Skanning – del I

Kapittel 2

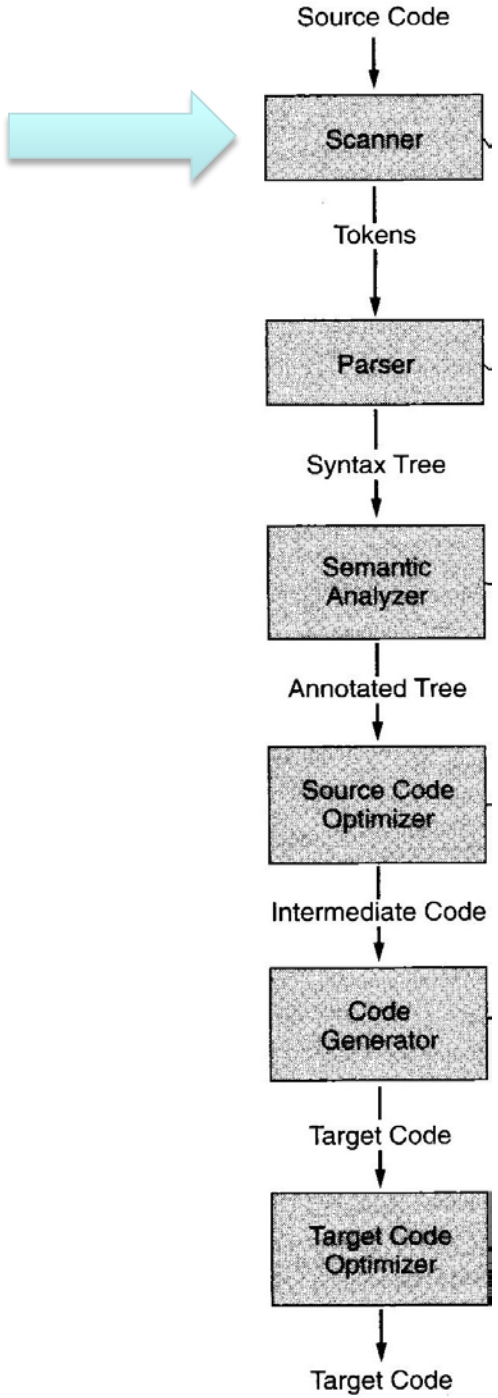

INF 5110 - 2013

Skanning: innhold (begge forelesningene)

- Hva gjør en skanner?
  - Input: programteksten.
  - Output: Ett og ett token fra programteksten (sekvensielt).

- Regulære uttrykk/definisjoner.
  - For å beskrive de ulike tokenklassene.

- Deterministiske automater (DFAer).
  - For å kjenne igjen de enkelt tokens.
- Implementasjon av DFAer.

- Ikke-deterministiske automater (NFAer).
  - For enklere overgang fra regulære uttrykk.
- Overgang fra NFAer til DFAer.

Hva skanneren gjør

- Hovedmål
  - Lage et program (metode) som leverer ett og ett token, med tilhørende attributter.

- Vanlige regler
  - Hvert token skal gjøres så langt som mulig innenfor beskrivelsen.
  - Dersom et token kan passe med flere beskrivelser må det finnes regler om valg:
    - Typisk: Kan det være både **nøkkelord** og **navn**, så skal det anses som nøkkelord.
  - **Blank**, **linjeskift**, **TAB** og kommentar angir skille mellom tokens, men skal forøvrig fjernes (”white space”).

Hva skanneren gjør

```
a[index] = 4 + 2
```

Vanlig invariant: Pilen peker på første tegn etter det siste token som ble lest.
Ved kall på getToken skal da denne pekeren flyttes!

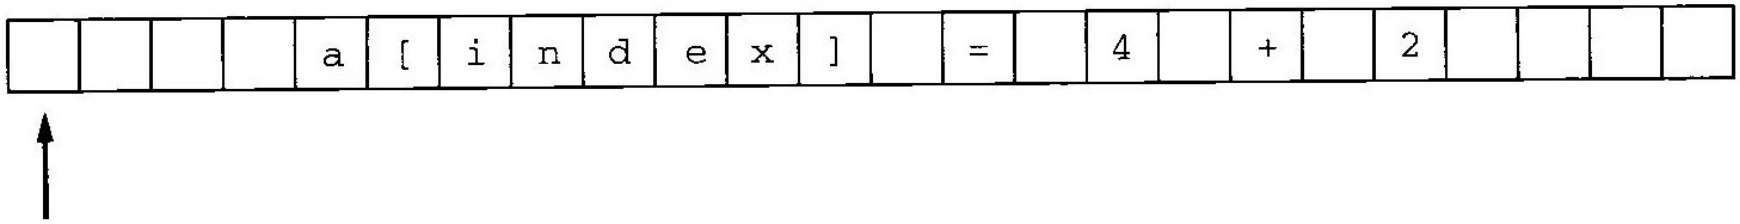

Tegnet pilen peker på ligger gjerne i en gitt variabel 'curChar' e.l.

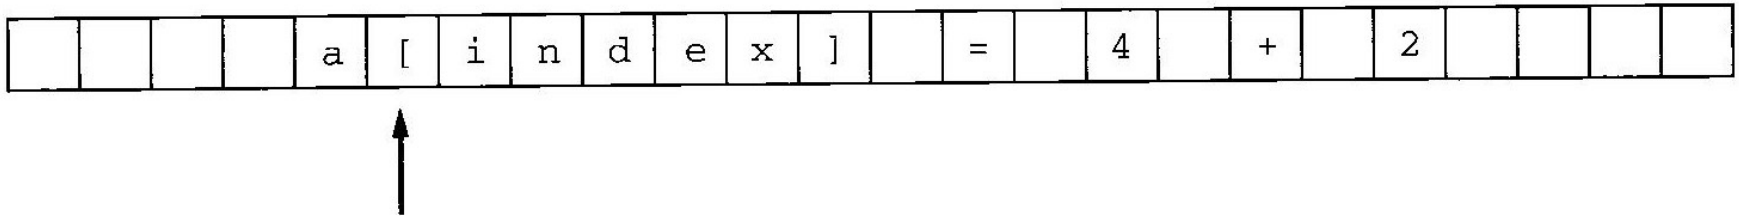

Fortran – spesielle regler for oppdeling i tokens

- Mellomrom (whitespace) uten betydning:

```
I F ( X 2 . EQ. 0) THE N

IF(X2.EQ.0)THEN
```

- Ingen reserverte ord:

```
IF(IF.EQ.0)THENTHEN=1.0

DO99I=1,10

DO99I=1.10
```

Klassifisering

- Mulig regel: Det som skal behandles likt under syntaktisk analyse skal i samme klasse.

- Selve tokenet angir klassen
  - hvilket leksem det er angis ved attributter.

- Det enkleste er å angi selve teksten (f.eks. string value) som attributt.

- Ofte vil scanneren også:
  - Sette navn i tabell, og gi med indeksen som attributt
  - Sette tekst-konstanter i tabell, og angi indeksen som attributt
  - beregne tallkonstanter, og angi verdien som attributt
  - …

En mulig klassifisering

- Navn (identifikator): abc25
- Heltallskonstant: 1234
- Reell konstant: 3.14E3
- Boolsk konstant: true false
- Tekst-konstant: ”dette er en tekstkonstant”
- Aritmetisk operator: + - * /
- Relasjons-operator: < <= >= > = <>
- Logisk operator: and or not
- Alle andre tokens i hver sin gruppe, f.eks.:

  nøkkelord ( ) [ ] { } := , ; .

- MEN: Langt fra klart at denne blir den beste ……

C-typer som kan representere et token

```
typedef struct
   { TokenType tokenval;
     char * stringval;
     int numval;
   } TokenRecord;
```

Hovedklassifikasjonen

Selve teksten, eller verdien

Hvis man vil lagre bare ett attributt:

```
typedef struct
   { TokenType tokenval;
     union
     { char * stringval;
       int numval;
     } attribute;
   } TokenRecord;
```

En skanner er ikke stor og vanskelig

- De forskjellige token-klassene kan lett beskrives i prosa-tekst.
- Ut fra det kan en skanner skrives rett fram, uten særlig teori.
- Kan typisk ta noen hundre linjer, der det samme prinsippet stadig går igjen.
- Men, man kan ønske seg:
  - Å angi token-klassene i en passelig formalisme.
  - Ut fra denne få laget et skanner-program automatisk.
- Det er dette kapittel 2 handler mest om.

Framgangsmåte

for automatisk å lage en skanner

- Beskriv de forskjellige token-klassene som regulære uttrykk.
  - Eller litt mer fleksibelt, som regulære definisjoner.
- Omarbeid dette til en NFA (Nondeterministic Finite Automaton).
  - Er veldig rett fram.
- Omarbeid dette til en DFA (Deterministic Finite Automaton).
  - Dette kan gjøres med en kjent, grei algoritme.
- En DFA kan uten videre gjøres om til et program.
- Det er hele veien et kompliserende element at vi:
  - ikke bare skal finne ett token, men en sekvens av token .
  - hvert token skal være så langt som mulig.
- Vi skal se på dette i følgende rekkefølge:

  (1) Regulære uttrykk (2) DFAer (3) NFAer

REGULÆRE UTTRYKK

Definisjon av regulære uttrykk

Og det språket de definerer = mengden av strenger

A **regular expression** is one of the following:

1. A **basic** regular expression, consisting of a single character **a**, where a is from an alphabet Σ of legal characters; the metacharacter **ε**; or the metacharacter **ϕ**. In the first case, $L(\mathbf{a}) = \{a\}$; in the second, $L(\boldsymbol{\varepsilon}) = \{\varepsilon\}$; in the third, $L(\boldsymbol{\phi}) = \{\}$.
2. An expression of the form $\boldsymbol{r}|\boldsymbol{s}$, where r and s are regular expressions. In this case, $L(\boldsymbol{r}|\boldsymbol{s}) = L(r) \cup L(s)$.
3. An expression of the form rs, where r and s are regular expressions. In this case, $L(rs) = L(r)L(s)$.
4. An expression of the form $r\boldsymbol{*}$, where r is a regular expression. In this case, $L(r\boldsymbol{*}) = L(r)^*$.
5. An expression of the form $\boldsymbol{(}r\boldsymbol{)}$, where r is a regular expression. In this case, $L(\boldsymbol{(}r\boldsymbol{)}) = L(r)$. Thus, parentheses do not change the language. They are used only to adjust the precedence of the operations.

Presedens:
*, konkatenering, |

INF 5110 - 2013

Mer rasjonelle skrivemåter

r+ = rr*

r? = r | ε

Spesielle skrivemåter for tegnmengder:

[0-9] [a-z]

~a ikke a ~(a | b) hverken a eller b

. hele Σ .* en vilkårlig streng

Gi regulære uttrykk navn (regulære definisjoner), og så bruke disse navnene videre i regulære uttrykk:

digit = [0-9]

nat = digit+

signedNat = (+|-)nat

number = signedNat (”.” nat)?(E signedNat)?

DETERMINISTISKE AUTOMATER

Deterministisk Endelig Automat

- En **DFA** (deterministic finite automaton) M består av:
  - Σ, et alfabet
  - S, et sett med tilstander
  - T: S x $\Sigma \rightarrow$ S, en transisjons-funksjon
  - $s_0 \in$ S, en start-tilstand
  - A $\subset$ S, et sett med aksepterende tilstander
- L(M) er språket akseptert av M, dvs alle strenger $c_1c_2\ldots c_n$ med $c_i \in \Sigma$ slik at det eksisterer tilstander $s_1=T(s_0,c_1)$, $s_2=T(s_1,c_2)$, …, $s_n=T(s_{n-1},c_n)$ og $s_n \in$ A.
- Eksempel:

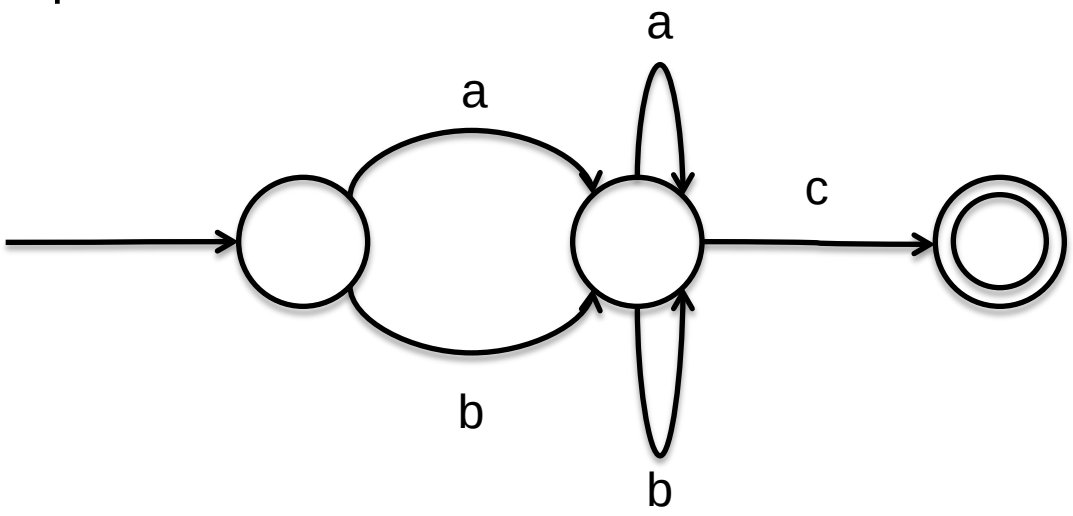

DFA

identifier = letter (*letter* | *digit*)*

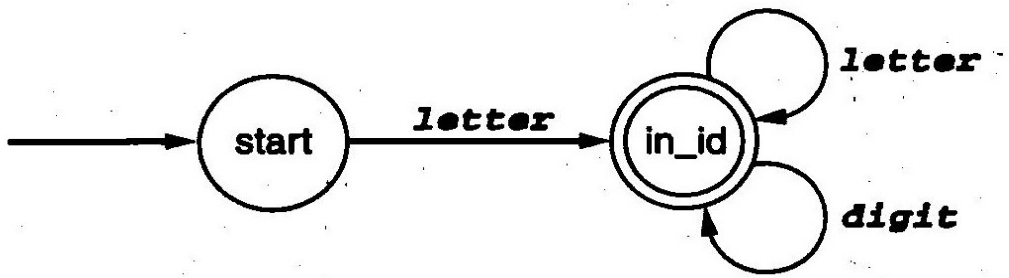

Funksjonen T: SxΣ -> S er ikke fullstendig definert.

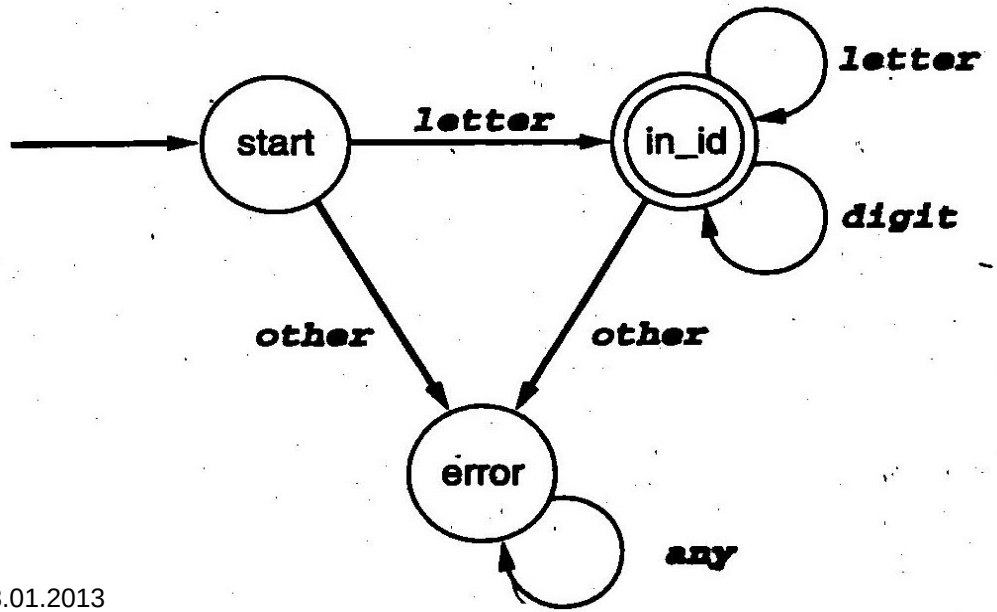

Denne utvidelsen (med en feiltilstand) er underforstått.

DFA for tall

Regulære definisjoner
digit = [0-9]
nat = digit+
signedNat = (+|-)? nat
number =
signedNat (“.”nat)?(E signedNat)?

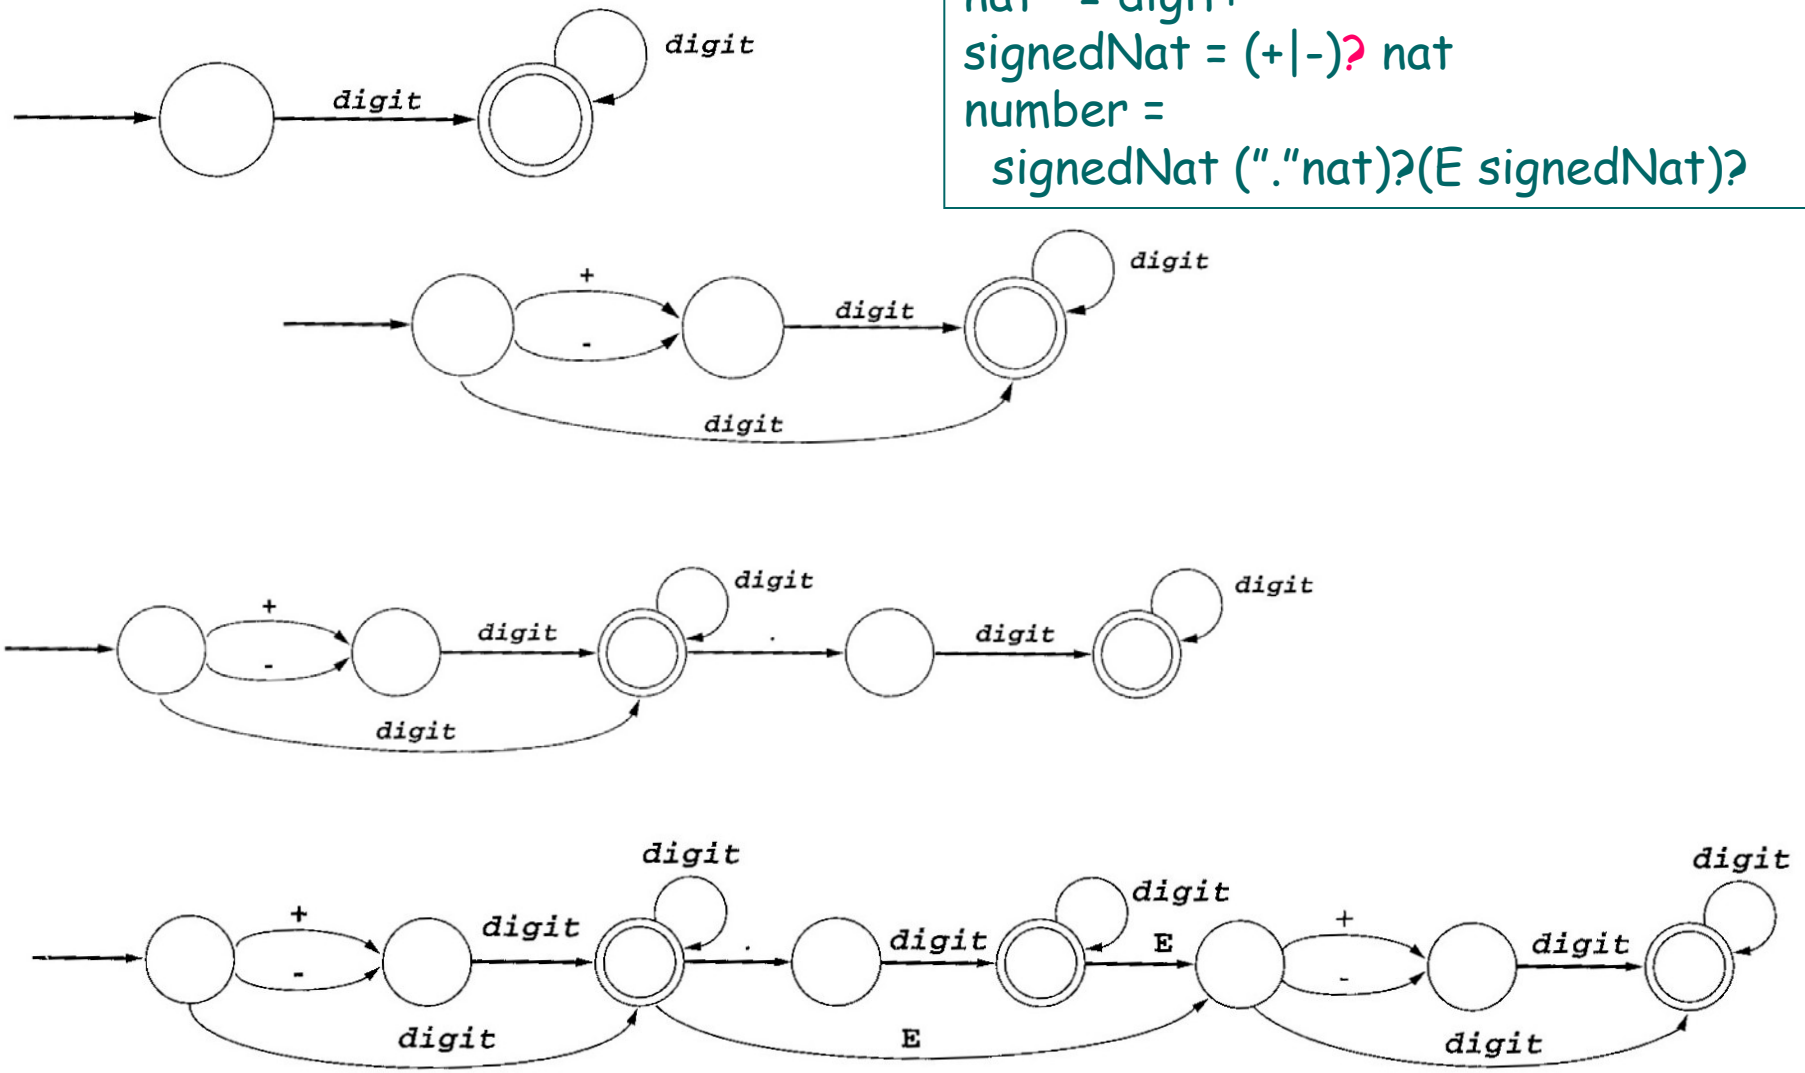

DFA for kommentarer

Pascal type

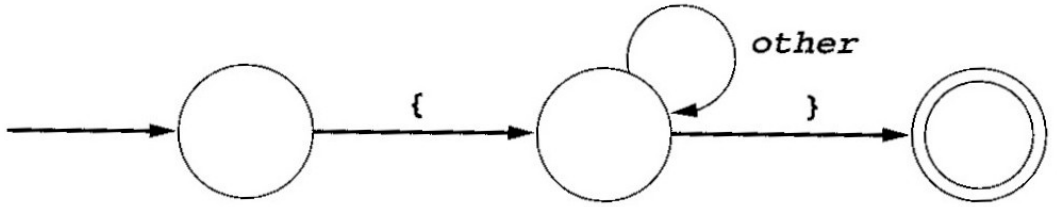

C, C++, Java type

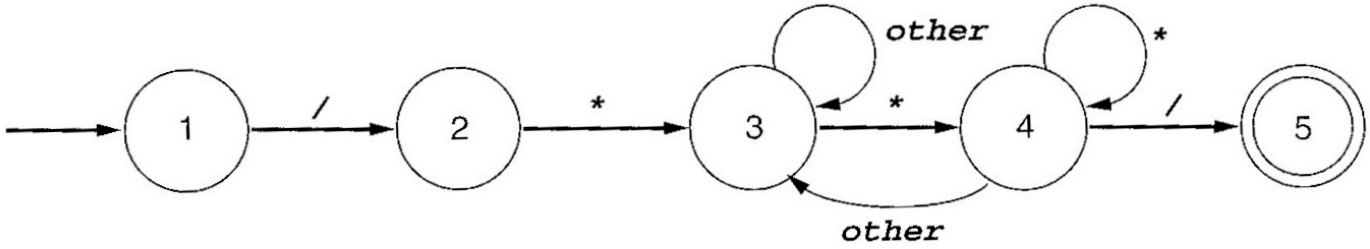

Implementasjon 1 av DFA

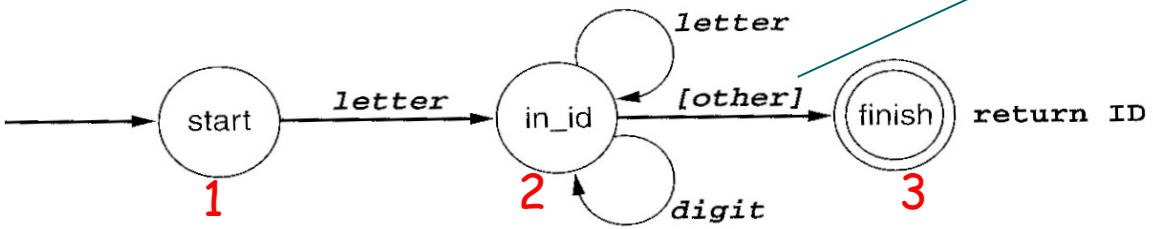

ikke flytt til neste tegn

```
{ starting in state 1 }
if the next character is a letter then
   advance the input;
   { now in state 2 }
   while the next character is a letter or a digit do
     advance the input; { stay in state 2 }
   end while;
   { go to state 3 without advancing the input }
   accept;
else
   { error or other cases }
end if;
```

er neste tegn et siffer: tall
er neste tegn {+,-,*,/}: arit. operator
...
...

Implementasjon 2 av DFA

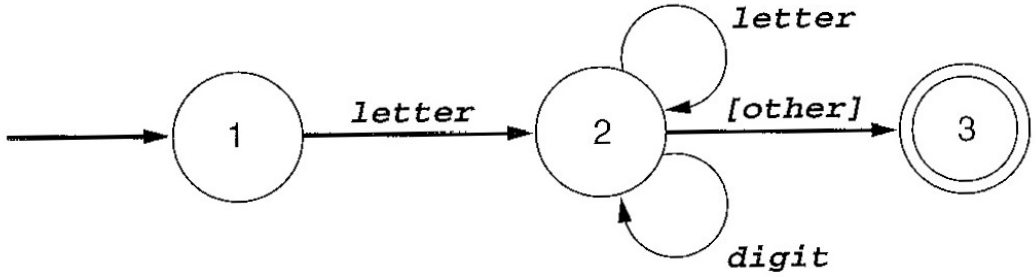

Tilstanden eksplisitt representert ved et tall

```
state := 1; { start }
while state = 1 or 2 do
  case state of
  1:  case input character of
      letter : advance the input;
               state := 2;
      else state := . . . { error or other };
      end case;
  2:  case input character of
      letter, digit: advance the input;
                     state := 2; { actually unnecessary }
      else state := 3;
      end case;
  end case;
end while;
if state = 3 then accept else error ;
```

hvis det bare er navn vi leter etter

hvis vi også aksepterer tall, vil siffer føre oss til en ny lovlig tilstand

INF 5110 - 2013

Implementasjon 3 av DFA

- Har et fast program
- Automaten ligger i en tabell

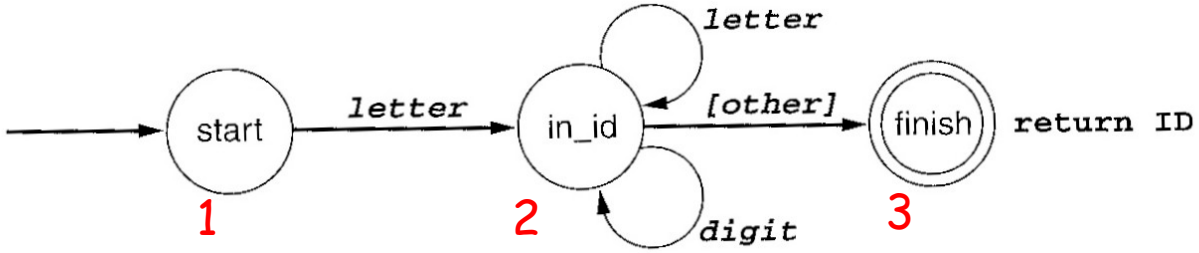

state \ input char	letter	digit	other
1	2		
2	2	2	3
3			

```
state := 1;
ch := next input character;
while not Accept[state] and not error(state) do
  newstate := T[state,ch];
  if Advance[state,ch] then ch := next input char;
  state := newstate;
end while;
if Accept[state] then accept;
```

state \ input char	letter	digit	other	Accepting
1	2			no
2	2	2	[3]	no
3				yes

IKKE-DETERMINISTISKE AUTOMATER

Ikke-deterministisk Endelig Automat

- En **NFA** (nondeterministic finite automaton) M består av:
  - Σ, et alfabet
  - S, et sett med tilstander
  - T: S x $(\Sigma \cup \{\varepsilon\}) \rightarrow \mathcal{P}(S)$, en transisjons-funksjon
  - $s_0 \in S$, en start-tilstand
  - $A \subset S$, et sett med aksepterende tilstander

- L(M) er språket akseptert av M, dvs alle strenger $c_1c_2\ldots c_n$ med $c_i \in \Sigma \cup \{\varepsilon\}$ slik at det eksisterer tilstander $s_1 \in T(s_0,c_1)$, $s_2 \in T(s_1,c_2)$, …, $s_n \in T(s_{n-1},c_n)$ og $s_n \in A$.

NFA vs DFA

- NFA: Kan ofte være lett å sette opp, spesielt ut fra et regulært uttrykk
- NFA: Kan ses på som syntaks-diagrammer

NFA

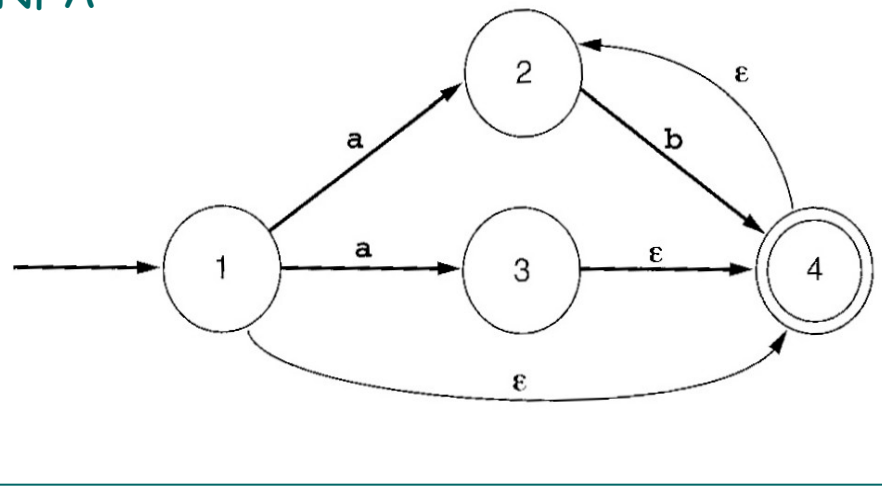

DFA

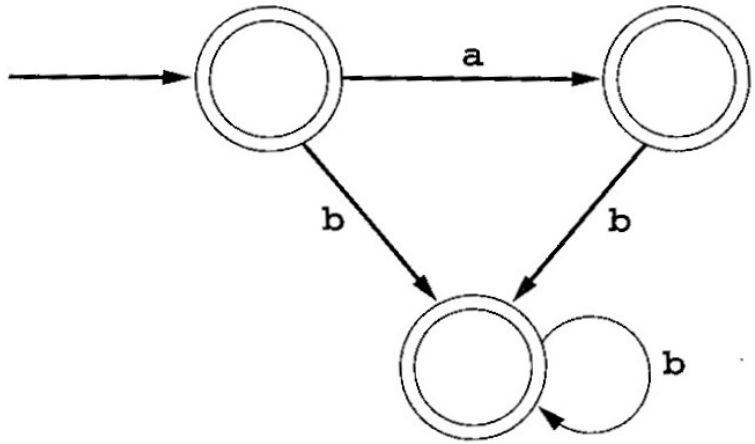

- ikke greit å gjøre til algoritme
- beskriver samme språk

Motivasjon for å innføre NFA-er (1)

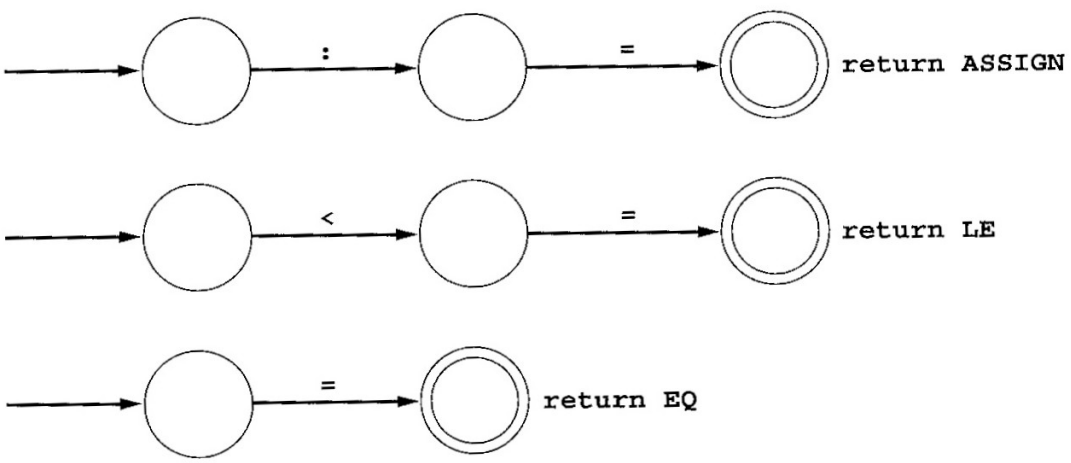

DFA-er for de enkelte token

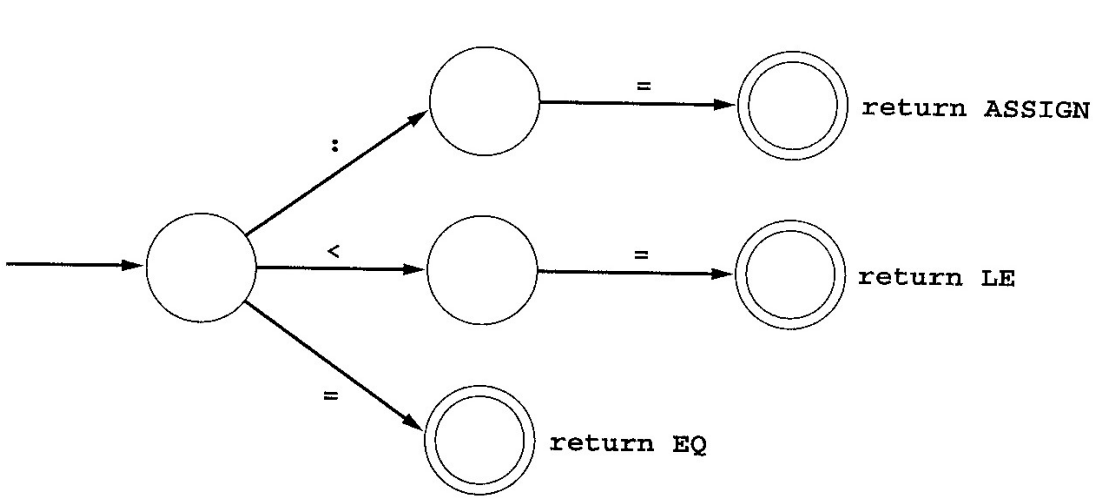

Siden de starter forskjellig går det greit å slå dem sammen, men de opprinnelige automatene er ikke der lenger

INF 5110 - 2013

Motivasjon for å innføre NFA-er (2)

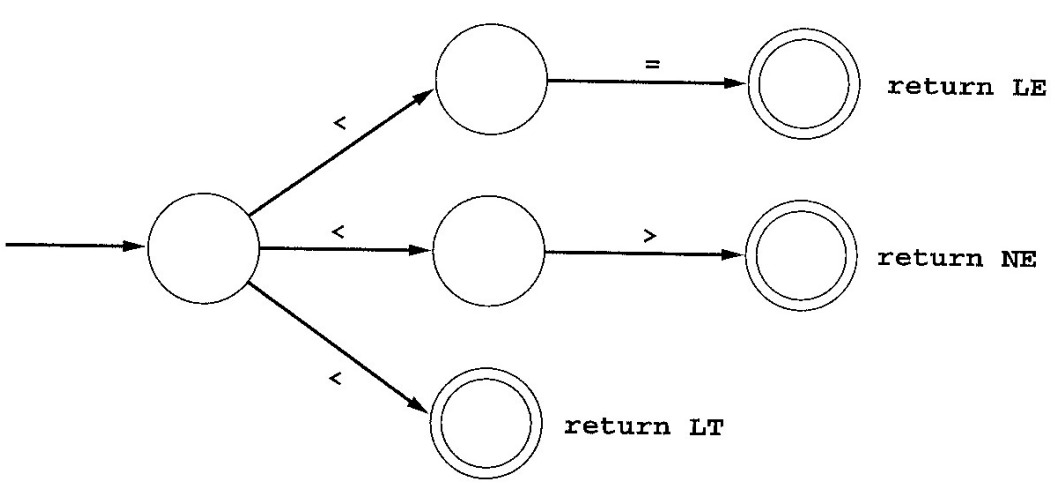

Med disse token-definisjoner går det ikke med en enkel sammenslåing, da dette ikke er en DFA

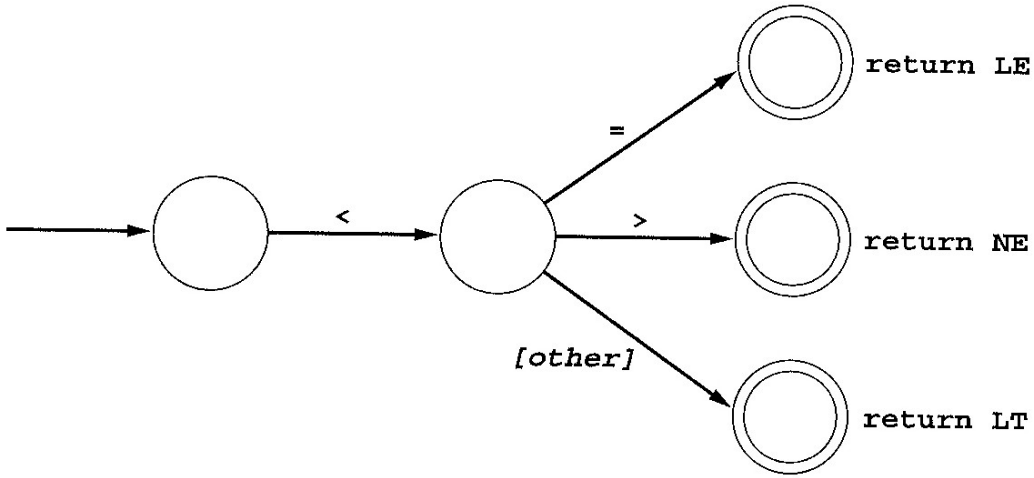

I dette tilfellet går det an å slå sammen på første tegn, men dette er ikke altid mulig

Motivasjon for å innføre NFA-er (3)

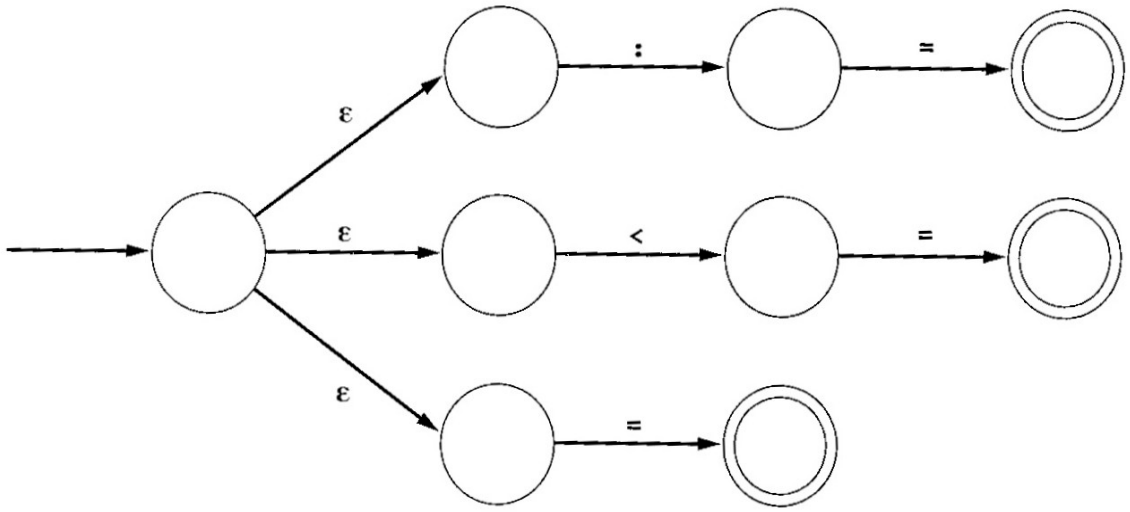

Ville være greiere generelt å gjøre det slik

Derfor

(1) Innfører ε-kant

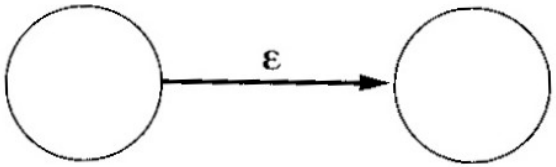

(2) Fjerner kravet om bare én a-kant ut fra hver tilstand

Thomson-konstruksjon I

(Ethvert regulært uttrykk skal bli automat på denne formen:)

a:

ε:

rs:

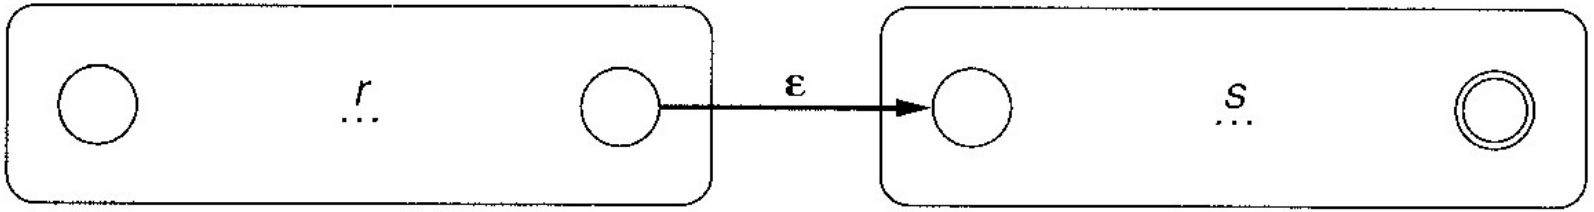

Thomson-konstruksjon II

r | s:

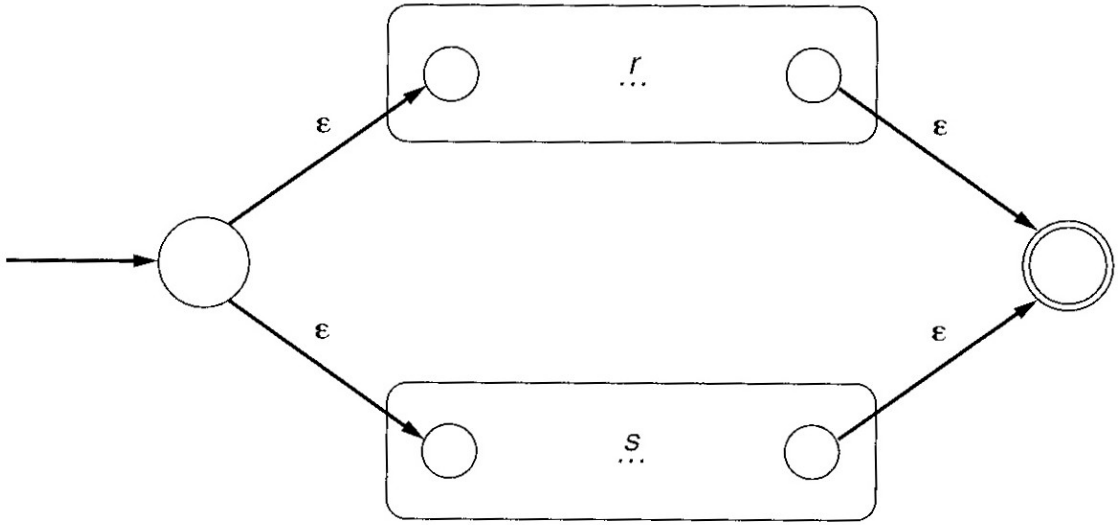

r*:

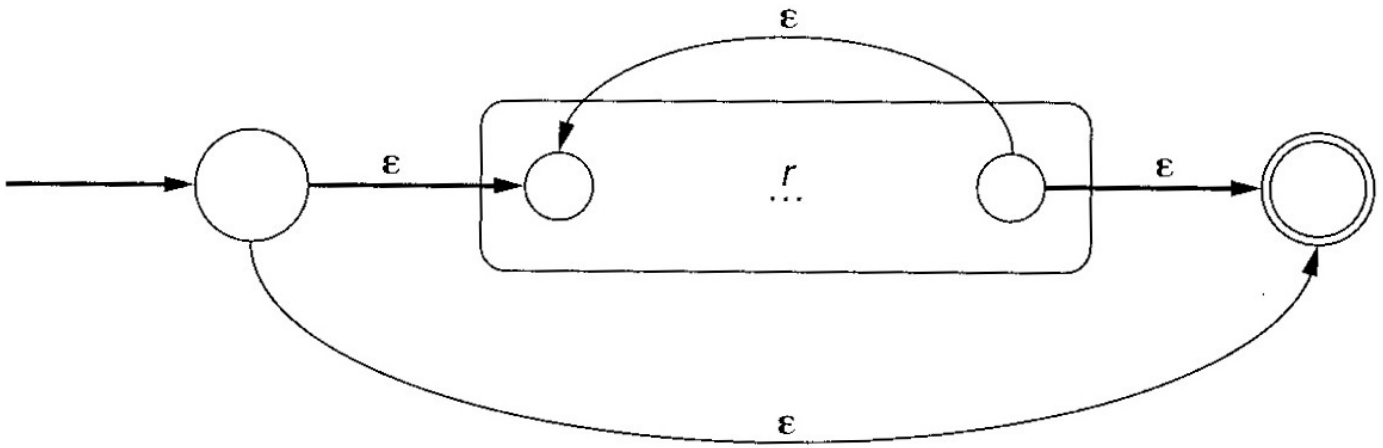

Eksempel Thomson-konstruksjon

Neste forelesning: Tirsdag 22. januar (Lille Aud, KN)

OVERGANG FRA NFA TIL DFA

OPPGAVER: 2.1, 2.12, 2.14, 2.16