

4 Tehtävä: Laadi yhteydetön kielioppi kielelle

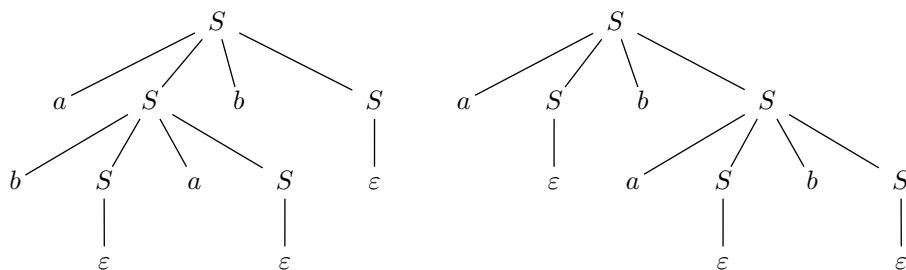
$$\{w \in \{a, b\}^* \mid w:\text{ssä on yhtä monta } a:\text{ta kuin } b:\text{tä}\}.$$

Vastaus: Kieliontin voi laatia parillakin eri tapaa. Yksinkertaisinta on laatia moniselitteinen kielioppi:

$$S \rightarrow aSbS \mid bSaS \mid \varepsilon .$$

Kieliontin ensimmäinen sääntö esittää ehdon: ”Jos sana alkaa *a*:lla, niin jossain kohtaa sanassa esiintyy myös vastaava *b*. Tätä ennen ja jälkeen voi esiintyä mitä tahansa tasapainoisia merkkijonoja.”

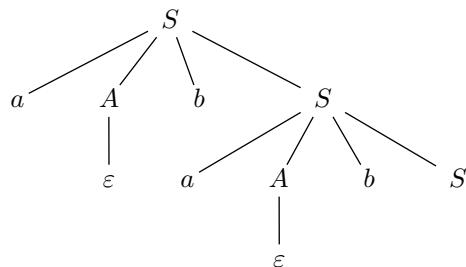
Esimerkiksi merkkijonolle *abab* on kaksi eri jäsenyspuuta:



Mikäli kielelle halutaan laatia yksiselitteinen kielioppi, täytyy varmistaa, että sanan alussa oleva *a* liitetään ensimmäiseen mahdolliseen *b*:hen:

$$\begin{aligned} S &\rightarrow aAbS \mid bBaS \mid \varepsilon \\ A &\rightarrow aAbA \mid \varepsilon \\ B &\rightarrow bBbB \mid \varepsilon \end{aligned}$$

Nyt jonolla *abab* on vain yksi jäsenyspuu:



5. Tehtävä:

(a) Osoita, että seuraavaa yhteydetön kielioppi on moniselitteinen:

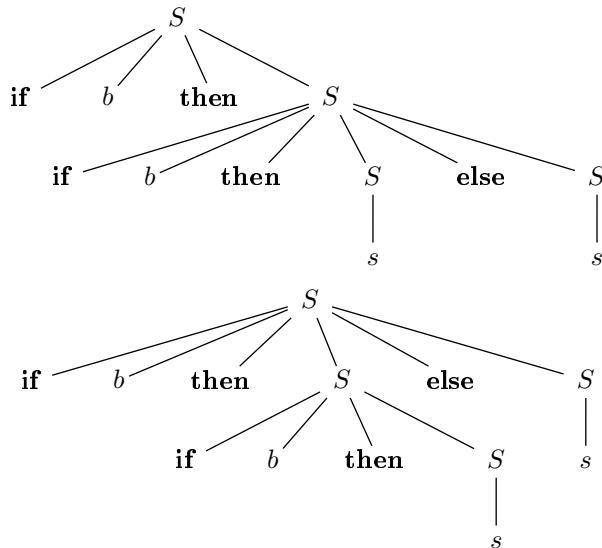
$$\begin{aligned} S &\rightarrow \text{if } b \text{ then } S \\ S &\rightarrow \text{if } b \text{ then } S \text{ else } S \\ S &\rightarrow s. \end{aligned}$$

(b) Muodosta (a)-kohdan kieliopin kanssa ekvivalentti, so. saman kielen tuottava yksiselitteinen kielioppi.

**Vastaus:** Yhteydetön kielioppi  $G$  on moniselitteinen, mikäli on olemassa sana  $w \in L(G)$  siten, että  $w$ :llä on ainakin kaksi erilaista jäsenyspuuta. Tehtävän kieliopille yksinkertaisin tällainen sana on:

**if b then if b then s else s,**

joka voidaan jäsentää kahdella tapaa:



Yleensä ohjelmointikielissä halutaan **else**-lause liittää lähinpään mahdolliseen **if**-lauseeseen. Ylläolevista puista ensimmäinen vastaa tästä käytäntöä.

Määritellään kielioppi seuraavasti:

$$\begin{aligned} G &= (V, \Sigma, P, S) \\ V &= \{S, B, U, s, b, \text{if}, \text{then}, \text{else}\} \\ \Sigma &= \{s, b, \text{if}, \text{then}, \text{else}\} \\ P &= \{S \rightarrow B \mid U \\ &\quad B \rightarrow \text{if } b \text{ then } B \text{ else } B \mid s \\ &\quad U \rightarrow \text{if } b \text{ then } S \mid \text{if } b \text{ then } B \text{ else } U\} \end{aligned}$$

Tässä välikeellä  $B$  saadaan johdettua vain ohjelmia, joissa kaikilla **if**-lauseilla on sekä **then**- että **else**-haarat. Välkkeellä  $U$  johdetaan sitten **if**-lauseet, joista puuttuu **else**-haaraa.

6. **Tehtävä:** Laadi rekursiivisesti etenevä jäsentäjä edellisten harjoitusten tehtävän 5 kieliopille.

**Vastaus:** Alla oleva C-ohjelma toteuttaa rekursiivisen jäsentäjän kieliopille:

$$\begin{aligned} C &\rightarrow S \mid S; C \\ S &\rightarrow a \mid \text{begin } C \text{ end} \mid \text{for } n \text{ times do } S \end{aligned}$$

Tässä on yksinkertaistettu hieman edellisen laskuharjoituskerran 6. tehtävän kielioppia korvaamalla erilliset numerot terminaalilla  $n$ , joka tarkoittaa mitä tahansa numeroa.

Tärkeimmät ohjelmassa esiintyvät funktiot ovat:

- `C()`, `S()` — toteuttavat kieliparin varsinaiset säännöt
- `lex()` — lukee syötteestä seuraavan lekseemin ja tallettaa sen globaaliin muuttujaan `current_tok`.
- `expect(int token)` — yrittää lukea syötteestä lekseemin *token*. Mikäli lukeminen epäonnistuu annetaan virheilmoitus.
- `consume_token()` — merkitään tämänhetkinen lekseemi käytetyksi. Tämä (tai jokin muu vastaava funktio) tarvitaan siksi, että joissain tapauksissa täytyy syöttää lukea yksi lekseemi eteenpäin ennen kuin tiedetään, mitä sääntöä täytyy käyttää.

Käytännössä ohjelointikielten jäsentäjät toteutetaan yleensä käyttäen *lex*- ja *yacc*-työkaluja<sup>1</sup>. Näistä *lex* muodostaa tilakonepohjaisen selaaajan, joka tunnistaa säännöllisillä lausekkeilla määritellyt leksemit, ja *yacc* tekee pinoautomaattipohjaisen jäsentimen annetulle yhteydettömälle kielipille.

```
#include <stdio.h>
#include <stdlib.h>
#include <ctype.h>

/* Define the alphabet */
enum TOKEN { DO, FOR, END, BEGIN, TIMES, OP, SC, NUMBER, ERROR };
const char* tokens[] = { "do", "for", "end", "begin", "times", "a",
                        ";", "NUMBER", NULL };

/* A global variable holding the current token */
int current_tok = ERROR;

/* Maximum length of a token */
#define TOKEN_LEN 128

/* declare functions corresponding to nonterminals */
void S(void);
void C(void);

int lex(void);
void consume_token(void);
void error(char *st);
void expect(int token);

void C(void)
{
    S();
    lex();
    if (current_tok == SC) {
        consume_token();
        C();
        printf("C => S ; C\n");
    } else {
        printf("C => S\n");
    }
}

void S(void)
```

---

<sup>1</sup>Tai niiden johdannaisia.

```

{
    lex();
    switch (current_tok) {
        case OP:
            consume_token();
            printf("S => a\n");
            break;
        case BEGIN:
            consume_token();
            C();
            expect(END);
            printf("S => begin C end\n");
            break;
        case FOR:
            consume_token();
            expect(NUMBER);
            expect(TIMES);
            expect(DO);
            S();
            printf("S => for N times do S\n");
            break;
        default:
            error("Parse error");
    }
}

/* int lex(void) returns the next token of the input. */
int lex(void)
{
    static char token_text[TOKEN_LEN];
    int pos = 0, c, i, next_token = ERROR;

    /* Is there an existing token already? */
    if (current_tok != ERROR)
        return current_tok;

    /* skip whitespace */
    do {
        c = getchar();
    } while (c != EOF && isspace(c));
    if (c != EOF) ungetc(c, stdin);

    /* read token */
    c = getchar();
    while (c != EOF && c != ';' && !isspace(c) && pos < TOKEN_LEN) {
        token_text[pos++] = c;
        c = getchar();
    }
    if (c == ';') {
        if (pos == 0) /* semicolon as token */
            next_token = SC;
        else /* trailing semicolon, leave it for future */
            ungetc(';', stdin);
    }
}

```

```

}

token_text[pos] = '\0'; /* trailing zero */

/* identify token */
if (isdigit(token_text[0])) { /* number? */
    next_token = NUMBER;
} else { /* not a number */
    for (i = D0; i < NUMBER; i++) {
        if (!strcmp(tokens[i], token_text)) {
            next_token = i;
            break;
        }
    }
}
current_tok = next_token;
return next_token;
}

void consume_token(void)
{
    current_tok = ERROR;
}

void error(char *st)
{
    printf(st);
    exit(1);
}

/* try to read a 'token' from input */
void expect(int token)
{
    int next_tok = lex();
    if (next_tok == token) {
        consume_token();
        return;
    } else
        error("Parse error");
}

int main(void)
{
    int i;
    C();
    return 0;
}

```