

missä A, B ja C ovat välikkeitä ja a on päätämerkki.

Lisäksi vaaditaan yksinkertaisuuden vuoksi, että lähtösymboli S ei esiinny minkään produktio oikealla puolella.

Lause 3.7. Mistä tahansa yhteydettömästä kiellopista G voidaan muodostaa ekvivalentti Chomskyn normaalimuotoinen kielloppi G' .

Todistus. Olkoon $G = (V, \Sigma, P, S)$. Mikäli lähtösymboli S esiintyy G :ssä jonkin produktio oikealla puolella, otetaan käyttöön uusi lähtösymboli S' ja lisätään G :hen produktio $S' \rightarrow S$. Poistetaan sitten G :stä ε -produktiot ja yksikköproduktiot lemmojen 3.5 ja 3.6 konstruktioilla. Tämän jälkeen kaikki G :n produktiot ovat muotoa $A \rightarrow a$ tai $A \rightarrow X_1 \dots X_k$, $k \geq 2$ (tai $S \rightarrow \varepsilon/S' \rightarrow \varepsilon$).

Lisätään nyt kielloppiin kutakin päätämerkkiä a varten uusi välike C_a ja sille produktio $C_a \rightarrow a$. Korvataan kussakin muotoa $A \rightarrow X_1 \dots X_k$, $k \geq 2$, olevassa produktiossa ensin kaikki päätämerkit em. uusilla välikkeillä, ja sitten koko produktio produktiojoukolla

$$\begin{aligned} A &\rightarrow X_1 A_1 \\ A_1 &\rightarrow X_2 A_2 \\ &\vdots \\ A_{k-2} &\rightarrow X_{k-1} X_k, \end{aligned}$$

missä A_1, \dots, A_{k-2} ovat jälleen uusia välikkeitä. \square

Em. konstruktiolla saatu
Chomskyn normaalimuoto:

$$\begin{aligned} S &\rightarrow C_a S_1^1 \\ S_1^1 &\rightarrow B S_2^1 \\ S_2^1 &\rightarrow C C_d \\ S &\rightarrow C_b S_1^2 \\ S_1^2 &\rightarrow C_b C_b \\ B &\rightarrow b \\ C &\rightarrow c \\ C_a &\rightarrow a \\ C_b &\rightarrow b \\ C_c &\rightarrow c \\ C_d &\rightarrow d. \end{aligned}$$

Esimerkki. Kielioppi:

$$\begin{aligned} S &\rightarrow aBCd \mid bbb \\ B &\rightarrow b \\ C &\rightarrow c \end{aligned}$$

CYK-algoritmi

Olkoon $G = (V, \Sigma, P, S)$ yhteydetön kielioppi. Lauseen 3.7 nojalla voidaan olettaa, että G on Chomskyn normaalimuodossa. Kysymys, kuuluuko annettu merkkijono x kieleen $L(G)$ voidaan tällöin ratkaista seuraavasti:

Jos $x = \varepsilon$, niin $x \in L(G)$ joss $S \rightarrow \varepsilon$ on G :n produktio.

Muussa tapauksessa merkitään $x = a_1 \dots a_n$ ja tarkastellaan x :n eri osajonojen tuottamista.

Merkitään N_{ik} :lla niiden välikkeiden A joukkoa, joista voidaan tuottaa x :n positioista i alkava, k merkin mittainen osajono:

$$\begin{aligned} N_{ik} &= \{A \in V - \Sigma \mid A \xrightarrow{*}_G a_i \dots a_{i+k-1}\}, \\ &1 \leq i \leq i+k-1 \leq n. \end{aligned}$$

Joukot N_{ik} voidaan laskea taulukoimalla lyhyistä osajonoista pitempiin seuraavassa esitettävällä tavalla. Selvästi on $x \in L(G)$ joss $S \in N_{1n}$.

Em. konstruktiolla saatu
Chomskyn normaalimuoto:

$$\begin{aligned} S &\rightarrow C_a S_1^1 \\ S_1^1 &\rightarrow B S_2^1 \\ S_2^1 &\rightarrow C C_d \\ S &\rightarrow C_b S_1^2 \\ S_1^2 &\rightarrow C_b C_b \\ B &\rightarrow b \\ C &\rightarrow c \\ C_a &\rightarrow a \\ C_b &\rightarrow b \\ C_c &\rightarrow c \\ C_d &\rightarrow d. \end{aligned}$$

Esimerkki. Kielioppi:

$$\begin{aligned} S &\rightarrow aBCd \mid bbb \\ B &\rightarrow b \\ C &\rightarrow c \end{aligned}$$

Esimerkki. Chomskyn normaalimuotoinen kielioppi G :


$$\begin{array}{l} S \rightarrow AB \mid BC \\ A \rightarrow BA \mid a \\ B \rightarrow CC \mid b \\ C \rightarrow AB \mid a \end{array}$$

CYK-algoritmin laskenta kieliopillä G ja syötteellä $x = baaba$:

N_{ik}	$i \rightarrow$				
	1 : b	2 : a	3 : a	4 : b	5 : a
1	B	A, C	A, C	B	A, C
2	S, A	B	S, C	S, A	-
3	\emptyset	B	B	-	-
4	\emptyset	S, A, C	-	-	-
5	S, A, C	-	-	-	-

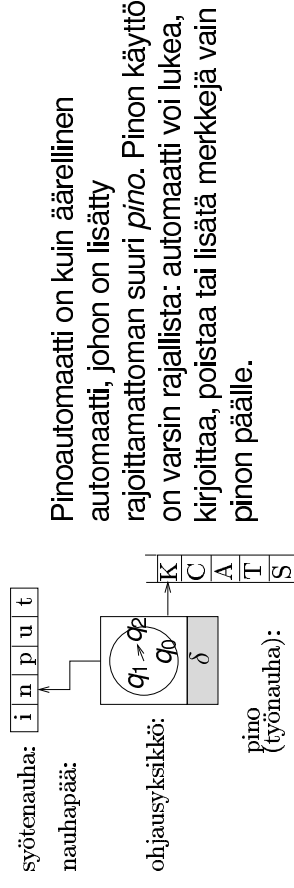
Koska lähtösymboli S kuuluu joukkoon N_{15} , päätellään että x kuuluu kieleen $L(G)$.

Yleisesti ottaen CYK-algoritmissa jotakin joukkoa N_{ik} määritettäessä edetään samanaikaisesti sarakkeessa N_{ij} joukkoa N_{ik} "kohiti" ja diagonaalilla $N_{+j,k-j}$ pitkin siitä "poispäin":



3.7 Pinoautomaatit

Yhteydettömille kielille saadaan automaattikarakterisointi ns. *pinoautomaattien* avulla:



Määritelmä 3.2 Pinoautomaatti on kuusikko

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

missä

- ▶ Q on tilojen äärellinen joukko;
- ▶ Σ on syöteakkosto;
- ▶ Γ on pinoakkosto;
- ▶ $\delta : Q \times (\Sigma \cup \{\varepsilon\}) \times (\Gamma \cup \{\varepsilon\}) \rightarrow \mathcal{P}(Q \times (\Gamma \cup \{\varepsilon\}))$ on (joukkoarvoinen) siirtymäfunktio;
- ▶ $q_0 \in Q$ on alkutila;
- ▶ $F \subseteq Q$ on (hyväksyvien) lopputilojen joukko.

Siirtymäfunktion arvon

$$\delta(q, \sigma, \gamma) = \{(q_1, \gamma_1), \dots, (q_k, \gamma_k)\}$$

tulkinta on, että ollessaan tilassa q ja lukiessaan syötemerkin σ ja pinomerkin γ automaatti voi siirtyä johonkin tiloista q_1, \dots, q_k ja korvata vastaavasti pinon päällimmäisen merkin jollakin merkeistä $\gamma_1, \dots, \gamma_k$. Pinoautomaatit ovat siis yleisessä tapauksessa *epädeterministisiä*.

Jos $\sigma = \varepsilon$, automaatti tekee siirtymän syötemerkkiä lukematta. Jos $\gamma = \varepsilon$, automaatti ei lue pinomerkkiä ja uusi kirjoitettu merkki tulee pinon päälle vanhaa päällimmäistä merkkiä poistamatta ("push"-operaatio). Jos pinosta luettu merkki on $\gamma \neq \varepsilon$ ja kirjoitettavana on $\gamma_j = \varepsilon$, pinosta poistetaan sen päällimmäinen merkki ("pop"-operaatio).

Automaatin *tilanne* on kolmikko $(q, w, \alpha) \in Q \times \Sigma^* \times \Gamma^*$; erityisesti automaatin *alkutilanne syötteellä* x on kolmikko (q_0, x, ε) .

Intuitio: tilanteessa (q, w, α) automaatti on tilassa q , syötemerkkijonon käsittelemätön osa on w ja pinossa on ylhäältä alas lukien merkijono α .

Tilanne (q, w, α) *johtaa suoraan tilanteeseen* (q', w', α') , merkitään

$$(q, w, \alpha) \vdash_M (q', w', \alpha'),$$

jos voidaan kirjoittaa $w = \sigma w', \alpha = \gamma\beta, \alpha' = \gamma'\beta$ $(|\sigma|, |\gamma|, |\gamma'| \leq 1)$, siten että

$$(q', \gamma') \in \delta(q, \sigma, \gamma).$$

Tilanne (q, w, α) *johtaa tilanteeseen* (q', w', α') , merkitään

$$(q, w, \alpha) \vdash_M^* (q', w', \alpha'),$$

jos on olemassa tilannejono $(q_0, w_0, \alpha_0), (q_1, w_1, \alpha_1), \dots, (q_n, w_n, \alpha_n), n \geq 0$, siten että

$$(q, w, \alpha) = (q_0, w_0, \alpha_0) \vdash_M (q_1, w_1, \alpha_1) \vdash_M \dots \vdash_M (q_n, w_n, \alpha_n) = (q', w', \alpha').$$

Pinoautomaatti M hyväksyy merkijonon $x \in \Sigma^*$, jos

$$(q_0, x, \varepsilon) \vdash_M^* (q_f, \varepsilon, \alpha) \quad \text{joillakin } q_f \in F \text{ ja } \alpha \in \Gamma^*,$$

siis jos se syöteen loppuessa on jossakin hyväksyvässä lopputilassa; muuten M hylkää x :n.

Automaatin M *tunnistama kieli* on:

$$L(M) = \{x \in \Sigma^* \mid (q_0, x, \varepsilon) \vdash_M^* (q_f, \varepsilon, \alpha) \text{ joillakin } q_f \in F \text{ ja } \alpha \in \Gamma^*\}.$$


Esimerkki. Pinoautomaatti kielelle $\{a^k b^k \mid k \geq 0\}$:

$$M = (\{q_0, q_1, q_2, q_3\}, \{a, b\}, \{A, \underline{A}\}, \delta, q_0, \{q_0, q_3\}),$$

missä

$$\begin{aligned} \delta(q_0, a, \varepsilon) &= \{(q_1, \underline{A})\}, \\ \delta(q_1, a, \varepsilon) &= \{(q_1, A)\}, \\ \delta(q_1, b, A) &= \{(q_2, \varepsilon)\}, \\ \delta(q_1, b, \underline{A}) &= \{(q_3, \varepsilon)\}, \\ \delta(q_2, b, A) &= \{(q_2, \varepsilon)\}, \\ \delta(q_2, b, \underline{A}) &= \{(q_3, \varepsilon)\}, \\ \delta(q_3, \sigma, \gamma) &= \emptyset \quad \text{muilla } (q, \sigma, \gamma). \end{aligned}$$

Kaavioesitys:



Automaatin toiminta syötteellä $aabb$:

$$\begin{aligned} (q_0, aabb, \varepsilon) &\vdash (q_1, abb, \underline{A}) \vdash (q_1, bb, \underline{AA}) \\ &\vdash (q_2, b, \underline{A}) \vdash (q_3, \varepsilon, \varepsilon). \end{aligned}$$


Koska $q_3 \in F = \{q_0, q_3\}$, on siis $aabb \in L(M)$.

Pinoautomaatit ja yhteydetöntä kielet


Lause 3.8 Kieli on yhteydetön, jos ja vain jos se voidaan tunnistaa jollakin (epädeterministisellä) pinoautomaatilla. □

Em. lauseen todistus sivuutetaan tässä, mutta periaatteena esim. annettua kielioppia G vastaavan pinoautomaatin M_G toiminnassa on, että M_G :n pinoon käyttäytyminen syönteellä x noudattelee G :n mukaisen vasemman lausejohdon $S \xRightarrow{*} x$ etenemistä: jos pinoon päällimmäisenä on välimerkki, sovelletaan jotain G :n produktiota ja lisätään pinoon pinnalle vastaavat merkit; jos pinoon päällimmäisenä on päätemerkki, se sovitetaan yhteen seuraavan syötemerkin kanssa.


Esimerkiksi syönteellä $abab$ on em. automaattilla seuraava hyväksyvä laskenta:



Tämä vastaa annetun kieliopin mukaista lauseen $abab$ vasenta johtoa:



Esimerkki. Kielioppia $\{S \rightarrow aSbS \mid bSaS \mid \varepsilon\}$ vastaava pinoautomaatti:



Automaatin kuvauksessa on käytetty seuraavaa luonnollista lyhennemerkintää:

Pinoautomaatti M on *deterministinen*, jos jokaisella tilanteella (q, w, α) on enintään yksi mahdollinen seuraaja (q', w', α') , jolla

$$(q, w, \alpha) \vdash_M (q', w', \alpha')$$

Toisin kuin äärellisten automaattien tapauksessa, epädeterministiset pinoautomaatit ovat aidoisti vahvempia kuin deterministiset. Esimerkiksi kieli $\{ww^R \mid w \in \{a, b\}^*\}$ voidaan tunnistaa epädeterministisellä, mutta ei deterministisellä pinoautomaatilla. (Tod. siv.)

Yhteydetön kieli on *deterministinen*, jos se voidaan tunnistaa jollakin deterministisellä pinoautomaatilla. Deterministiset kielet voidaan jäsentää ajassa $O(n)$; yleiset yhteydetöntä kielet vaativat tunnetuilla menetelmillä lähes ajan $O(n^3)$.