INF5110, onsdag 19. februar, 2014

Dagens tema:

Kapittel 4

Parsering ovenfra-ned (top-down)

Vi har med alle foilene til kap. 4 her, også de som ble gjennomgått mot slutten av forelesning 7. februar

Pensum er korta ned litt i forhold til det i 2013

Kap. 4: Parsering ovenfra-ned (top-down)

Dette bør leses om igjen etter kapittel 4:

- *First* og *Follow*-mengder
  - Boka tar det et stykke uti kap 4, vi tok det først (forrige gang)
- *LL(1)-parsering* og boka og pensum:
  - Det som i *boka* kalles LL(1)-parsering (4.2.1, 4.2.2 og 4.2.4) er en metode for top-down parsering med en eksplisitt stakk. Denne metoden er *ikke* med som pensum.
  - *Vi* konsentrerer oss i dette kapittelet om ”recursive descent”-parsering, en intuitiv metode som mange sikkert har vært litt borti (INF2100, ++)
  - Ofte brukes betegnelsen LL(1)-parsering også om ”rec. desc.”- metoden brukt ut fra syntaksdiagrammer, EBNF eller ren BNF, men man har da gjerne et ikke-teknisk forhold til det om ting helt sikkert fungerer riktig.
  - Vi skal se på det tekniske kravet for at en ren BNF-grammatikk kan parseres rett fram med ”rec. desc.”-metoden.
  - LL(1)-grammatikk i vår betydning:
    Det er en ren BNF-grammatikk som tilfredstiller kravet fra forrige punkt

Vi skal først og fremst se på metoden «Recursive descent» («Rekursiv parsering»??)

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

Neste token «Global» variabel

if n + n * **(** n + n) <= ...

Hoved-idé:

- Skriv en funksjon/ prosedyre/metode for hver ikke-terminal
- La denne finne riktig alternativ (helst fra bare variablen "token"), og gjør parsering av den videre input ut fra det
- Og sjekk på veien at alt er OK

"Typisk" rec.decent-prosedyre for siste produksjon over, som blir veldig enkel.

```
procedure factor ;
begin
  case token of
  ( :   match( ( ) ;
        exp ;
        match( ) ) ;
  number :
        match(number) ;
  else error ;
  end case ;
end factor ;
```

Sjekker at angitt terminal kommer, og "leser til neste". Brukes ofte *bare* for å lese (sjekken må slå til). Da er det egentlig nok å kalle "getToken" (men her kalles alltid "match")

```
procedure match ( expectedToken ) ;
begin
  if token = expectedToken then
    getToken ;
  else
    error ;
  end if ;
end match ;
```

Situasjonen under rekursiv parsering

Kalles altså "top down"-parsering (ovenfra-ned-parsering)

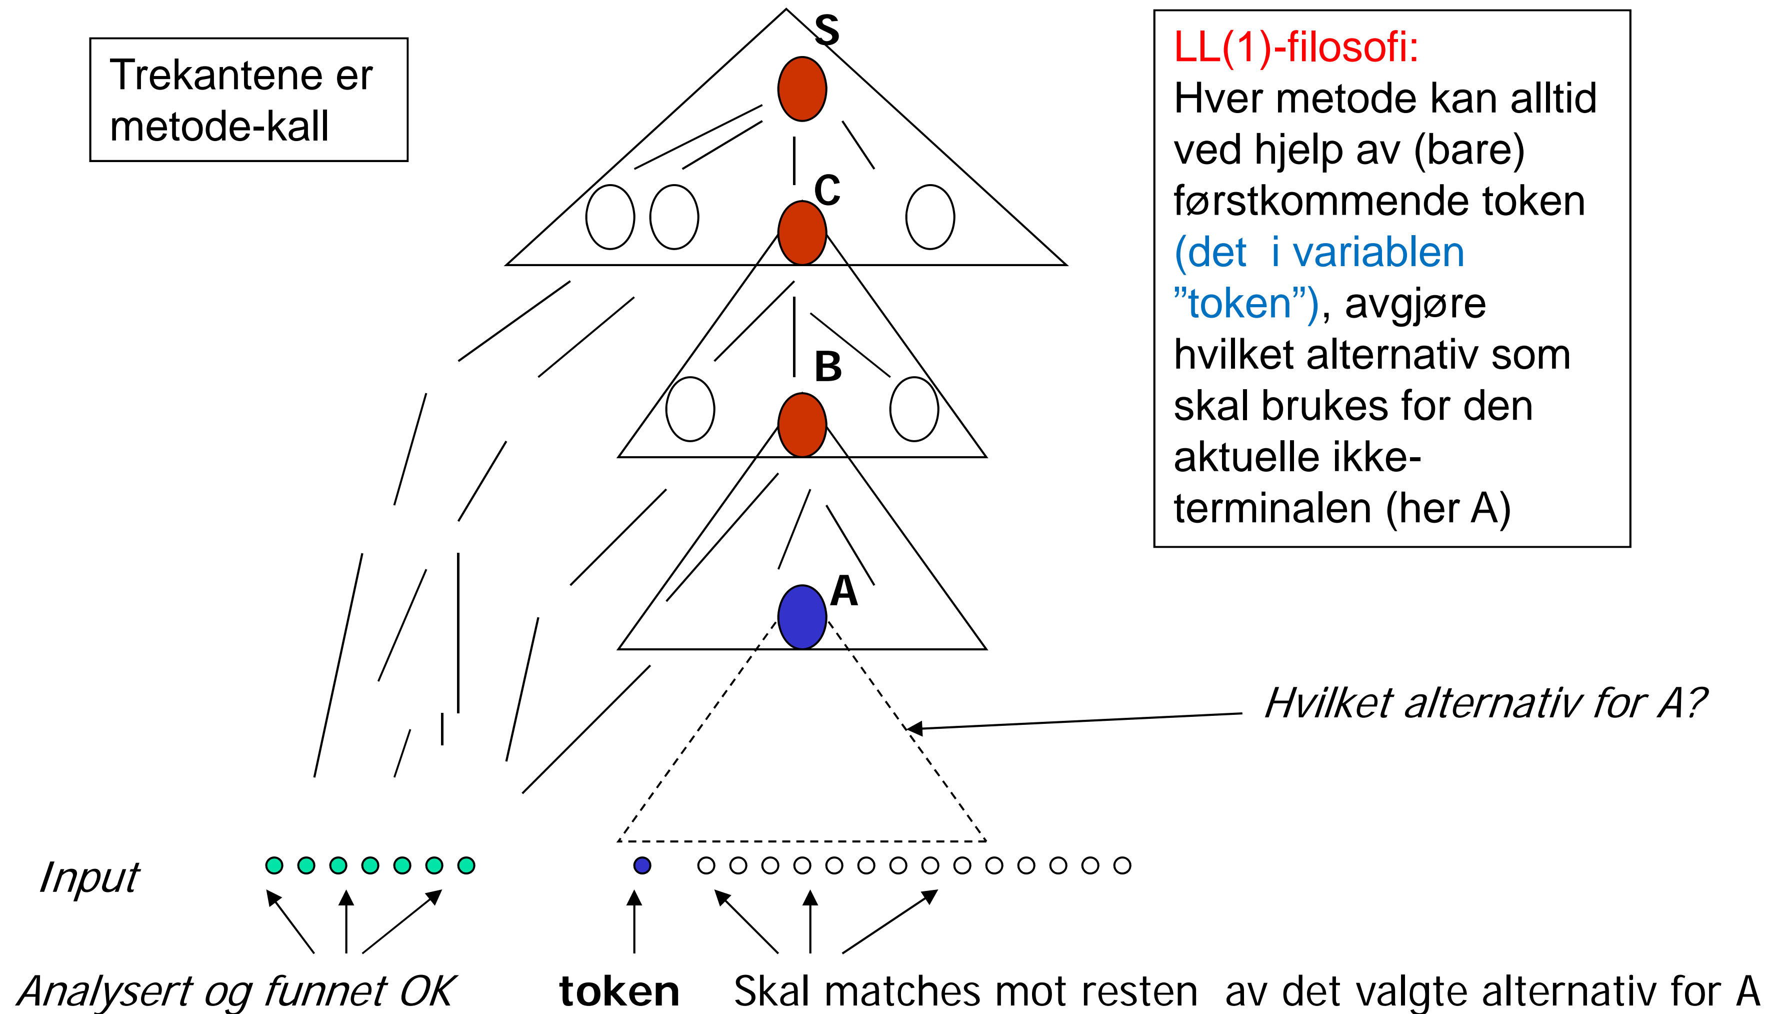

I mer kompliserte tilfeller virker ofte ikke ren BNF bra,
men med venstrefaktorisering eller EBNF går det her ofte greit

Opprinnelig:

if-stmt → **if** **(** *exp* **)** *statement*
  | **if** **(** *exp* **)** *statement* **else** *statement*

Kan i EBNF skrives ut som:

if-stmt → **if** **(** *exp* **)** *statement* [**else** *statement*]

R-D-prosedyre:

procedure *ifStmt* ;
begin
  match (**if**) ;
  match (**(**) ;
  exp ;
  match (**)**) ;
  statement ;
  if *token* = **else then**
    match (**else**) ;
    statement ;
  end if ;
end *ifStmt* ;

NB: Kunne også bruke venstre-faktorisering. Da ville dette bli en egen prosedyre "elsePart":

ifStmt → **if** (exp) stmt elsePart
elsePart → ε | **else** stmt

Venstre-rekursjon gir problemer ved ren BNF. Men går ofte greit med EBNF

Gir uendelig mange rekursive kall

$exp \rightarrow exp\ addop\ term \mid term$

NB: Kan også fjerne venstre-rekursjon på trad. måte, se neste foil.

Bruker EBNF:

$exp \rightarrow term \ \{\ addop\ term\ \}$

```
procedure exp ;
begin
   term ;
   while token = + or token = - do
      match (token) ;
      term ;
   end while ;
end exp ;
```

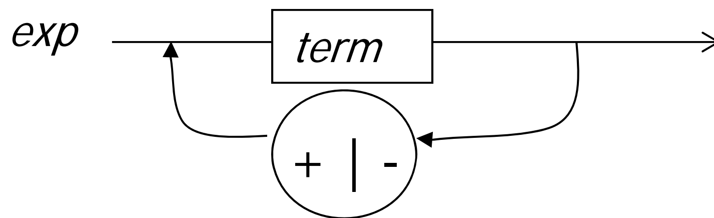

$term \rightarrow term\ multop\ factor \mid factor$

$term \rightarrow factor\ \{\ mulop\ factor\ \}$

```
procedure term ;
begin
   factor ;
   while token = * do
      match (token) ;
      factor ;
   end while ;
end term ;
```

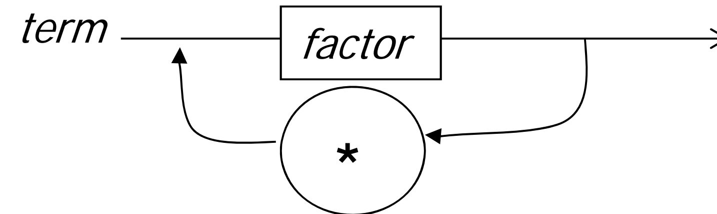

Rec.decent etter tradisjonell fjerning av venstre-rekursjon

Treet blir nå høyre-assosiativt istedenfor venstre.

Dette må det korrigeres for, men det er ikke pensum!

Uttrykk: 3 – 4 – 5

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

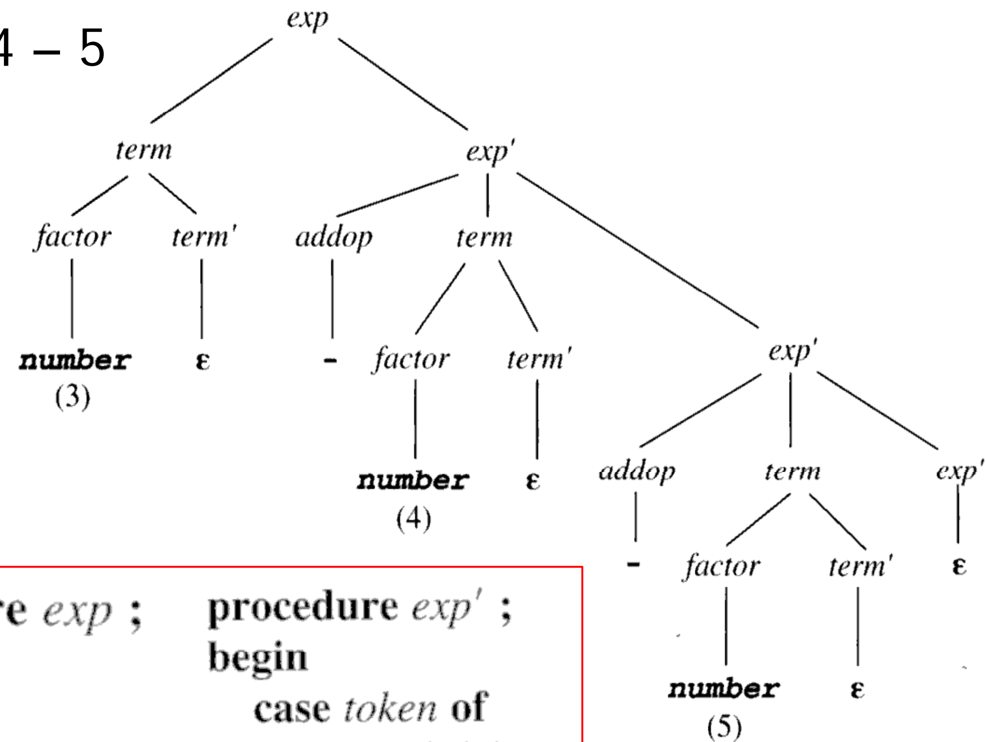

Det abstrakte syntakstreet vi Egentlig ønsket ønsket å lage:

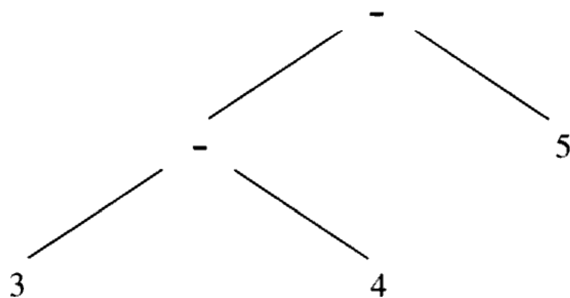


```
procedure exp ;
begin
    term ;
    exp' ;
end exp ;
```

```
procedure exp' ;
begin
    case token of
     + : match (+) ;
          term ;
          exp' ;
     - : match (-) ;
          term ;
          exp' ;
    end case ;
end exp' ;
```

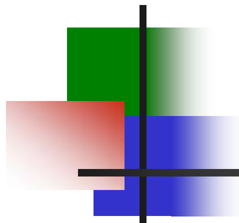

Ikke pensum: Rec.decent etter tradisjonell fjerning av venstre-rekursjon (treet er nå høyre-assosiativt istedenfor venstre).

Lage tre eller beregne verdi : 3 – 4 – 5

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

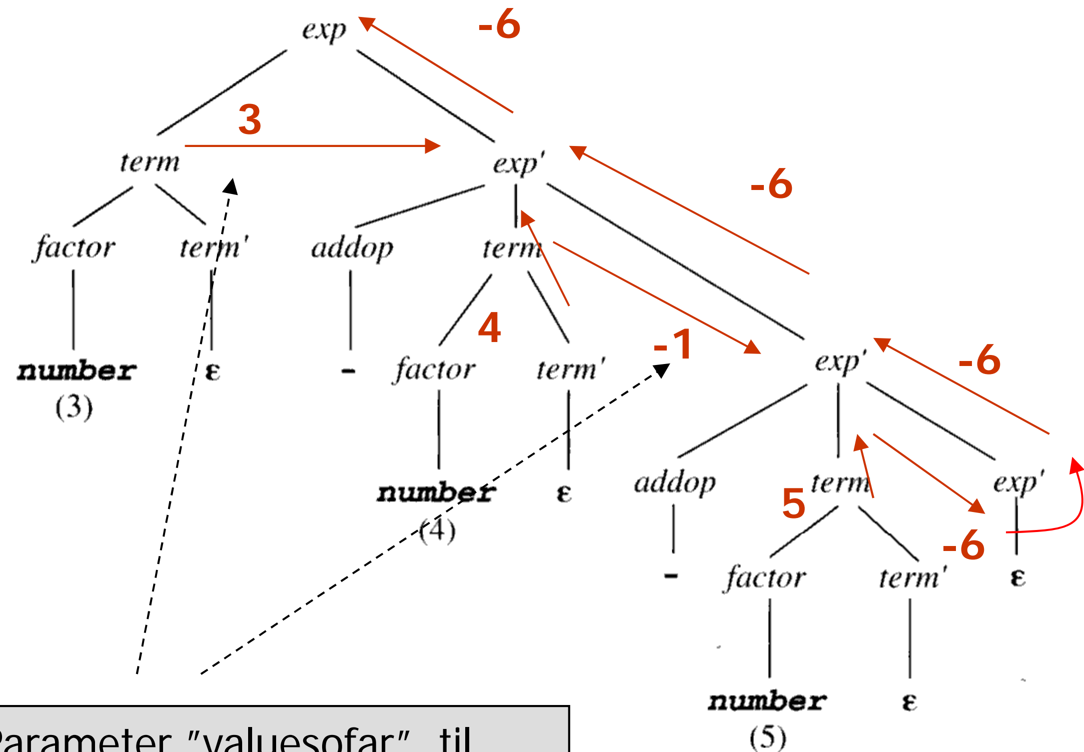

Det abstrakte syntakstreet vi ønsker å lage:

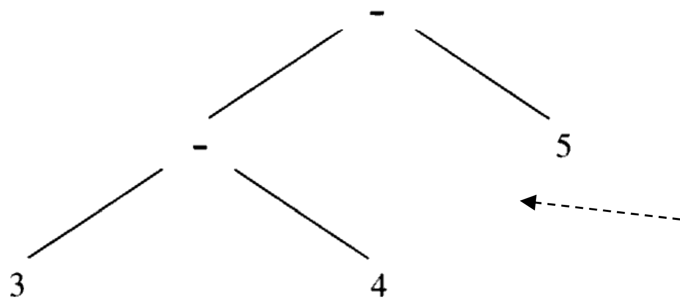

Parameter "valuesofar" til prosedyren "exp"

For trebygging ville den være: "rootOfTreeSoFar"

Hvordan "lage noe" under rec.-decent parsering?

- Mål: Ønsker å bygge abstrakt syntaks-tre
- Tar utgangspunkt i foil 6 (uten nummer)
- Men foreløpig (som kan være forvirrende!):
  - beregner *verdien* av et uttrykk (med venstre-assosiativitet)

```
function exp : integer ;
var temp : integer ;
begin
  temp := term ;
  while token = + or token = - do
    case token of
     + : match (+) ;
         temp := temp + term ;
     - : match (-) ;
         temp := temp - term ;
    end case ;
  end while ;
  return temp ;
end exp ;
```

Kall!

- Kan lett bygges ut til full "kalkulator"   3 + 4 + 5

Bygging av abstrakt syntaks-tre

Igjen med utganspunkt i foil 6

```
function exp : syntaxTree ;
var temp, newtemp : syntaxTree ;
begin
  temp := term ;
  while token = + or token = - do
    case token of
     + : match (+) ;
       newtemp := makeOpNode(+) ;
       leftChild(newtemp) := temp ;
       rightChild(newtemp) := term ;
       temp := newtemp ;
     - : match (-) ;
       newtemp := makeOpNode(-) ;
       leftChild(newtemp) := temp ;
       rightChild(newtemp) := term ;
       temp := newtemp ;
    end case ;
  end while ;
  return temp ;
end exp ;
```

NB: Kall

Alternativt: newtemp.leftChild

NB: Kall

3-4-5:

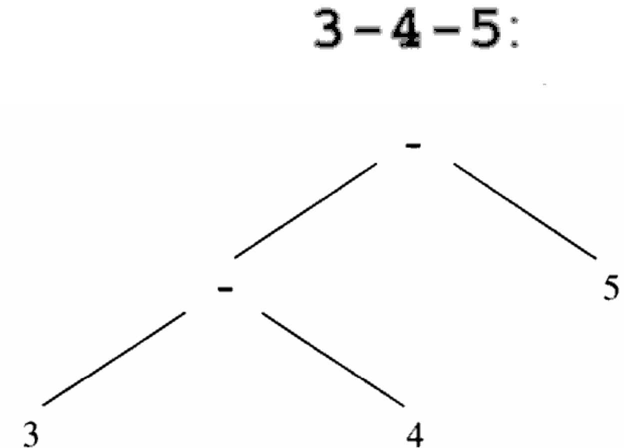

Merk: Dersom det bare er <u>én</u> "term", så lages ingen ny node. Vi leverer den vi har fått

Prosedyre med trebygging for:

factor → *(exp)* | *number*

```
function factor: syntaxTree;
var fact: syntaxTree;
begin
    case token of
    ( :
        match ("(") ;
        fact = exp ;
        match (")") ;
    number :
        fact = makeNumberNode(number) ;
        match (number) ;
    else error(.....) ;
    end case;
    return fact;
end factor;
```

Parsering av if-setning, med tre-generering

EBNF: if-stmt -> if (exp) stmt [else stmt]

```
function ifStatement : syntaxTree ;
var temp : syntaxTree ;
begin
   match (if) ;
   match (( ) ;
   temp := makeStmtNode(if) ;
   testChild(temp) := exp ;
   match ( )) ;
   thenChild(temp) := statement ;
   if token = else then
      match (else) ;
      elseChild(temp) := statement ;
   else
      elseChild(temp) := nil ;
   end if ;
end ifStatement ;
```

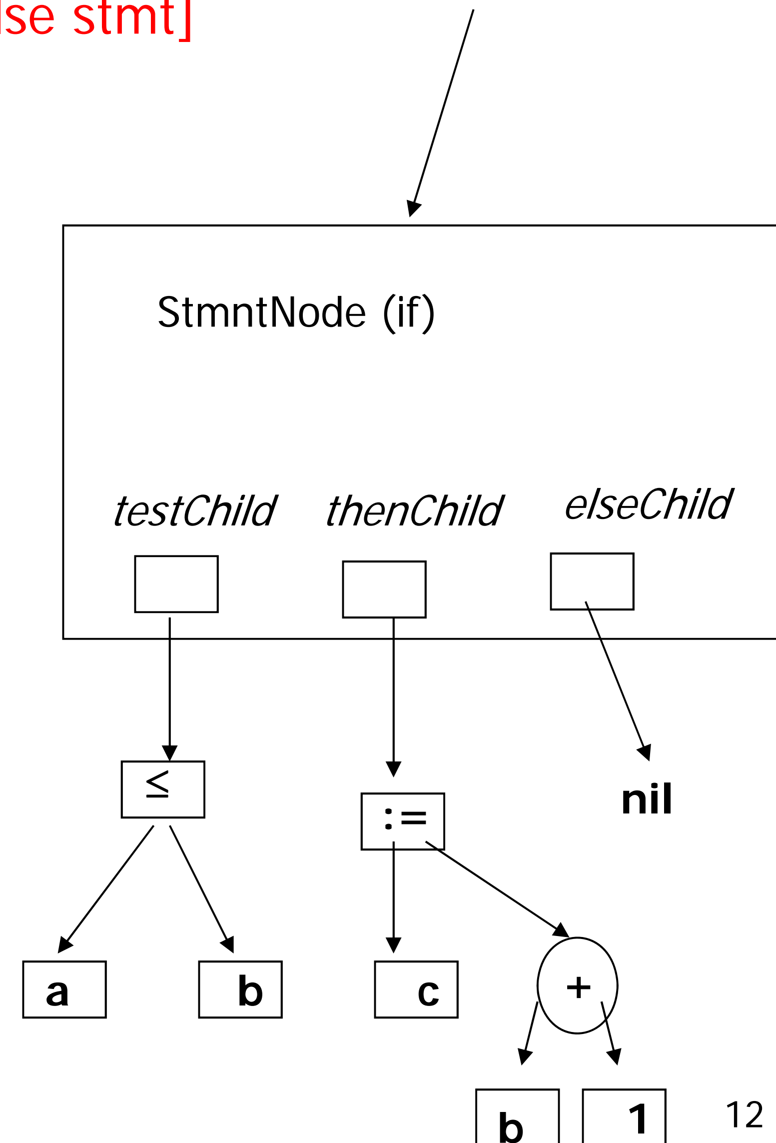

Viktig detalj om hva som skal stå i «token» ved inngang og utgang av de rekusive metodene

Som før:

Trekantene er metode-kall.

LL(1)-filosofi:
Hver metode kan alltid ved hjelp av (bare) førstkommende token, avgjøre hvilket alternativ som skal brukes for den aktuelle ikke-terminalen (her A)

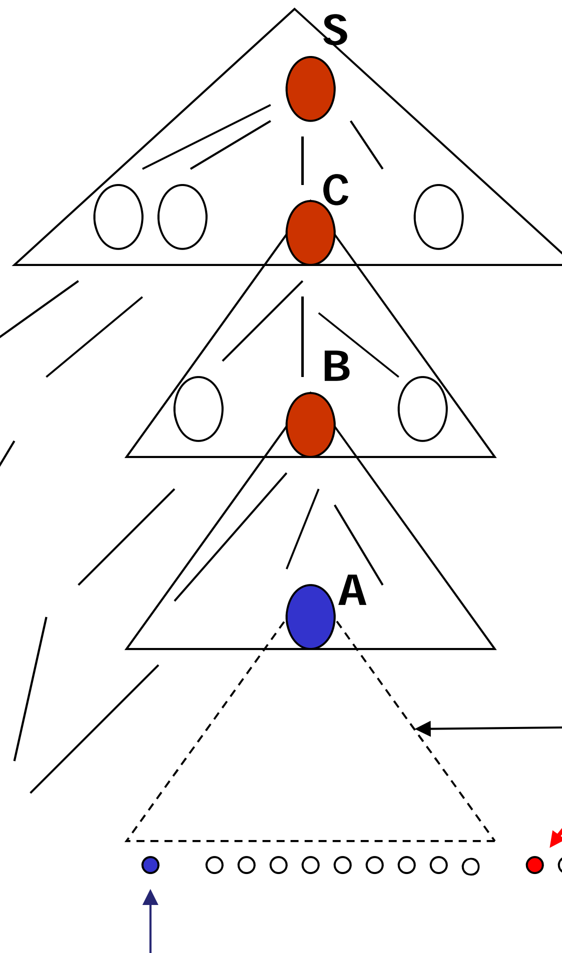

Regel for hva som skal ligge i «token» ved inngang og utgang av en syntaks-metode (si for A):

- Ved *inngang* skal første symbolet i den syntaktiske konstruksjonen A ligge i «token»
- Ved utgang skal første symbolet *etter* konstuksjonen A ligge i «token»

Det valgte alternativet for A

Dette skal ligge i «token» når metoden for A returnerer

Input

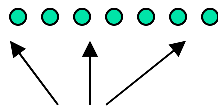

Analysert og funnet OK

Dette skal ligge i «token» når metoden for A kalles

LL(1) – grammatikk

1. Altså, dersom

   $a \in First(\alpha)$

   så legg

   $A \to \alpha$ inn i M[A, a]

- LL(1) -kravet for en "ren BNF-grammatikk":
  Det som kreves for at en rek. descent-parsering skal fungere direkte fra grammatikken uten omskrivninger.
- For å avgjøre om en grammatikk er "LL(1)": Sett opp tabell M[N,T] med mulige aksjoner for alle mulige situasjoner, slik:

1. If $A \to \alpha$ is a production choice, and there is a derivation $\alpha \Rightarrow^* a\,\beta$, where a is a token, then add $A \to \alpha$ to the table entry $M[A, a]$.

2. If $A \to \alpha$ is a production choice, and there are derivations $\alpha \Rightarrow^* \varepsilon$ and $S\,\$ \Rightarrow^* \beta\,A\,a\,\gamma$, where S is the start symbol and a is a token (or \$), then add $A \to \alpha$ to the table entry $M[A, a]$.

Definisjon av LL(1):
En grammatikk er LL(1) dersom M[A,a] er entydig for alle situasjoner (eller angir "error")

2. Altså, dersom:

- α er utnullbar, og
- $a \in Follow(A)$

så legg $A \to \alpha$ inn i M[A, a]

Oppsett av LL(1) –tabell

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

- Venstre-faktorisering utført
- Er ikke vestrerekursiv

	First	Follow
statement	**other, if**	**$, else**
if-stmt	**if**	**$, else**
else-part	**else, ε**	**$, else**
exp	**0, 1**	**)**

M[N, T]	**if**	**other**	**else**	0	1	$
statement	*statement* → *if-stmt*	*statement* → **other**				
if-stmt	*if-stmt* → **if (** *exp* **)** *statement else-part*					
else-part			*else-part* → **else** *statement* *else-part* → ε			*else-part* → ε
exp				*exp* → **0**	*exp* → **1**	

Merk: Selv om man:

- fjerner venstre-rek.
- Utfører venstre-fakt.
- er det generelt **ikke** nok til å *garantere* LL(1)-grammatikk.

For tabellen ble ikke entydig her

Ikke Pensum: Kan også være greit å snakke om den "utvidede startmengden", *Efirst*, til en produksjon

NB: Ikke i boka, men kan øke forståelsen!

- Den "utvidede startmengden", *Efirst*, til en *produksjon* **A** $\rightarrow \alpha$ er *det og bare det* som kan ligge som førstkommende token i input dersom **A** $\rightarrow \alpha$ et riktig valg på dette stadiet under parseringen.
- Her må man også tenke på tilfellet at α kan være utnullbar, og da kan også Follow(**A**) komme som førstkommende token
- Mengden kan beregnes slik:

  Efirst (**A** $\rightarrow \alpha$) = First(α), pluss, om α er utnullbar, Follow(**A**).
- Vi ser da at produksjonen **A** $\rightarrow \alpha$ skal inn i M[A, a] hvis og bare hvis a $\in$ Efirst (**A** $\rightarrow \alpha$)
- Dermed, får vi en alternativ definisjon av LL(1):

Anta at: **A** $\rightarrow \alpha_1 \mid \alpha_2 \mid \alpha_3 \mid \dots \mid \alpha_n$

Da må alle:
Efirst (A $\rightarrow \alpha_1$), Efirst(A $\rightarrow \alpha_2$), …, Efirst(A $\rightarrow \alpha_n$)
være parvis disjunkte. Merk at dette også innebærer at bare ett av alternativene kan være utnullbare

På forrige side vil da både

*Efirst(else-part -> **else** statmt)*
og
Efirst(else-part -> ε)

inneholde **else**
Dermed er grammatikken *ikke* LL(1)

Tidligere foil:
Situasjonen under rekursiv parsering

Trekantene er metode-kall

Det er nå laget ferdig et abstrakt syntakstre for alt til venstre for den røde linjen

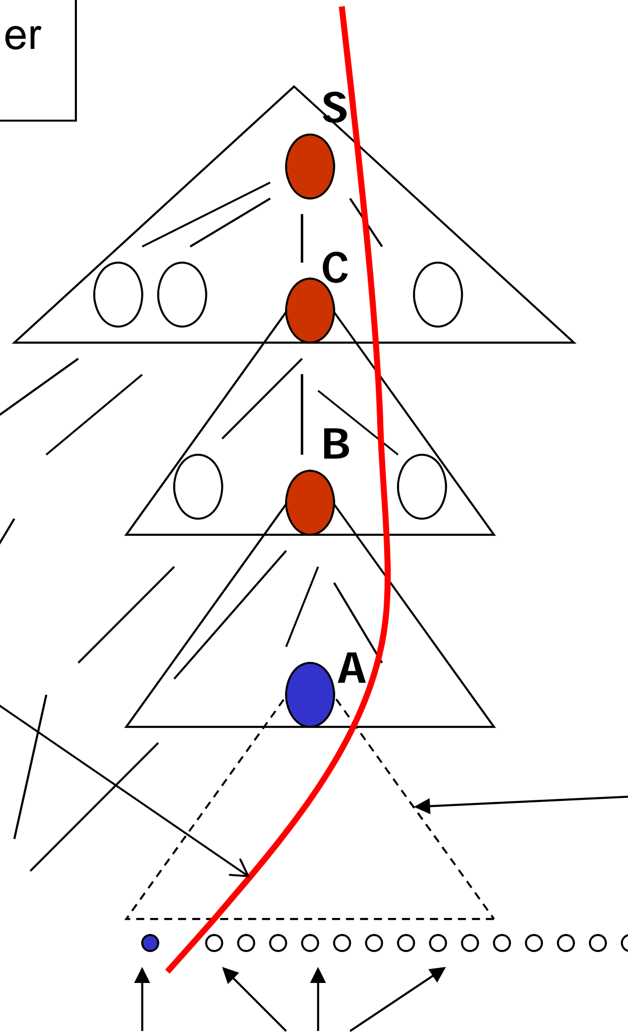

Merk:
En grammatikk som er flertydig kan ikke være en LL(1)-grammatikk

Altså:
En LL(1)-grammatikk er alltid entydig!

Hvilket alternativ for A?

Input

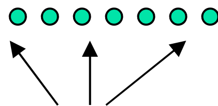

Analysert og funnet OK **token** Skal matches mot resten av det valgte alternativ for A

LL(1) –tabell for uttrykks-grammatik

Vi har tidligere funnet First og Follow som en oppgave

Har fjernet venstre-rekursjon. Er den nå LL(1)?

$exp \rightarrow term\ exp'$
$exp' \rightarrow addop\ term\ exp' \mid \varepsilon$
$addop \rightarrow \texttt{+} \mid \texttt{-}$
$term \rightarrow factor\ term'$
$term' \rightarrow mulop\ factor\ term' \mid \varepsilon$
$mulop \rightarrow \texttt{*}$
$factor \rightarrow \texttt{(}\ exp\ \texttt{)} \mid \textbf{number}$

Opprinnelig utgave. Ikke LL(1)!

$exp \rightarrow exp\ addop\ term \mid term$
$addop \rightarrow \texttt{+} \mid \texttt{-}$
$term \rightarrow term\ mulop\ factor \mid factor$
$mulop \rightarrow \texttt{*}$
$factor \rightarrow \texttt{(}\ exp\ \texttt{)} \mid \textbf{number}$

Vi får da følgende First- og Follow-mengder:

$\text{First}(exp) = \{\texttt{(}, \textbf{number}\}$	$\text{Follow}(exp) = \{\$, \texttt{)}\}$
$\text{First}(exp') = \{\texttt{+}, \texttt{-}, \varepsilon\}$	$\text{Follow}(exp') = \{\$, \texttt{)}\}$
$\text{First}(addop) = \{\texttt{+}, \texttt{-}\}$	$\text{Follow}(addop) = \{\texttt{(}, \textbf{number}\}$
$\text{First}(term) = \{\texttt{(}, \textbf{number}\}$	$\text{Follow}(term) = \{\$, \texttt{)}, \texttt{+}, \texttt{-}\}$
$\text{First}(term') = \{\texttt{*}, \varepsilon\}$	$\text{Follow}(term') = \{\$, \texttt{)}, \texttt{+}, \texttt{-}\}$
$\text{First}(mulop) = \{\texttt{*}\}$	$\text{Follow}(mulop) = \{\texttt{(}, \textbf{number}\}$
$\text{First}(factor) = \{\texttt{(}, \textbf{number}\}$	$\text{Follow}(factor) = \{\$, \texttt{)}, \texttt{+}, \texttt{-}, \texttt{*}\}$

M[N, T]	(	**number**	)	+	-	*	$
exp	*exp* → *term exp'*	*exp* → *term exp'*					
exp'			*exp'* → ε	*exp'* → *addop term exp'*	*exp'* → *addop term exp'*		*exp'* → ε
addop				*addop* → +	*addop* → -		
term	*term* → *factor term'*	*term* → *factor term'*					
term'			*term'* → ε	*term'* → ε	*term'* → ε	*term'* → *mulop factor term'*	*term'* → ε
mulop						*mulop* → *	
factor	*factor* → (*exp*)	*factor* → **number**					

Når kompilatoren oppdager feil

Vi ser på denne og den neste foilen ved slutten av kap. 5

- Minstekrav:
  - Tester løpende at programmet er OK, og gir fornuftig feilmelding ved feil (men stopper kanskje)
- Vanlig krav ved feil ("error recovery"):
  - Gir fornuftig feilmelding.
  - "Blar forbi feilen" og fortsetter kompileringen (og blar forbi så lite som mulig).
  - Vanligvis vil man slutte å lage maskinkode etter feil (Men noe "feilrettende" kompilatorer forsøker det – lite brukt)
  - Det er etter *syntaksfeil* det er vanskeligst å ta opp tråden igjen.

Feilmeldinger m.m.

Ser på denne i forbindelse med Kap. 5

- Viktig:
  - Forsøke å unngå feilmeldinger som bare er følgefeil
  - Rapportere feil så tidlig som mulig, helst så snart det man har lest *ikke kan forlenges til et riktig program*
  - Man må passe på at man ikke blir gående i løkke *uten å lese noe fra input* (verken med eller uten rapportering feil)

- Hvilken feilmelding skal man gi?
  - Anta at man ved "factor" har valgt alternativet " (*exp*) ", og at man, når exp-metoden returnerer, ikke finner en ") ".
  - Hvilken feilmelding skal man da gi??
  - Man kan melde: "Sluttparentes mangler"
  - Men dette kan ofte være forvirrende, f.eks. om det som stod var: (a + b c).
  - Her vil exp-metoden stoppe etter " (a + b ", og det vil være forvirrende her med feilmeldingen "Sluttparentes mangler"
  - Man bør derfor heller gi meldingen: "Noe galt i et uttrykk, eller sluttparentes mangler"

Behandling av Syntaksfeil

"recursive decent". Ikke pensum 2014.

Metode: "Panic mode" og synkroniserings-mengde

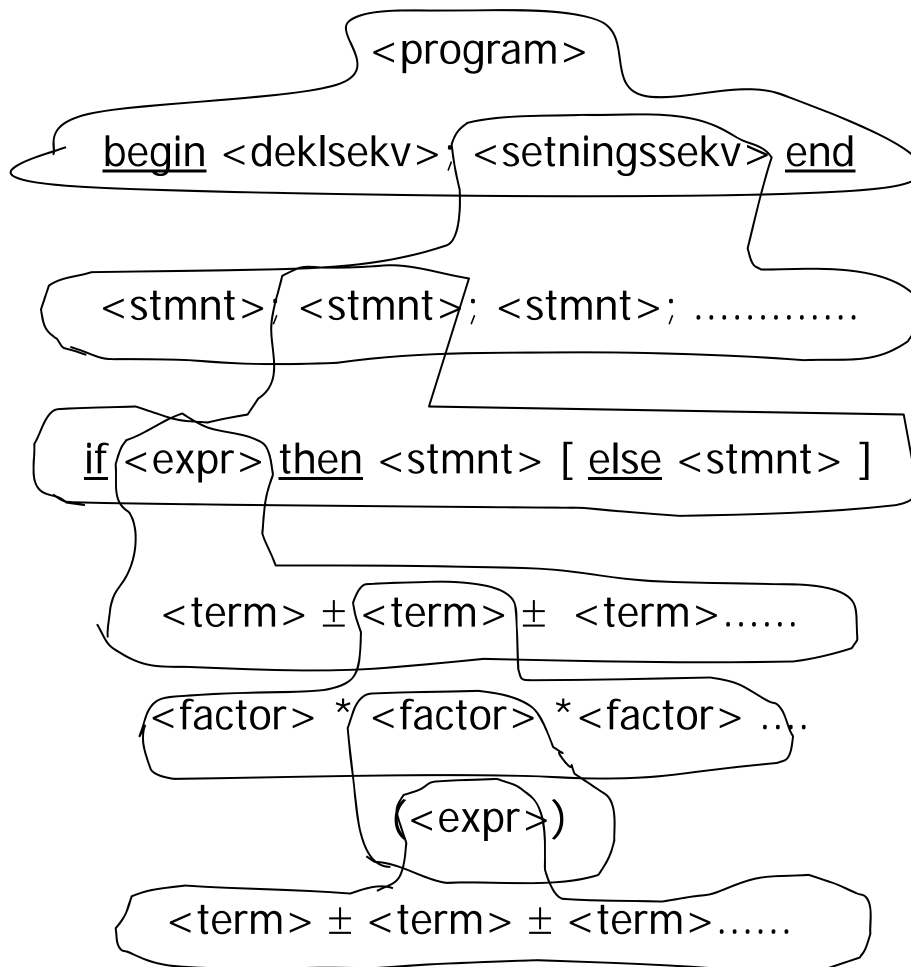

Synch-set (stakk eller parameter):

$

<u>end</u>

; First(stmt)

<u>navn</u> <u>if</u> <u>while</u> <u>for</u> ...

<u>then</u> First(stmt) <u>else</u>

+ - First(term)

(<u>tall</u> <u>navn</u>

* First(factor)

)

+ - (<u>tall</u> <u>navn</u>

Syntaksfeil ved "recursive descent"

Ikke pensum 2014.

Ut fra skissen på forrige foil er det greit å finne:

- hvem som skal ta opp tråden
- "hvor" denne skal fortsette eksekveringen

Vi antar at $ bare legges på stakken av start-symbol-metoden
Unionen av alle på stakken kalles "synkroniseringsmengden", SM

<u>Algoritme:</u>
For hvert input-symbol framover, test om det er med i SM
I så fall:

- Let gjennom SM-stakken fra det siste vi la på, og finn den metoden som
  - sist ble kalt,
  - og som kan ta opp tråden på dette input-symbolet
- Denne metoden vet selv hvor den skal fortsette, ut fra input-symbolet

Det som *<u>ikke</u> er greit*, er å programmere dette *uten at den vakre strukturen* ved "rec. descent" blir helt ødelagt.

Spørsmål, som foreleseren ikke har gått til bunns i:
Kan man få til noe bra ved å bruke Javas unntaksmekanisme??

Uttrykksprosedyrer ved "error recovery". Ikke pensum 2014

Filosofien her er litt annerledes (og noe uklar?)

```
procedure exp ( synchset ) ;
begin
  checkinput ( { (, number }, synchset ) ;
  if not ( token in synchset ) then
    term ( synchset ) ;
    while token = + or token = - do
      match (token) ;
      term ( synchset ) ;
    end while ;
    checkinput ( synchset, { (, number }) ;
  end if;
end exp ;
```

?

if token **in** {(,number} **then** ...

Også { +, - } ?

Hovedfilosofi

"checkinput" kalles to ganger: Først for å sjekke at konstruksjonen starter riktig, etterpå for å sjekke at symbolet etter konstruksjonen er lovlig.

Bruker parameter, ikke stakk

Prosedyrene må selv ta opp tråden riktig når de får igjen kontrollen:

match(t) er som før:

- tester input mot t
- kaller eventuelt "error" (som *nå returnerer*!)
- kaller ikke "scanto(...)"

```
procedure factor ( synchset ) ;
begin
  checkinput ( { (, number }, synchset ) ;
  if not ( token in synchset ) then
   case token of
   ( :  match( ( ) ;
        exp ( { ) } ) ;
        match( ) ) ;
   number :
        match(number) ;
   else error ;
   end case ;
   checkinput ( synchset, { (, number }) ;
  end if ;
end factor ;
```

Hvorfor ikke også "synchset"?

```
procedure scanto ( synchset ) ;
begin
  while not ( token in synchset ∪ { $ }) do
    getToken ;
end scanto ;

procedure checkinput ( firstset, followset ) ;
begin
  if not ( token in firstset ) then
    error ;
    scanto ( firstset ∪ followset ) ;
  end if ;
end;
```