

DD1360 Programmeringsparadigm: Artificiella språk och syntaxanalys, föreläsning 3

Karl Palmskog

KTH

20 mars, 2023

Förra föreläsningen

- Mer formellt om automater
 - 5-tupel av mängder: $(Q, \Sigma, q_0, \delta, F)$
 - δ är en funktion (deterministiska automater)
- Reguljära språk
 - klass av språk som kan beskrivas av ändliga automater och reguljära uttryck
 - ändliga automater och reguljära uttryck har samma **uttrycksfullhet**
- Grammatiker
 - mer uttrycksfull formalism än reguljära uttryck och automater
 - kan beskriva språket $L = \{a^n b^n \mid n \geq 0\}$

Dagens föreläsning

- ① Lexikal analys
- ② Härledning och syntaxträd
- ③ Parsning genom rekursiv nedåkning
- ④ Eliminering av tvetydighet

① Lexikal analys

② Härledningar och syntaxträd

③ Parsning genom rekursiv medåkning

④ Eliminering av tvetydighet

Definition av lexikal analys

*Processen som omvandlar en sekvens av **tecken** till en sekvens av **tokens** (delar)*

Mål:

- Ta bort irrelevanta delar av en indatasträng, t ex
 - blanktecken/whitespace (blanksteg, nyrad, tabbar, ...)
 - kodkommentarer (oftast ej en del av kompilerad kod)
- Abstrahera bort detaljer från grammatiken, t ex
 - längsta matchning: "hello123 45" ska behandlas som tokensekvensen `Ident(hello123) Num(45)` snarare än `Ident(hello) Num(123) Num(4) Num(5)`

Tumregel: om en del av språket kan beskrivas av ett enkelt reguljärt uttryck så är det bättre att göra den delen till en token än till grammatikregler.

Lexikal analys av siffror och tal

- Idé: Förbehandla indatasträngen så att tal representeras av fullständiga tokens
- Exempel: indatasträngen "378*232*(582-01) "
 - indata som teckensekvens: '3', '7', '8', '*', '2', '3', '2', '*', '(', '5', '8', '2', '-', '0', '1', ')', ' ', ' '
 - tokensekvens: Num '*' Num '*' '(' Num '-' Num ') ' ' '
- Vissa tokens motsvarar enskilda tecken (som '*' och '('), medan andra består av delsträngar (som Num)
- Tokens kan också innehålla data, som heltalsvärdet för ett tal, t ex Num(378)
- Den genererade tokensekvensen blir **indata till parsern** (eller annat verktyg)

Analogi med naturliga språk

Den här meningen består av ord som består av bokstäver (tecken), och skiljetecken (kommatecken och parenteser).

- När vi kontrollerar stavning tittar vi på hur enskilda tecken byggts ihop till ord
- Ur ett stavningsperspektiv är de enskilda bokstäverna “byggstenarna”, eller tokens, i texten
- När vi kontrollerar grammatik tittar vi på hur olika typer av ord (substantiv, verb, adjektiv) och skiljetecken byggts ihop
- Ur ett grammatikperspektiv är meningen en sekvens av ordtyper och skiljetecken, dessa är här våra tokens

Exempel: “Ugglan dansar” är sekvensen <substantiv> <verb> (grovt förenklat, olika böjningar av ord har helt ignorerats)

Exempel på lexikal analys

Betrakta en Haskellfunktion:

```
myFunction alpha beta =  
  5 * x  
  where  
    -- compute difference  
    x = alpha-beta
```

Vilka tokens finns i funktionen?

- Namn: myFunction (funktion), alpha (parameter), beta (parameter), x (variabel)
- Nyckelord: where
- Operatorer/symboler: '=' (lika) '*' (gång), '-' (minus)
- Tal: 5 (heltal)

Möjlig tokenisering: Name Name Name Equal Num Times Name
Where Name Equal Name Minus Name

Blanktecken och kommentarhantering

- För programspråk bortses konventionellt från blanktecken och kommentarer (“äts upp”)
- Blanktecken **kan** dock vara del språket, exempel:
 - indentering i Python
 - nyrad i LaTeX
- Vissa språk stödjer nästlade kommentarer, t ex OCaml

```
(* yttre kommentar börjar
  (* inre kommentar börjar
    inre kommentar slutar *)
  yttre kommentar slutar *)
```

- ① Lexikal analys
- ② Härledningar och syntaxträd
- ③ Parsning genom rekursiv medåkning
- ④ Eliminering av tvetydighet

Härledningar

Betrakta följande grammatik:

$$\begin{aligned} \text{Expr} \rightarrow \text{Num} \mid \text{Expr} + \text{Expr} \mid \text{Expr} - \text{Expr} \\ \mid \text{Expr} * \text{Expr} \mid \text{Expr} / \text{Expr} \mid (\text{Expr}) \end{aligned}$$

En **härledning** av en indatasträng är en sekvens av de grammatikregler som genererar strängen.

Som exempel, låt oss härleda "4*(3+5)":


- Börja med **startsymbolen** i grammatiken
- I varje steg: **ersätt precis en ickeslutsymbol** med den högra sidan av en av dess produktionsregler

$$\begin{aligned} \text{Expr} \rightarrow \text{Expr} * \text{Expr} \rightarrow \text{Num} * \text{Expr} \rightarrow \text{Num} * (\text{Expr}) \rightarrow \\ \text{Num} * (\text{Expr} + \text{Expr}) \rightarrow \text{Num} * (\text{Num} + \text{Expr}) \rightarrow \\ \text{Num} * (\text{Num} + \text{Num}) \end{aligned}$$

Syntaxträd

Ett **syntaxträd** representerar en (mängd av) härledningar och kapslar in **semantiken** för en indatasträng.


$\underline{\text{Expr}} \rightarrow \underline{\text{Expr}} * \text{Expr} \rightarrow \text{Num} * \underline{\text{Expr}} \rightarrow \text{Num} * (\underline{\text{Expr}}) \rightarrow$
 $\text{Num} * (\underline{\text{Expr}} + \text{Expr}) \rightarrow \text{Num} * (\text{Num} + \underline{\text{Expr}}) \rightarrow$
 $\text{Num} * (\text{Num} + \text{Num})$



Semantik för syntaxträd

Exempel: syntaxträdet kapslar in semantiken för ett uttryck (ett program).

- Syntaxträd möjliggör att **evaluera ett uttryck**: utför beräkningen och erhåll **värdet**
- Behöver veta heltalsvärdena för Num-tokens: lägg till som data
- Evaluering utförs som **trädtraversering**



Härledningar och träd

$$\text{Expr} \rightarrow \text{Num} \mid \text{Expr} + \text{Expr} \mid \text{Expr} - \text{Expr} \\ \mid \text{Expr} * \text{Expr} \mid \text{Expr} / \text{Expr} \mid (\text{Expr})$$

Betrakta följande uttryck: $3 + 5 * 4$

- Går det att hitta två olika **härledningar**?
- Går det att hitta två olika **syntaxträd**?

$$\underline{\text{Expr}} \rightarrow \underline{\text{Expr}} + \text{Expr} \rightarrow \text{Num} + \underline{\text{Expr}} \rightarrow \text{Num} + \underline{\text{Expr}} * \text{Expr} \rightarrow \\ \text{Num} + \text{Num} * \underline{\text{Expr}} \rightarrow \text{Num} + \text{Num} * \text{Num}$$

$$\underline{\text{Expr}} \rightarrow \text{Expr} + \underline{\text{Expr}} \rightarrow \text{Expr} + \text{Expr} * \underline{\text{Expr}} \rightarrow \\ \text{Expr} + \underline{\text{Expr}} * \text{Num} \rightarrow \underline{\text{Expr}} + \text{Num} * \text{Num} \rightarrow \text{Num} + \text{Num} * \text{Num}$$

- 1 Lexikal analys
- 2 Härledningar och syntaxträd
- 3 Parsning genom rekursiv medåkning
- 4 Eliminering av tvetydighet

Parsning genom rekursiv medåkning

Metod för att konstruera en effektiv parser för en given grammatik:

- En indatasträng parsas enligt produktionsreglerna som krävs för dess härledning
- När en sträng för en ickeslutsymbol ska parsas, **titta framåt** på nästa token för att välja motsvarande produktionsregel
- För varje ickeslutsymbol, skapa en **rekursiv funktion** som parsar den ickeslutsymbolen
- Parsa en produktionsregel på följande sätt:
 - För varje slutsymbol: kolla om den matchar nästa token
 - För varje ickeslutsymbol: anropa funktionen för motsvarande ickeslutsymbol

Grammatik för binära träd

```
<BinTree> ::= Leaf LPar Num RPar  
           | Branch LPar <BinTree> Comma <BinTree> RPar
```

Slutsymboler:

- Leaf: "leaf"
- Branch: "branch"
- Num: [0-9]+
- LPar: '(', RPar: ')', Comma: ',',

Exempel:

```
branch(branch(leaf(17),leaf(42)),leaf(5))
```

Resultat från lexikal analys:

```
Branch LPar Branch LPar Leaf LPar Num RPar Comma Leaf  
LPar Num RPar RPar Comma Leaf LPar Num RPar RPar
```

Parser för binära träd i Java

```
<BinTree> ::= Leaf LPar Num RPar  
           | Branch LPar <BinTree> Comma <BinTree> RPar
```

```
ParseTree BinTree() throws SyntaxError {  
    Token t = lexer.peekToken();  
    if (t.getType() == TokenType.Leaf) {  
        lexer.nextToken();  
        expect(TokenType.LPar);  
        Token param = expect(TokenType.Num);  
        expect(TokenType.RPar);  
        return new LeafNode((Integer) param.getData());  
    } else if (t.getType() == TokenType.Branch) {  
        lexer.nextToken();  
        expect(TokenType.LPar);  
        ParseTree left = BinTree();  
        expect(TokenType.Comma);  
        ParseTree right = BinTree();  
        expect(TokenType.RPar);  
        return new BranchNode(left, right);  
    } else { throw new SyntaxError(); }  
}
```

Katter och hundar

```
<Start> ::= 'c' <Cat> | 'd' <Dog>
<Cat> ::= 'p' | 'z' | 'f' <Dog> | <Start> <Start>
<Dog> ::= 'p' | 'z' | 'b' <Cat> | <Start>
```

```
function Cat():
    char next = peekChar();
    if (c == 'p') // Cat, regel 1
        eatChar(); // gå förbi 'p'
    else if (c == 'z') // Cat, regel 2
        eatChar(); // gå förbi 'z'
    else if (c == 'f') // Cat, regel 3
        eatChar(); // gå förbi 'f'
        Dog(); // ska nu komma en Dog
    else // måste vara Cat, regel 4
        Start(); // första Start
        Start(); // andra Start
```

- ① Lexikal analys
- ② Härledningar och syntaxträd
- ③ Parsning genom rekursiv medåkning
- ④ Eliminering av tvetydighet

Tvetydig uttrycksgrammatik

$$\text{Expr} \rightarrow \text{IntLiteral} \mid \text{Ident} \mid \text{Expr} + \text{Expr} \mid \text{Expr} / \text{Expr}$$

`foo + 42 / bar + arg`

- Varje nod i syntaxträdet ges av ett grammatikalternativ
- Indatasträngen ovan har två syntaxträd

Använd prioritetslager i grammatiken

$$\text{Expr} \rightarrow \text{Ident} \mid \text{Expr} - \text{Expr} \mid \text{Expr} \wedge \text{Expr} \mid (\text{Expr})$$

omvandlas till

$$\text{Expr} \rightarrow \text{Term} (- \text{Term})^*$$

$$\text{Term} \rightarrow \text{Factor} (\wedge \text{Factor})^*$$

$$\text{Factor} \rightarrow \text{Ident} \mid (\text{Expr})$$

Hantera högerassociativ operator

Använd rekursion (eller loopa och omvänd en lista)

$$x^y^z \rightarrow x^{(y^z)}$$

`Exp(Var("x"), Exp(Var("y"), Var("z")))`

```
Expr term() {  
    Expr e = factor();  
    if (lexer.token == ExpToken) {  
        lexer.next();  
        return new Exp(e, term());  
    } else {  
        return e;  
    }  
}
```

Hantera vänsterassociativ operator

$$x - y - z \rightarrow (x - y) - z$$

```
Minus(Minus(Var("x"), Var("y")), Var("z"))
```

```
Expr expr() {  
    Expr e = term();  
    while (lexer.token == MinusToken) {  
        lexer.next();  
        e = new Minus(e, term());  
    }  
    return e;  
}
```

Grammatiker och tvetydighet

- Om vi kan hitta en sträng med **två olika syntaxträd** är grammatiken **tvetydig**
- Tvetydighet påverkar inte vilket språk grammatiken definierar
- Det kan vara svårt att bestämma om en grammatik är tvetydig eller ej
 - problemet är **oavgörbart**: det finns ingen generell algoritm
- Hur man gör grammatiker entydiga:
 - säkerställ att det bara finns ett syntaxträd per korrekt sträng
 - beakta associativitet och andra egenskaper vid syntaxträds konstruktion
- Tvetydiga grammatiker kan fortfarande vara användbara, t. ex. för teori om språk

Manuell konstruktion av en parser

- Applicera föregående transformationer för att få en mer parsebar grammatik
- Skriv sedan en parser med rekursiv nedåtgång som avgör om indata är korrekt
- Ornamentera sedan parsern för att konstruera träd, och ta då hänsyn till associativitet och prioritet för operatorer

Grammatik kontra rekursiv medåkning

$\text{Expr} \rightarrow \text{Term TermList} \quad \text{Term} \rightarrow \text{Factor FactorList}$

$\text{TermList} \rightarrow + \text{Term TermList} \mid - \text{Term TermList} \mid \epsilon$

$\text{FactorList} \rightarrow * \text{Factor FactorList} \mid / \text{Factor FactorList} \mid \epsilon$

$\text{Factor} \rightarrow \text{Ident} \mid (\text{Expr})$

```
def expr = { term; termList }
def termList =
  if (token == PLUS) {
    skip(PLUS); term; termList
  } else if (token == MINUS)
    skip(MINUS); term; termList
  }
def term = { factor; factorList }
...
def factor =
  if (token == IDENT) name
  else if (token == LPAR) {
    skip(LPAR); expr; skip(RPAR)
  } else { error("expected ident or (") }
```

Sammanfattning av rekursiv medåkning

- En av de **mest använda** metoderna för att parsa kod i kompilatorer för generalistiska programspråk, exempel:
 - GCC frontend för C/C++
 - Javas referenskompilator
 - Scalas referenskompilator
- **Effektiv** (linjär) i tokensekvensens längd
- **Rättfram att implementera manuellt** baserat på en grammatik
 - finns även **parsergeneratorer** som ger källkod som utdata
- Nära överensstämmelse mellan grammatik och kod
 - vanligt att citera grammatiken i kommentarer

Parsergenerering utan medåkning

$$\text{Prop} \rightarrow \perp \mid \neg \text{Prop} \mid p \mid \text{Prop} \wedge \text{Prop} \mid \text{Prop} \vee \text{Prop} \\ \mid \text{Prop} \Rightarrow \text{Prop} \mid (\text{Prop})$$

```
%token <string> IDENT
```

```
%token COMMA LPAREN RPAREN CONT NOT AND OR IMPLIES
```

```
%right IMPLIES
```

```
%left AND
```

```
%left OR
```

```
%right NOT
```

```
prop:
```

```
    CONT {} \ NOT prop {} \ IDENT {} \ prop AND prop {}  
    \ prop OR prop {} \ prop IMPLIES prop {}  
    \ LPAREN prop RPAREN {}  
    ;
```

Talseriegrammatik

Betrakta följande grammatik:

`<Nums> ::= Num <NumsAux> | NoNums`

`<NumsAux> ::= <NumsAux> SemiColon Num | Epsilon`

- Startsymbol: `<Nums>`
- Num: `[0-9]+`
- SemiColon: `' ; '`
- NoNums: `' _ '`
- Epsilon: tomma strängen
- Exempelsträng: `1;2;3`

Kan vi parsra den här grammatiken med rekursiv medåkning?

Talseriegrammatik, fortsättning

$\langle \text{Nums} \rangle ::= \text{Num } \langle \text{NumsAux} \rangle \mid \text{NoNums}$

$\langle \text{NumsAux} \rangle ::= \langle \text{NumsAux} \rangle \text{ SemiColon Num} \mid \text{Epsilon}$

- Rekursiv medåkning måste terminera på varje (ändlig) indatasträng för att parse korrekt
- Implementationer av NumsAux regel 1 måste göra anrop till NumsAux och når därmed aldrig basfall
- Givna grammatiken kan **inte** parsas med rekursiv medåkning (ty den är **vänsterrekursiv**)
- Med **högerrekursiv** grammatik för samma språk fungerar rekursiv medåkning

$\langle \text{Nums} \rangle ::= \text{Num } \langle \text{NumsAux} \rangle \mid \text{NoNums}$

$\langle \text{NumsAux} \rangle ::= \text{SemiColon Num } \langle \text{NumsAux} \rangle \mid \text{Epsilon}$

Vilka uttryck är tvetydiga?

Betrakta följande grammatik:


$\langle \text{Exp} \rangle ::= \langle \text{Exp} \rangle \text{ Minus } \langle \text{Exp} \rangle \mid \text{Num} \mid \text{LPar } \langle \text{Exp} \rangle \text{ RPar}$

- Startsymbol:
- Minus: '-'
- Num: $[0-9]^+$
- LPar: '('
- RPar: ')'

Hur kan vi känna igen tvetydiga uttryck som genereras av grammatiken? (Inte nödvändigtvis alla.)

Att bygga en automat för tvetydighet

- Kärnan är att minusoperatoren kan associera på flera sätt
 - $1 - 4 - 5$ kan tolkas som $(1 - 4) - 5$
 - $1 - 4 - 5$ kan tolkas som $1 - (4 - 5)$ också
- Men: parenteser kan göra uttryck entydiga
- Vi antar att vi bara får tokensekvenser enligt grammatiken



Utökningar av BNF

- För att göra det lättare att skriva BNF-grammatiker kan vi införa **utökningar av BNF**
- En möjlig utökning är ? för “noll eller en gång” (som för reguljära uttryck)
- Men: grammatiker med utökningar ska kunna skrivas om i vanliga BNF

`<Stm> ::= If <Exp> Then <Stms> [ Else <Stms> ]? End`

Hur kan vi skriva om denna deklaration i vanlig BNF? Hur generaliserar vi det till godtyckliga användningar av ??

Omskriven utökad grammatik

`<Stm> ::= If <Exp> Then <Stms> [ Else <Stms> ]? End`

- För varje förekomst av ? i ett högerled inför vi två stycken regler istället för den gamla regeln.
- I första regel utelämnar vi innehållet inom hakparenteser
- I andra regeln tar vi med innehållet inom hakparenteser

`<Stm> ::= If <Exp> Then <Stms> End`

`| If <Exp> Then <Stms> End <Stms> End`