Kontekstfrie grammatikker og syntaksanalyse (parsering)

INF5110 - kap.3 i Louden + hjelpenotat (se hjemmesida)

Arne Maus
Ifi, UiO – v2006

Hvor er vi nå - kap. 3 (+4,5) ?

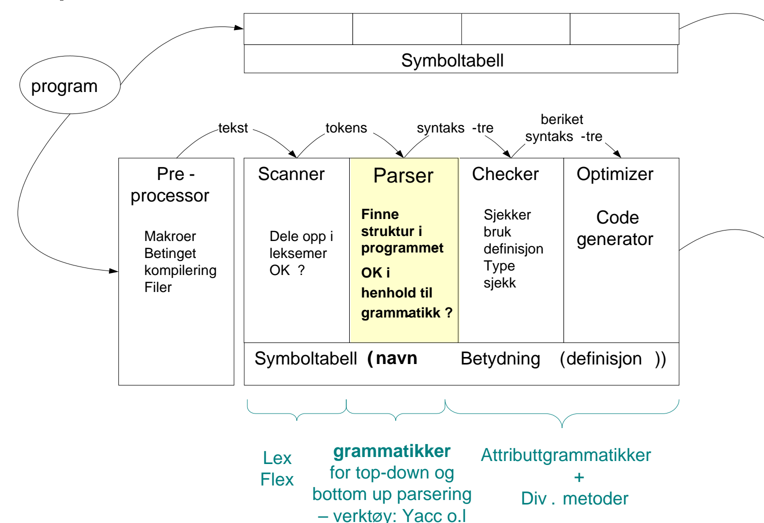

Forenklet skisse av hva en parser gjør

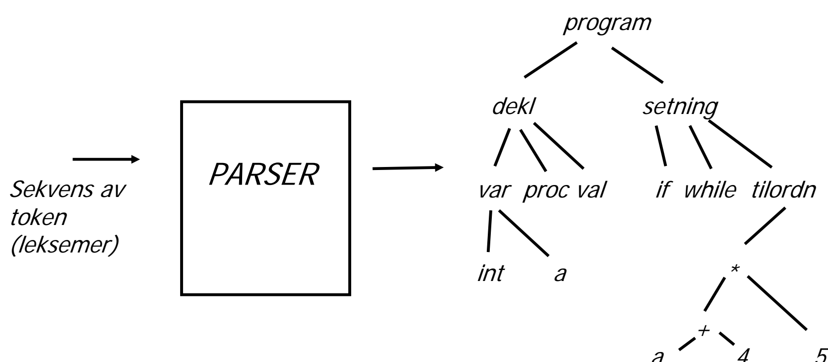

Oversikt – kap 3 (grunnleggende om grammatikker)

- Hva er en grammatikk
- Vi kommer til å lære flere (mange) typer grammatikk
  - hvorfor ?
- Kontekstfrie grammatikker
- Parserings-trær og abstrakte syntaks-trær
- Tvetydige grammatikker
- Utvidet notasjon: EBNF og syntaksdiagrammer
- Eksempel
  - Tiny

Hva får vi fra parseren

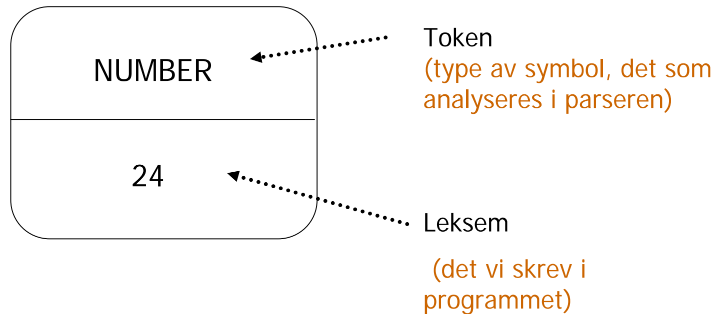

Token
(type av symbol, det som analyseres i parseren)

Leksem

(det vi skrev i programmet)

Av og til vil vi gi eksempler med token og av og til med leksem

Hva er en grammatikk

- En grammatikk bruker et alfabet
  - Som oftest det vi kan taste inn fra tastaturet
- En grammatikk består av noen **symboler** = sammensetninger av tegn fra alfabetet:
  - **Terminal-symboler** - slike vi bruker når vi programmerer
    Dvs. for parseren er det slike tokens/leksemer vi får fra skanneren:
    - int, TALL, if , VARIABEL, ...
  - **Ikke-terminalsymboler** - begreper vi bruker i grammatikken):
    - WHILE-setning, TILORDNING, KLASSEDEKL,UTTRYKK...
    - Startsymbolet : Lovlige setninger er utledet fra dette.
  - **Meta-symboler**- slike hjelpesymboler/tegn vi bruker for å sette opp reglene:
- En grammatikk spesifiserer via regler lovlige sammensettinger av terminal- og ikke-terminalsymboler:

```
<exp> ::= <exp> <op> <exp> | (<exp>) | NUMBER
<op> ::= + | - | *
```

Grammatikk - eksempel

- Grammatikken:

```
<exp> ::= <exp> <op> <exp> | (<exp>) | NUMBER
<op> ::= + | - | *
```

- Metasymboler: ::=, <,>,|
- Ikke-terminaler: exp, op
- Terminaler : NUMBER, (,), *, +, -

::= ' leses som:'	kan bestå av
| 'betyr'	eller

Rollen til en grammatikk, semantikk og syntaks

- En grammatikk definerer *visse sider* av et språk – **syntaksen** (skrivereglene)
  - Gjelder naturlige språk (tysk,.., norsk)
  - Gjelder alle kunstige språk som programmeringsspråk
  - Ikke alle de setningene vi kan lage i grammatikken, gir mening
- **Semantikken** (meningen) med de ulike delene spesifiseres separat – se kap.6.
- En grammatikk definerer regler for sammensetting av de ulike elementene (terminalsymbolene) vi har i et språk.
  - Eks: En regel for en viss type setning på norsk er at den består av (spesifisert på BNF):
    <Setning> → <Subjekt><Predikat> | <Setning><Prep><Objekt>
    <Subjekt> → Per | Huset
    <Predikat> → løper | ler | står | slår | bygger
    <Objekt> → Kari | Huset | Per
  - En grammatikk kan lage (utlede) mange, ofte uendelig mange setninger
    - Noen følger grammatikken , men følger ***ikke*** semantikken og er da ikke setninger i språket
      - Eks: `int i = true;`
    - Noen følger både syntaksen og semantikken og er da korrekte setninger i språket , og vil da også kompilere
      - Men det er ikke sikkert at de løser problemet vårt (er riktige sett ut fra hva programmet skal gjøre)

Hvorfor ikke bare én (stor) grammatikk?

- Kunne vi ikke laget en (stor) grammatikk som sa 'alt' om språket
  - F. eks det som tas av skanneren –hvordan tall og variable er definert
  - Som sa at det skal være samme type på hver side av en tilording
  - Som ordnet alle presedensregler mellom operatorer (multiplikasjon før addisjon,... osv)
- Grammatikker spesifiserer ikke 'alt' ved språket, fordi:
  - En slik grammatikk vil bli 'uhåndterlig stor'
  - Vanskelig/"nær umulig" å formulere visse aspekter ved et språk
  - mye raskere å ta:
    - enkle ting i skanneren,
    - setningsformen i parseren
    - mer kompliserte krav i semantikk - sjekkeren
      - jfr. samlebåndsproduksjon av biler (bilen lages i flere steg)
- Må ofte jobbe med hvordan vi formulerer en grammatikk for at den skal gi en god/riktig parser
  - flere måter å formulere grammatikken for et språk

Kontekstfrie grammatikker, BNF notasjon med variasjoner

- Bokas notasjon

  exp → exp op exp | (exp) | number

  op → + | - | *

- En tradisjonell måte (Algol 60 rapporten)

```
<exp> ::= <exp> <op> <exp> | (<exp>) | NUMBER
<op> ::= + | - | *
```

- Litt utvidet BNF

  exp → *exp* ("**+**" | "**-**" | "*****") *exp* | "**(**" *exp* "**)**" | **number**

Flere måter å skrive den samme grammatikken

- Regnes som den mest basale

  exp → *exp op exp*
  exp → **(** *exp* **)**
  exp → **number**
  op → **+**
  op → **-**
  op → *****

- Kortest mulig

  $E \rightarrow E\ O\ E \mid (\ E\ ) \mid n$
  $O \rightarrow + \mid - \mid *$

Avledning (venstreavledning) av: (number – number) * number

exp → *exp op exp*
exp → **(** *exp* **)**
exp → **number**
op → **+**
op → **-**
op → *****

	Startsymbol	Produksjon brukt
(1)	*exp* ⇒ *exp op exp*	[*exp* → *exp op exp*]
(2)	⇒ **(***exp***)** *op exp*	[*exp* → **(** *exp* **)**]
(3)	⇒ **(***exp op exp***)** *op exp*	[*exp* → *exp op exp*]
(4)	⇒ **(number** *op exp***)** *op exp*	[*exp* → **number**]
(5)	⇒ **(number** – *exp***)** *op exp*	[*op* → **-**]
(6)	⇒ **(number - number)** *op exp*	[*exp* → **number**]
(7)	⇒ **(number - number) *** *exp*	[*op* → *****]
(8)	⇒ **(number - number) * number**	[*exp* → **number**]

Vestreavledning = avleder med terminaler fra venstre
Ferdig når det bare er terminalsymboler

$L(G) = \{\ s \mid exp \Rightarrow^* s\ \}$

grammatikk — *streng med bare terminal-symboler*

Avledning (høyreavledning)

av: (number – number) * number

$exp \to exp\ op\ exp$
$exp \to$ (exp)
$exp \to$ **number**
$op \to$ +
$op \to$ -
$op \to$ *

	Startsymbol	Produksjon brukt
(1)	$exp \Rightarrow exp\ op\ exp$	[$exp \to exp\ op\ exp$]
(2)	$\Rightarrow exp\ op$ **number**	[$exp \to$ **number**]
(3)	$\Rightarrow exp$ * **number**	[$op \to$ *]
(4)	$\Rightarrow$ (exp) * **number**	[$exp \to$ (exp)]
(5)	$\Rightarrow$ ($exp\ op\ exp$) * **number**	[$exp \to exp\ op\ exp$]
(6)	$\Rightarrow$ ($exp\ op$ **number**) * **number**	[$exp \to$ **number**]
(7)	$\Rightarrow$ (exp - **number**) * **number**	[$op \to$ -]
(8)	$\Rightarrow$ (**number** - **number**)***number**	[$exp \to$ **number**]

Høyreavledning = avleder med terminaler fra høyre
Ferdig når det bare er terminalsymboler

Det finnes også mange andre rekkefølger å avlede en setning fra en grammatikk

Opplagte krav til en grammatikk

Alle ikke-terminaler:

- Må kunne inngå i en streng avledet fra startsymbolet
- Må kunne avledes videre til noe som bare inneholder terminal-symboler

- Eks:

  A→ Bx

  B → Ay

  C → z

  - Kan aldri avlede fra A til bare terminalsymboler
  - C kan ikke inngå i noen streng avledet fra A

Altså en håpløs grammatikk

Parserings-tre (konkret syntaks-tre)

(1)	$exp \Rightarrow exp\ op\ exp$
(2)	$\Rightarrow$ **number** $op\ exp$
(3)	$\Rightarrow$ **number** + exp
(4)	$\Rightarrow$ **number** + **number**

- Representasjon som er uavhengig av avlednings-rekkefølgen

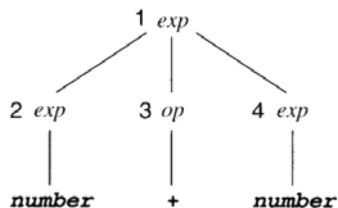

- Tallene angir høyre/avledning
- Ser vi bort fra tallene, gir alle avlednings/rekkefølger det samme treet

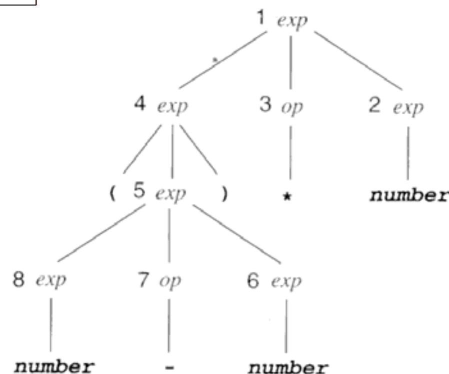

(Abstrakt) syntakstre – forlengs polsk notasjon
- "fra tre til fil-format" – det vi egentlig trenger videre

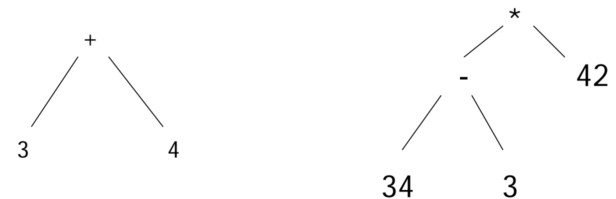

*Prefix-form av treet for (34-3)*42: ("veltet til venstre" – prefiks traversering – først noden, så venstre sub-tre, så høyre sub-tre):*

OpExp(Times, OpExp(Minus, Const(34), Const(3)), Const(42))

Flere parserings-trær

G1:

statement → *if-stmt* | **other**
if-stmt → **if (** *exp* **)** *statement*
| **if (** *exp* **)** *statement* **else** *statement*
exp → **0** | **1**

Setning:

```
if (0) other else other
```

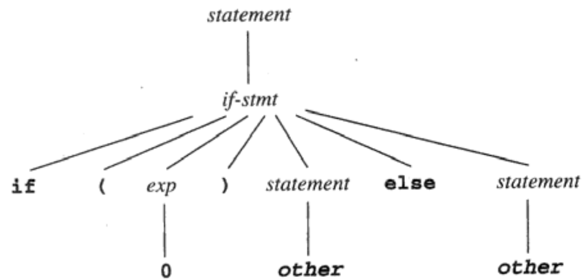

En annen grammatikk G2 for if-setninger

G2:

statement → *if-stmt* | **other**
if-stmt → **if (** *exp* **)** *statement else-part*
else-part → **else** *statement* | ε
exp → **0** | **1**

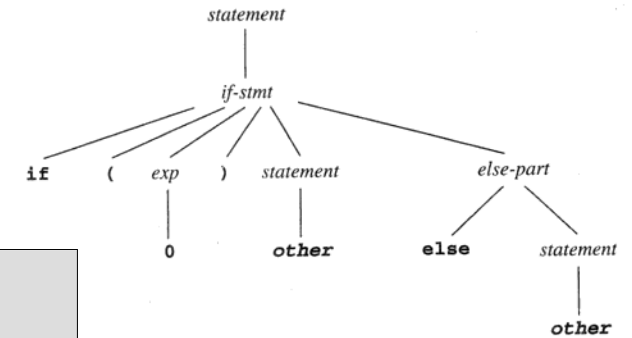

Felles abstrakt syntaks-tre for G1 og G2:

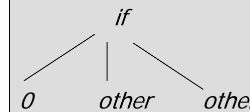

Tvetydige grammatikker - analyse av setningen: n - n * n

*G er flertydig hvis det finnes en setning i L(G) som kan gis **flere** parserings-trær*

Dette eksempelet er essensiell tvetydighet, angir ulike beregninger.

exp → *exp op exp* | **(** *exp* **)** | **number**
op → **+** | **-** | *****

Konkret

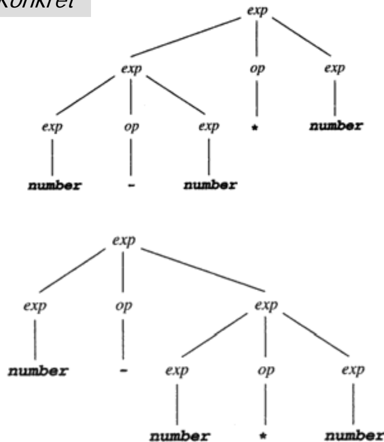

Abstrakt

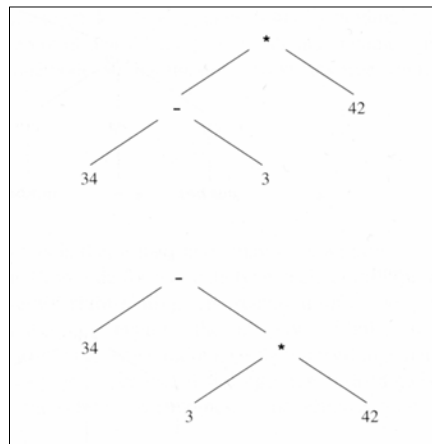

Entydige grammatikker for samme språket, to trær for to *ulike* uttrykk.

exp → *exp addop term* | *term*
addop → **+** | **-**
term → *term mulop factor* | *factor*
mulop → *****
factor → **(** *exp* **)** | **number**

34-3*42

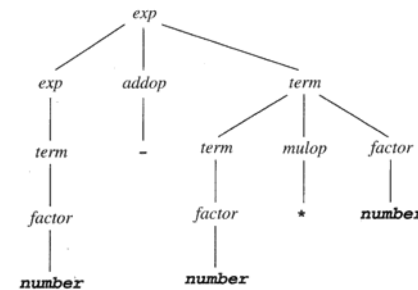

34-3-42

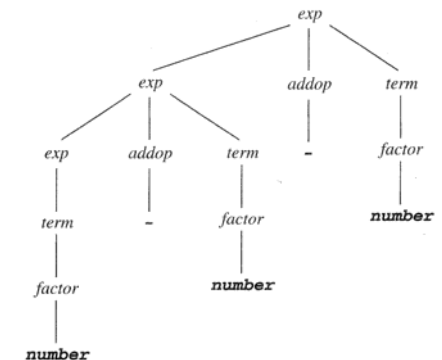

To eksempler på viktigheten av assosiativitet (og presedens)

a) Melding til lederen for en eksekusjons-peletong:

- Stopp ikke skyt ham !
  - Stopp ikke - skyt ham
  - Stopp - ikke skyt ham

b) uttrykket : 3 - 4 - 5

- 3 - (4-5) = 3-(-1) = 4 høyre
- (3-4) -5 = - 6 venstre

Presedens og assosiativitet uttrykt i grammatikken

- Presedens i grammatikken for operatorer
  - Noen operasjoner gjøres før andre (* før +)
  - Ordnes med kaskading av definisjoner av operatorgrupper (addop, multop, expop,..) – se forrige grammatikk
- Assosiativitet i grammatikken for operatorer:
  - Venstre (assositivitet) : Operatorer med samme presedens utføres fra venstre mot høyre
  - Høyre (assositivitet) : Operatorer med samme presedens utføres fra høyre mot venstre.
  - Ingen (assositivitet) : Tillater ingen rekkefølge av slike operasjoner. i samme .
  - Ordnes med at uttrykk med slike operatorer bare kan utvides på den ene siden :
    exp → exp addop term | *term*
    (denne utvider på venstre side og blir venstre assisiativ)
    Ingen assosiativitet ordnes med at vi krever parenteseser med bare en operator i en parentes.

Vanlig å:

- Angi språket ved flertydige grammatikk som

$$exp \rightarrow exp\ op\ exp \mid (\ exp\ ) \mid \mathbf{number}$$
$$op \rightarrow + \mid - \mid *$$

- Oppgi regler for presedens og assosiativitet for hver operasjon, slik at alle setninger får ett entydig syntakstre:
  +, lav, venstre ass.
  *, høy , venstre-ass
  ↑ , høyerst, høyre ass.

- Dette er helt greit for binære infix-operatorer, men fungerer "vanligvis" også greit for unære postfiks eller prefiks operatorer

- 3+5 * 3 * 2 + 4 ↑2 * 3

Presendens og assosiativitet i Java

Venstre assosiativ

Operator Precedence

Java performs operations assuming the following ordering (or ***precedence***) rules if parentheses are not used to determine the order of evaluation (operators on the same line are evaluated in left-to-right order subject to the conditional evaluation rule for && and ||). The operations are listed below from highest to lowest precedence (we use ⟨exp⟩ to denote an atomic or parenthesized expression):

```
postfix ops      [] . (⟨exp⟩) ⟨exp⟩++ ⟨exp⟩--
prefix ops       ++⟨exp⟩ --⟨exp⟩ -⟨exp⟩ ~⟨exp⟩ !⟨exp⟩
creation/cast    new (⟨type⟩)⟨exp⟩
mult./div.       * / %
add./subt.       + -
shift            << >> >>>
comparison       < <= > >= instanceof
equality         == !=
bitwise-and      &
bitwise-xor      ^
bitwise-or       |
and              &&
or               ||
conditional      ⟨bool_exp⟩? ⟨true_val⟩: ⟨false_val⟩
assignment       =
op assignment    += -= *= /= %=
bitwise assign.  >>= <<= >>>=
boolean assign.  &= ^= |=
```

Ikke-essensiell flertydighet

stm-seq → stm-seq; stm | stm   *venstre-ass*

stm-seq → stm; stm-seq | stm   høyre-ass

stm → s

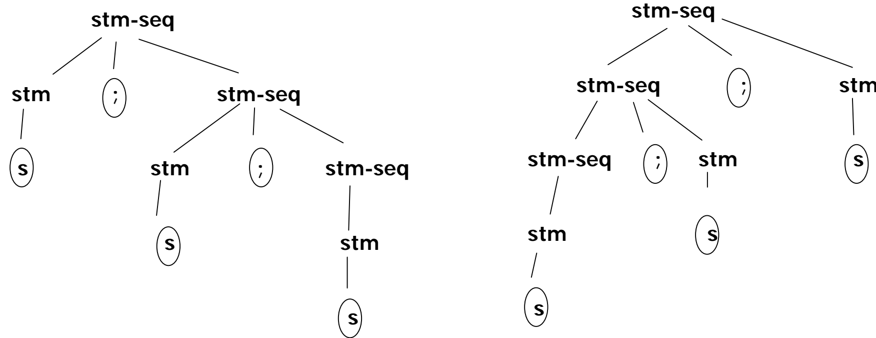

Kan like gjerne representeres som:

seq   eller: seq

s s s   s → s → s

"Dangelig else" - problemet

- Problem: Hvilken **if**-setning skal vi koble **else** til?

```
if (0) if (1) other else other
```

- Grammatikken (tvetydig):

statement → *if-stmt* | **other**
if-stmt → **if (** *exp* **)** *statement*
  | **if (** *exp* **)** *statement* **else** *statement*
exp → **0** | **1**

To muligheter:

statement → *if-stmt* | **other**
if-stmt → **if (** *exp* **)** *statement*
  | **if (** *exp* **)** *statement* **else** *statement*
exp → **0** | **1**

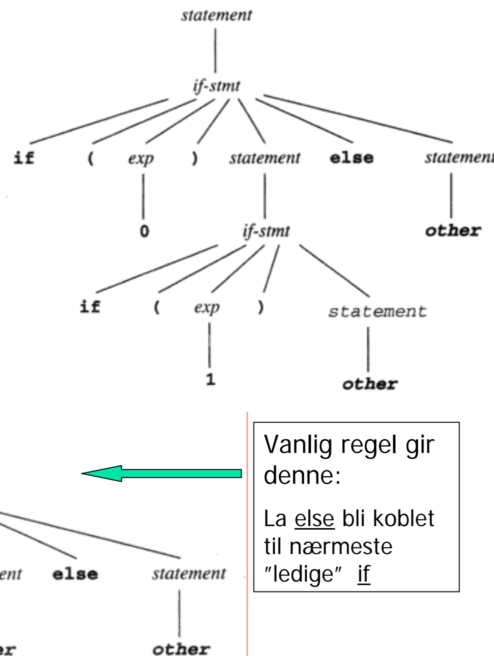

statement
if-stmt
if (exp) statement
0
if-stmt
if (exp) statement else statement
1 other other

Vanlig regel gir denne:

La else bli koblet til nærmeste "ledige" if

Eks: Entydig grammatikk for if-setning. Gir "vanlig" løsning

```
if (0) if (1) other else other
```

statement → *matched-stmt* | *unmatched-stmt*
matched-stmt → **if (** *exp* **)** *matched-stmt* **else** *matched-stmt* | **other**
unmatched-stmt → **if (** *exp* **)** *statement*
  | **if (** *exp* **)** *matched-stmt* **else** *unmatched-stmt*
exp → **0** | **1**

Idé:

matched-stmt
- kan ***ikke*** kobles med etterfølgende else

unmatched-stmt
- kan kobles med etterfølgende else

Er det opplagt at denne kan generere alle "lovlige" setninger (ut fra den kortere flertydige grammatikken på forrige to foiler)?

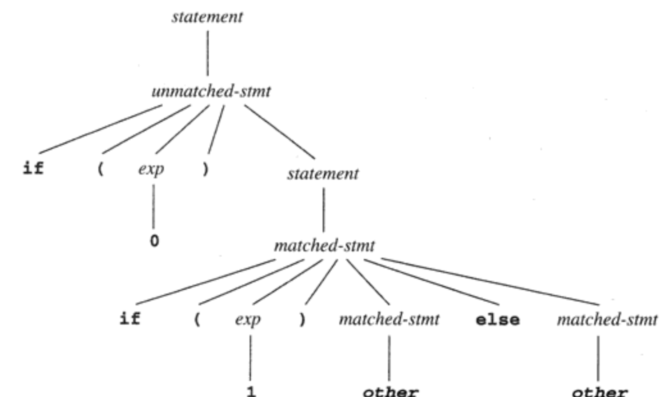

Utvidet BNF (EBNF)

Idé: Man kan generelt bruke "regulære uttrykk" på høyresiden i produksjoner

Vanlig: $\alpha *$ skrives : $\{\alpha\}$ α er en streng av
$\alpha\ ?$ skrives: $[\alpha]$ terminaler og ikke-terminaler

Eksempel:

exp → *exp* ("+" | "–" | "*") *exp* | "(" *exp* ")" | **number**

Meta-symbol ikke-meta

A → A α | β kan skrives: A → β {α }
A → α A | β kan skrives: A → {α} β
stm-seq → stm {; stm} eller → {stm;} stm
if-setn → if (expr) stm [else stmt]

Merk: For en del metoder etc. må man gå ut fra basal BNF.

Syntaks-diagrammer

factor → (*exp*) | **number**

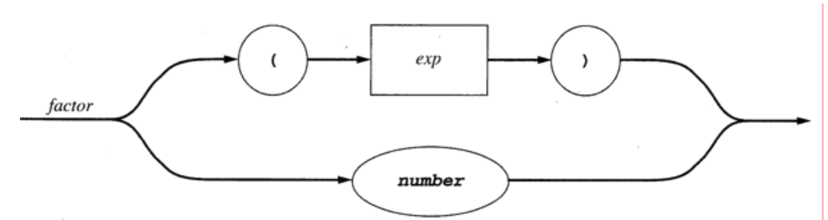

A → { *B* }

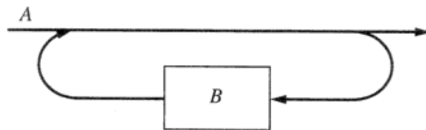

A → [*B*]

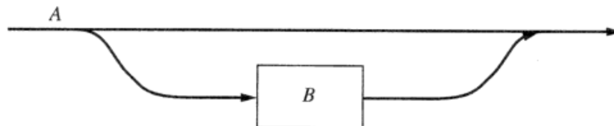

BNF-grammatikk

exp → *exp addop term* | *term*
addop → **+** | **–**
term → *term mulop factor* | *factor*
mulop → *****
factor → **(** *exp* **)** | **number**

EBNF-grammatikk for samme "språket", brukes til å lage syntaksdiagrammene

exp → *term* { *addop term* }
addop → **+** | **–**
term → *factor* { *mulop factor* }
mulop → *****
factor → **(** *exp* **)** | **number**

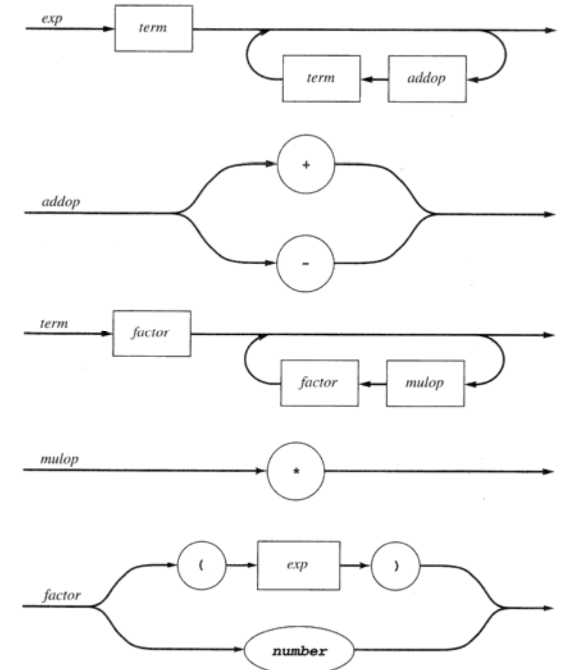

Chomsky-hierarkiet

a er vilkårlig terminalsymb.
β, α, γ er vilkårlig samling av terminal- og ikke-terminalsymb.
A, B er ikke-terminaler

- Type 0 – språk
  - Urestrikterte prod.: $\alpha \to \beta, \quad \alpha \neq \varepsilon$ (α er ikke-tom)
- Type 1 – språk
  - Kontekst-sensitive produksjoner $\beta A \gamma \to \beta \alpha \gamma$
- Type 2 – språk
  - Kontkstfrie prod: $A \to \alpha$
- Type 3 språk
  - Regulære språk:
    - Regulære utrykk
    - NFA
    - DFA

Produksjoner bare på formen:
$A \to Ba$ og $A \to a$
eller
$A \to aB$ og $A \to a$

BNF-grammatikk for TINY

program → *stmt-sequence*
stmt-sequence → *stmt-sequence* **;** *statement* | *statement*
statement → *if-stmt* | *repeat-stmt* | *assign-stmt* | *read-stmt* | *write-stmt*
if-stmt → **if** *exp* **then** *stmt-sequence* **end**
| **if** *exp* **then** *stmt-sequence* **else** *stmt-sequence* **end**
repeat-stmt → **repeat** *stmt-sequence* **until** *exp*
assign-stmt → **identifier** **:=** *exp*
read-stmt → **read identifier**
write-stmt → **write** *exp*
exp → *simple-exp comparison-op simple-exp* | *simple-exp*
comparison-op → **<** | **=**
simple-exp → *simple-exp addop term* | *term*
addop → **+** | **-**
term → *term mulop factor* | *factor*
mulop → ***** | **/**
factor → **(** *exp* **)** | **number** | **identifier**

Nodestruktur i C for TINY

```
typedef enum {StmtK,ExpK} NodeKind;
typedef enum {IfK,RepeatK,AssignK,ReadK,WriteK}
             StmtKind;
typedef enum {OpK,ConstK,IdK} ExpKind;

/* ExpType is used for type checking */
typedef enum {Void,Integer,Boolean} ExpType;

#define MAXCHILDREN 3

typedef struct treeNode
   { struct treeNode * child[MAXCHILDREN];
     struct treeNode * sibling;
     int lineno;
     NodeKind nodekind;
     union { StmtKind stmt; ExpKind exp;} kind;
     union { TokenType op;
             int val;
             char * name; } attr;
     ExpType type; /* for type checking of exps */
   } TreeNode;
```

Nodestruktur i C for TINY

Denne nodestrukturen passer enda bedre med et OO-språk med klasser /sublklasser **som implementasjons-språk.**

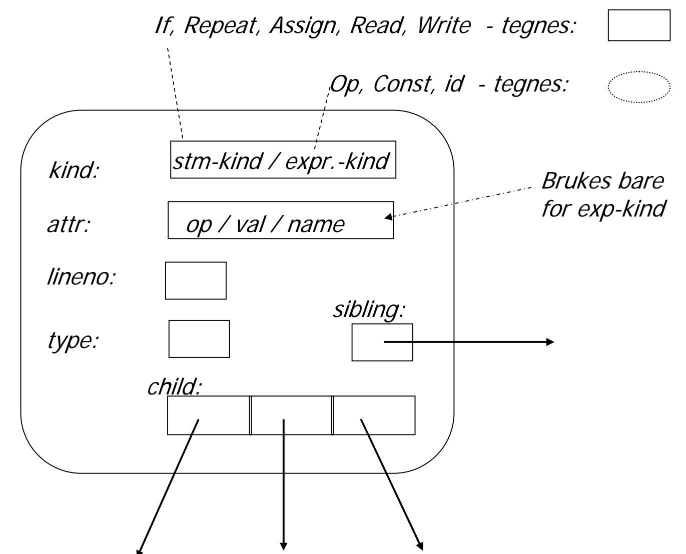

Syntaks-tre for et program i Tiny

```
{ Sample program
  in TINY language—
  computes factorial
}
read x; { input an integer }
if 0 < x then { don't compute if x <= 0 }
  fact := 1;
  repeat
    fact := fact * x;
    x := x - 1
  until x = 0;
  write fact { output factorial of x }
end
```

```
read x; { input an integer }
if 0 < x then { don't compute if x <= 0 }
  fact := 1;
  repeat
    fact := fact * x;
    x := x - 1
  until x = 0;
  write fact { output factorial of x }
end
```