Scanning-I Kap. 2

- Hovedmål
  - Gå ut fra en beskrivelse av de enkelte ”leksemer” (tokens), og hvordan de skal deles opp i klasser
  - Lage et program (funksjon, prosedyre, metode) som leverer ett og ett token, med all nødvendig informasjon
  - Tokenet skal angis som en hovedklassifikasjon, med tilhørende ”attributter”
- Vanlige regler
  - Hvert token skal gjøres så langt som mulig innfor 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 ansees som nøkkelord
  - **Blank**, **linjeskift**, **TAB** og kommentar angir skille mellom tokens, men skal forøvrig ”fjernes” (”white space”)

Hva scanneren gjør

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

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

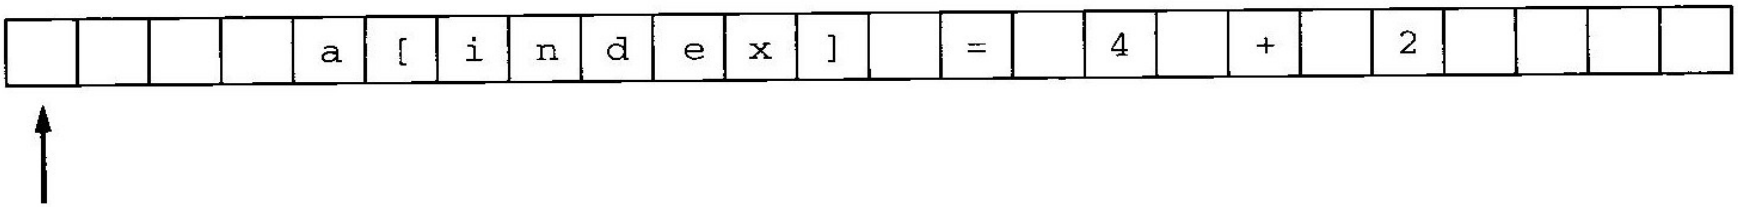

Tegnet pilen peker på ligger gjerne i en gitt variabel 'curChar' e-lign.

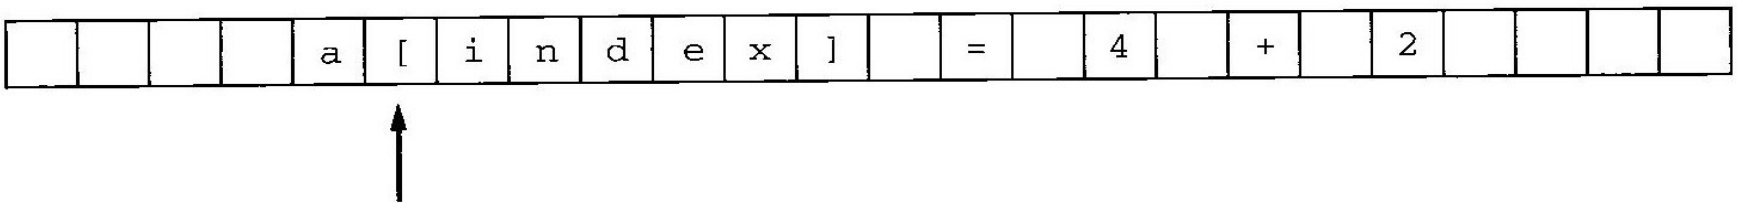

Fortran

Spesielle regler for oppdeling i tokens

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

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

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

```
DO99I=1,10
```

```
DO99I=1.10
```

```
DO 99 I=1,10
  -
  -
  -
99 CONTINUE
```

Klassifisering

- Hva som er en god klassifisering blir ikke klart før senere i kompilatoren
- En mulig regel: Det som skal behandles ”likt” under syntaktisk analyse skal i samme klasse.
- Selve ”tokenet” angir klassen
  - hvilket leksem det er innen klassen angis ved attributter
- Det enkleste er å angi selve teksten (”string value”) som attributt
- Men 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 scanner er ikke stor og vanskelig

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

Framgangsmåte

- for automatisk å lage en scanner

- 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
  - der hvert token skal være så langt mulig, etc.
- Vi skal se på dette i følgende rekkefølge:
  (1) Regulære uttrykk (2) DFAer (3) NFAer

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, |

L(ε) = språket som bare innholder ε-strenger
L(∅) = språket uten noen strenger

Eksempler - I

$\Sigma=\{a,b,c\}$

- Strenger som har nøyaktig en b

  $(a \mid c)^* b\ (a \mid c)^*$

- Strenger som har max en b

  $(a \mid c)^* \mid b\ (a \mid c)^*$ $\qquad$ $(a \mid c)^*\ (b \mid \varepsilon)\ (a \mid c)^*$

- Strenger som har formen aaaabaaaa (dvs like mange a-er)

  $(a^n\ b\ a^n)$?

Eksempler - II

- Strenger som ikke inneholder to b-er etter hverandre

(b (a | c))*	en a eller c etter hver b
((a | c)* | (b (a | c))*)*	kombinert med (a | c)*
((a | c) | (b (a | c)))*	forenklet
(a | c | ba | bc)*	enda mer forenklet
(a | c | ba | bc)* (b | ε)	får med b på slutten
(*notb* | b *notb*)* (b | ε)	hvor *notb* = a | c

Mer rasjonelle skrivemåter

- r+ = rr*
- r? = r | ε

- 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)?

- Spesielle skrivemåter for tegnmengder
  - [0-9] [a-z]
  - ~a ikke a ~(a | b) hverken a eller b
  - . hele Σ .* en vilkårlig streng

Deterministisk Endelig Automat

A **DFA** (deterministic finite automaton) M consists of an alphabet Σ, a set of states S, a transition function T: $S \times \Sigma \rightarrow S$, a start state $s_0 \in S$, and a set of accepting states $A \subset S$. The language accepted by M, written $L(M)$, is defined to be the set of strings of characters $c_1c_2 \ldots c_n$ with each $c_i \in \Sigma$ such that there exist states $s_1 = T(s_0, c_1)$, $s_2 = T(s_1, c_2), \ldots, s_n = T(s_{n-1}, c_n)$ with s_n an element of A (i.e., an accepting state).

DFA -1

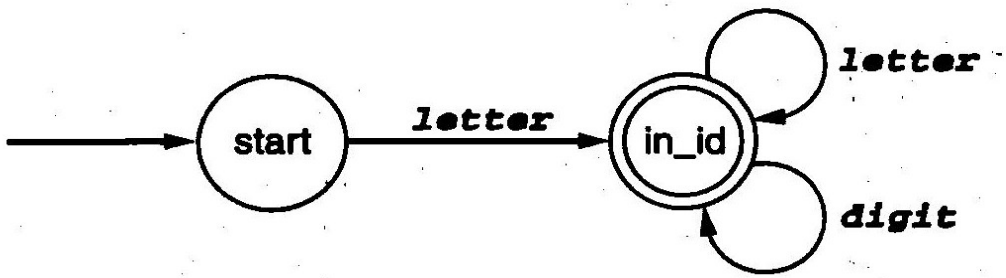

Funksjonen T: SxΣ -> S er ikke fullstendig definert

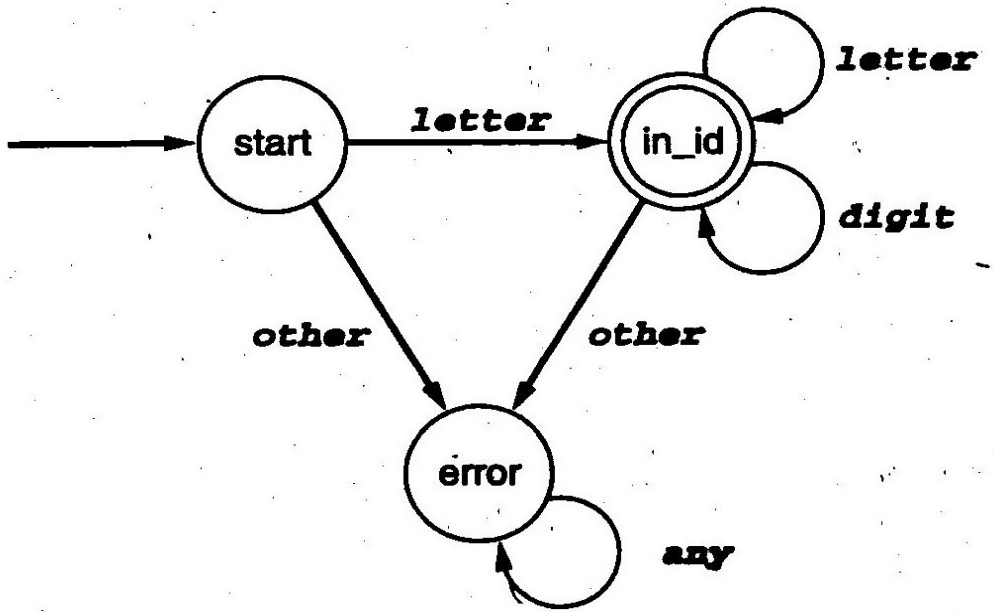

Denne utvidelsen (med en feiltilstand) er underforstått

DFA for tall

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

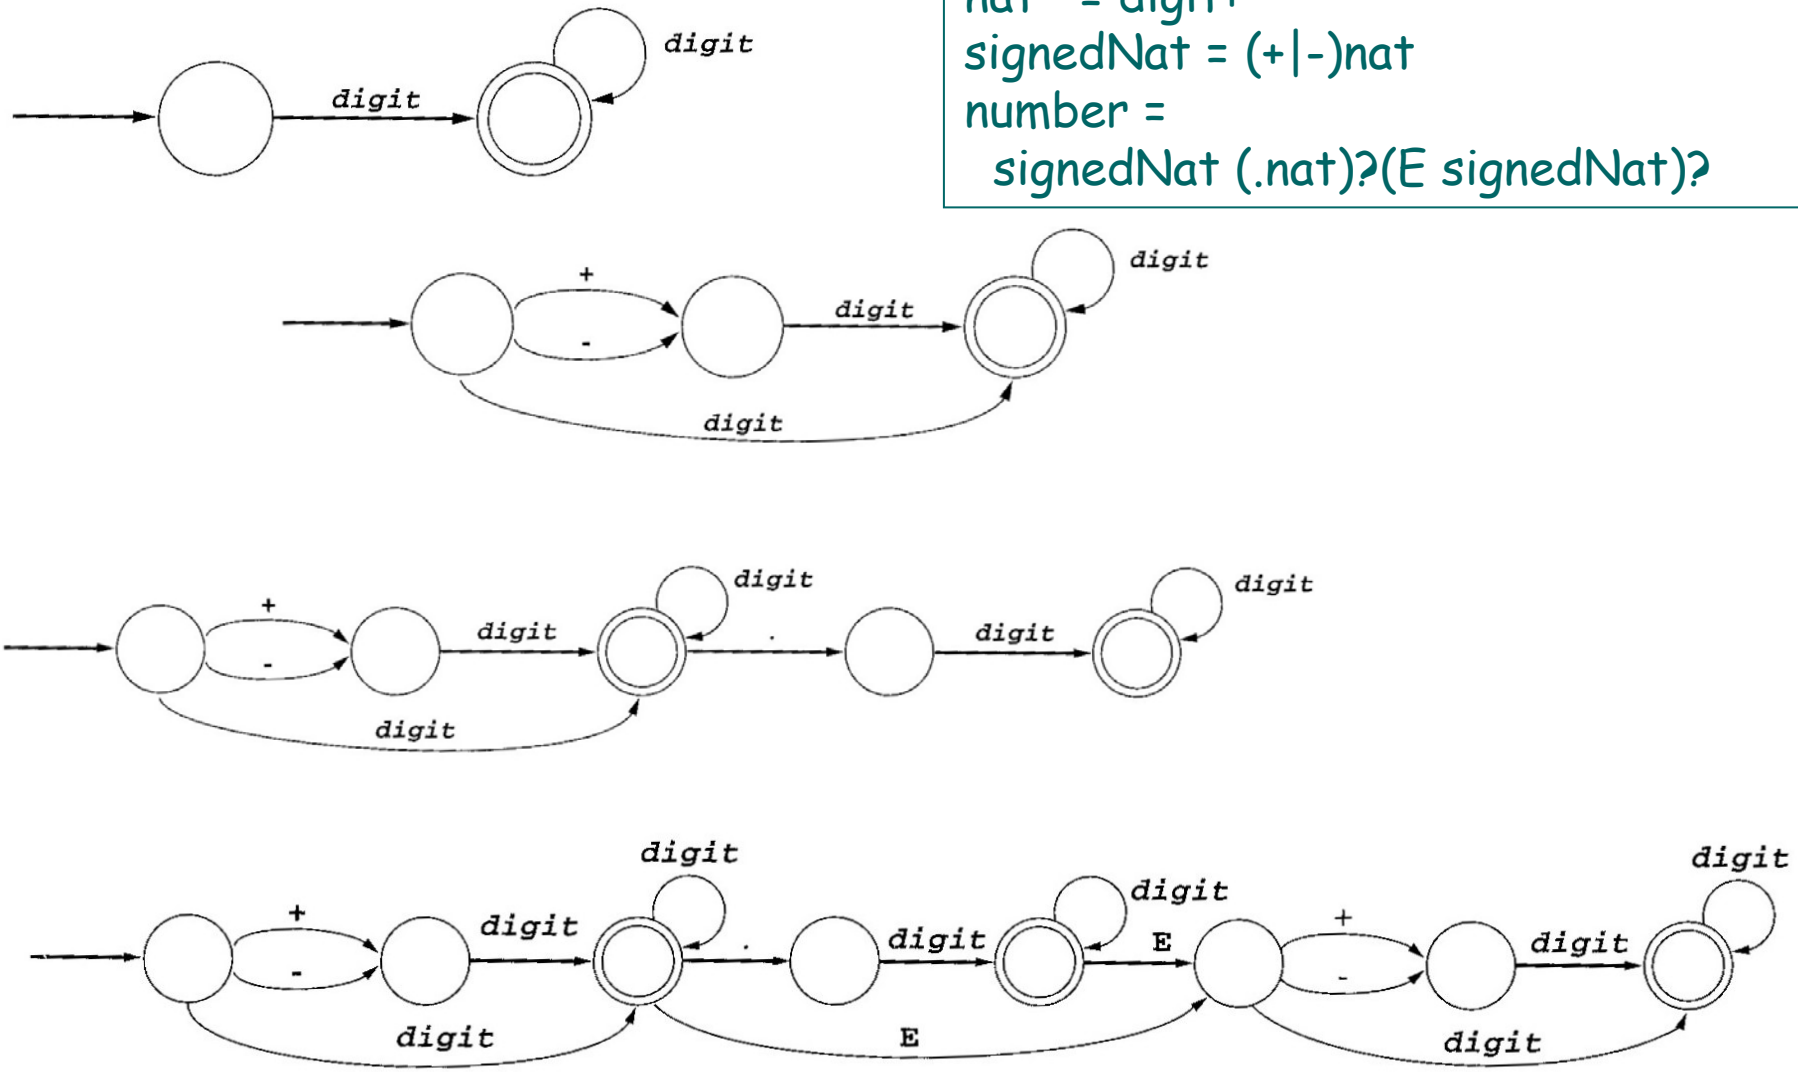

DFA for kommentarer

Pascal type

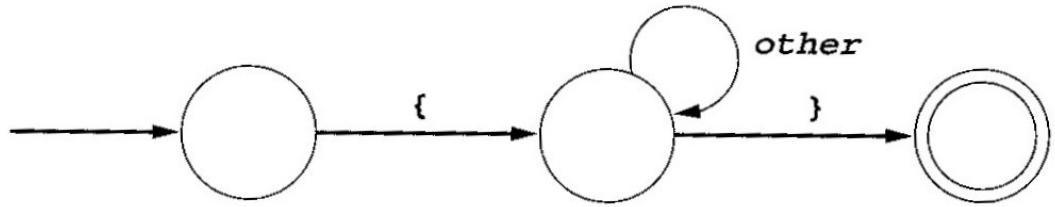

C, C++, Java type

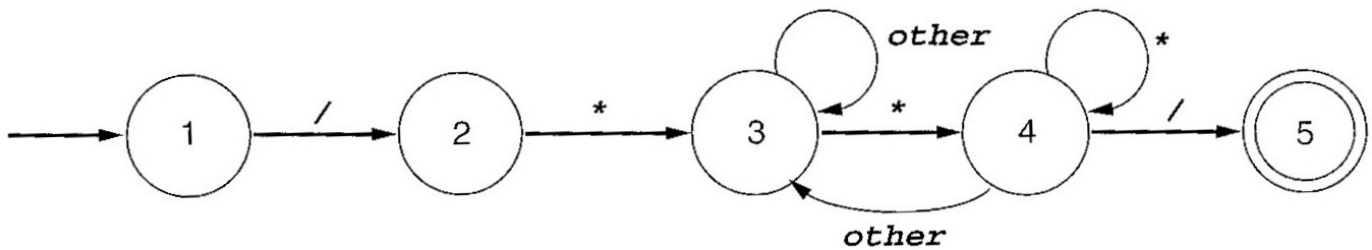

Implementasjon 1 av DFA

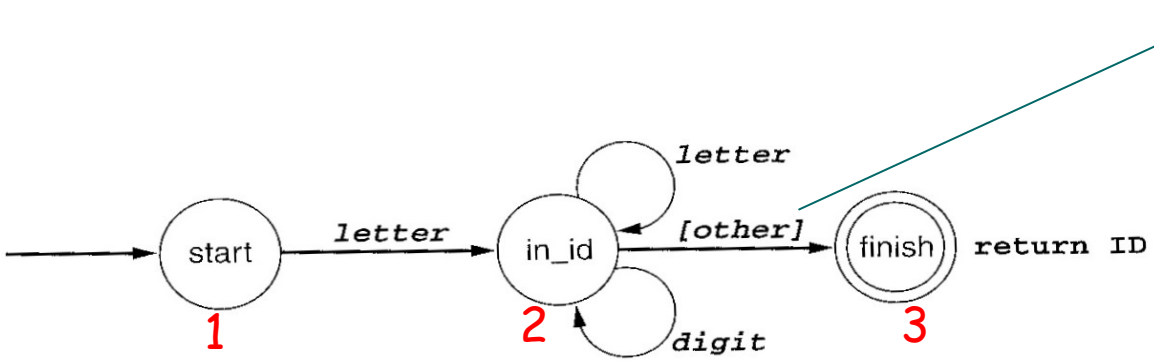


```
{ starting in state 1 }
if the next character is a letter then
   advance the input;
   { now in state 2 }
   while the next character is a letter or a digit do
     advance the input; { stay in state 2 }
   end while;
   { go to state 3 without advancing the input }
   accept;
else
   { error or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

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

Implementasjon 2 av DFA

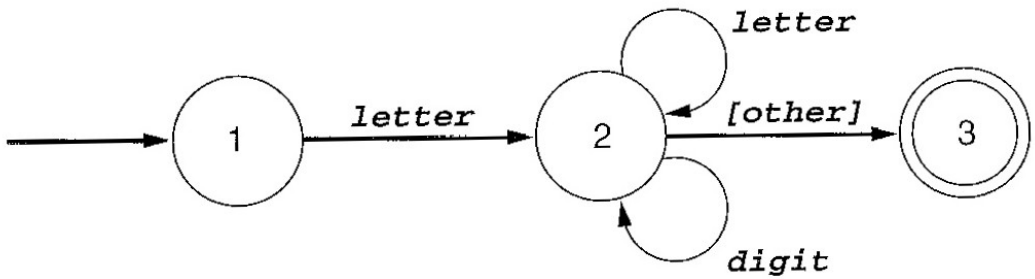

Tilstanden eksplisitt representert ved et tall

```
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 - 2005

Implementasjon 3 av DFA

- Har et fast program
- Automaten liger i en tabell

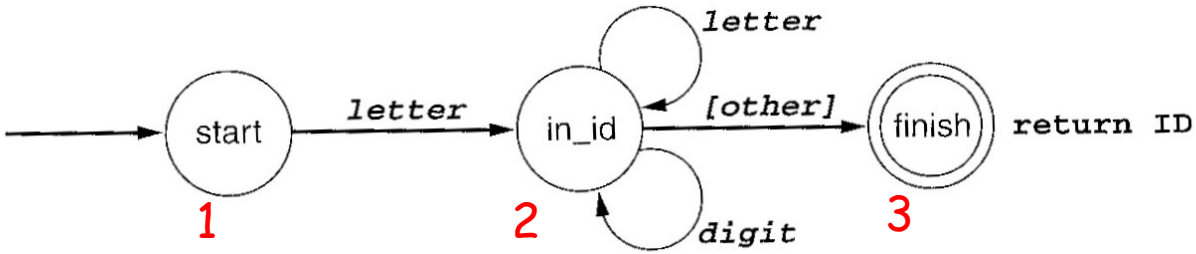

state \ input char	letter	digit	other
1	2		
2	2	2	3
3			

```
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

Definisjon av NFA

An **NFA** (nondeterministic finite automaton) M consists of an alphabet Σ, a set of states S, a transition function T: $S \times (\Sigma \cup \{\varepsilon\}) \rightarrow \wp(S)$, a start state s_0 from S, and a set of accepting states A from S. The language accepted by M, written $L(M)$, is defined to be the set of strings of characters $c_1c_2 \ldots c_n$ with each c_i from $\Sigma \cup \{\varepsilon\}$ such that there exist states s_1 in $T(s_0, c_1)$, s_2 in $T(s_1, c_2)$, . . . , s_n in $T(s_{n-1}, c_n)$ with s_n an element of A.

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

NFA

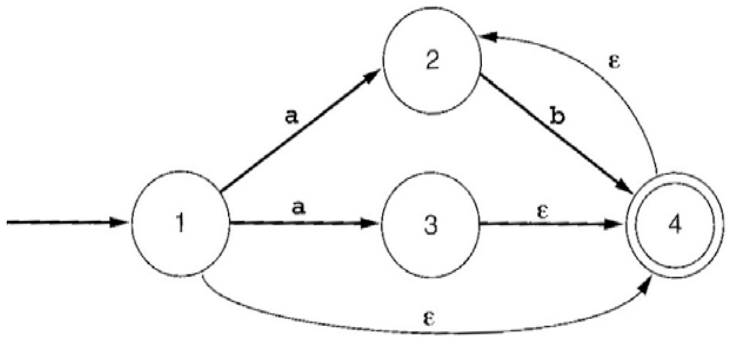

DFA

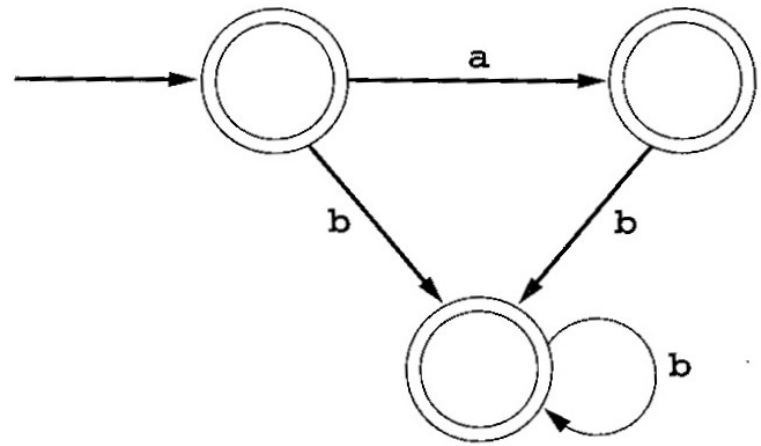

- ikke greit å gjøre til algoritme
- beskriver samme språk

Motivasjon for å innføre NFA-er (1)

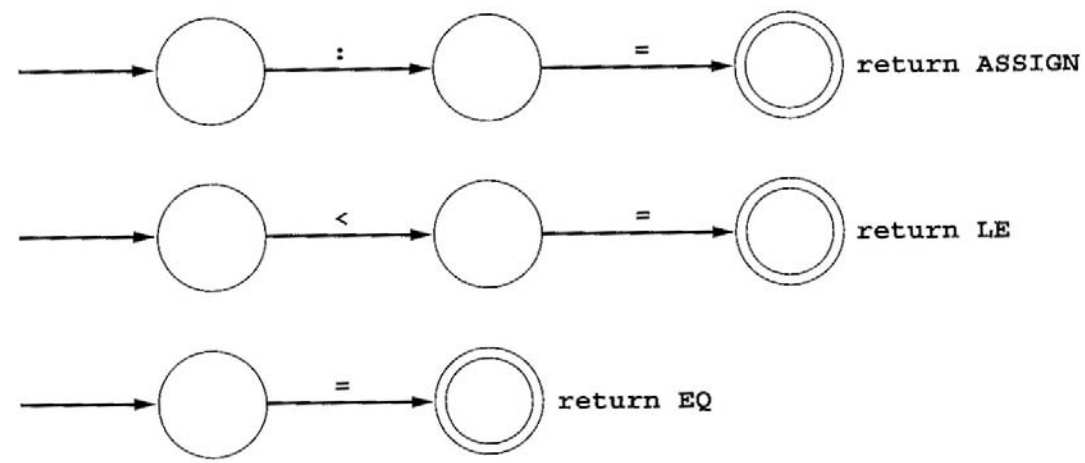

DFA-er for de enkelte token

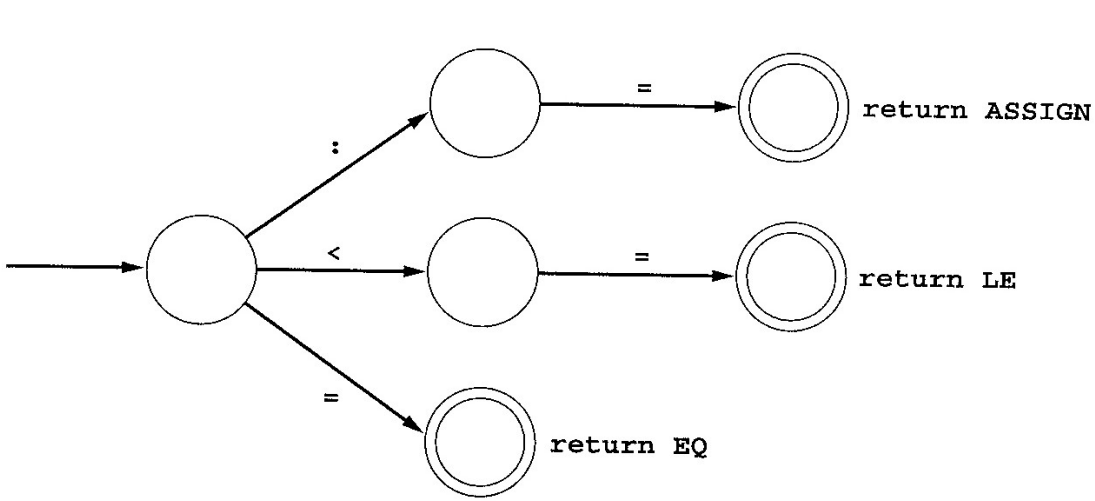

Siden de starter forskjellig går det greit å slå dem sammen

Motivasjon for å innføre NFA-er (2)

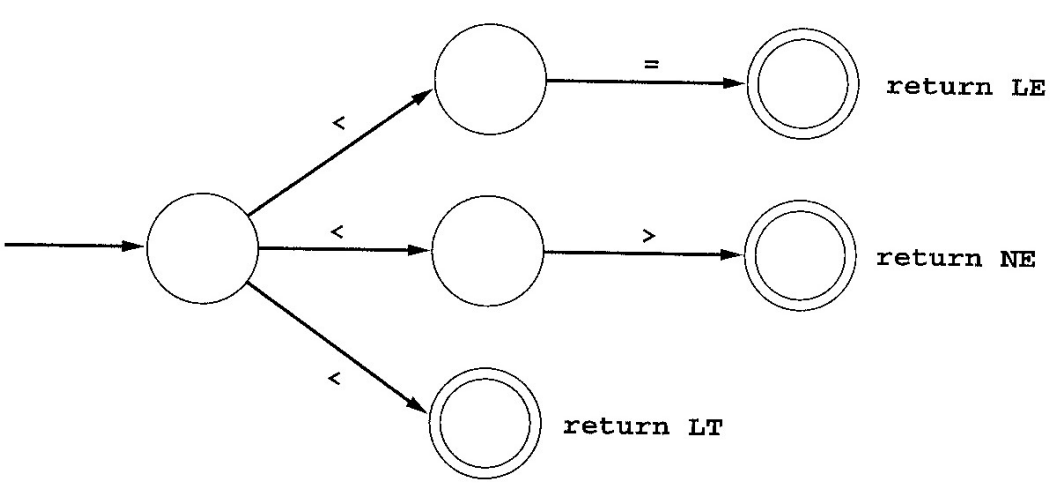

Med disse token-definisjoner går det ikke med en enkel sammenslåing

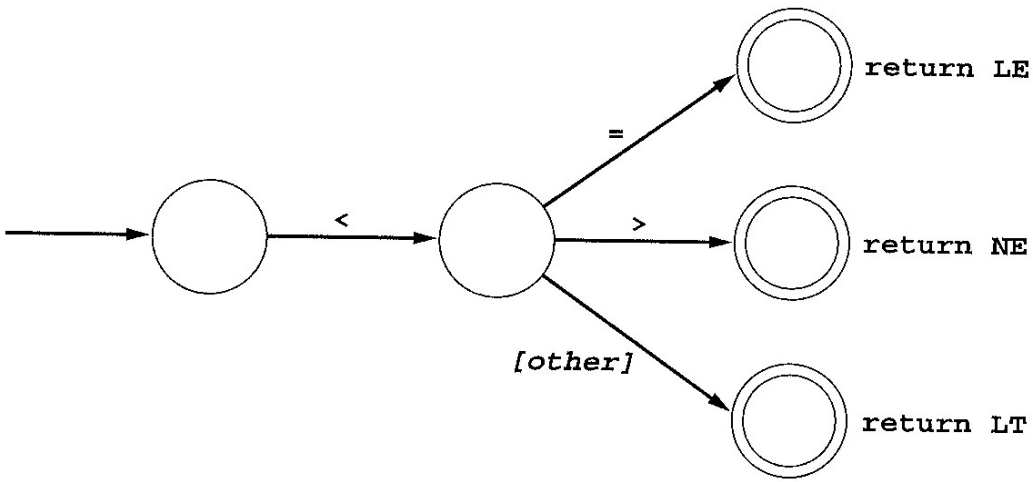

I dette tilfellet går det an å slå sammen på første tegn

Motivasjon for å innføre NFA-er (3)

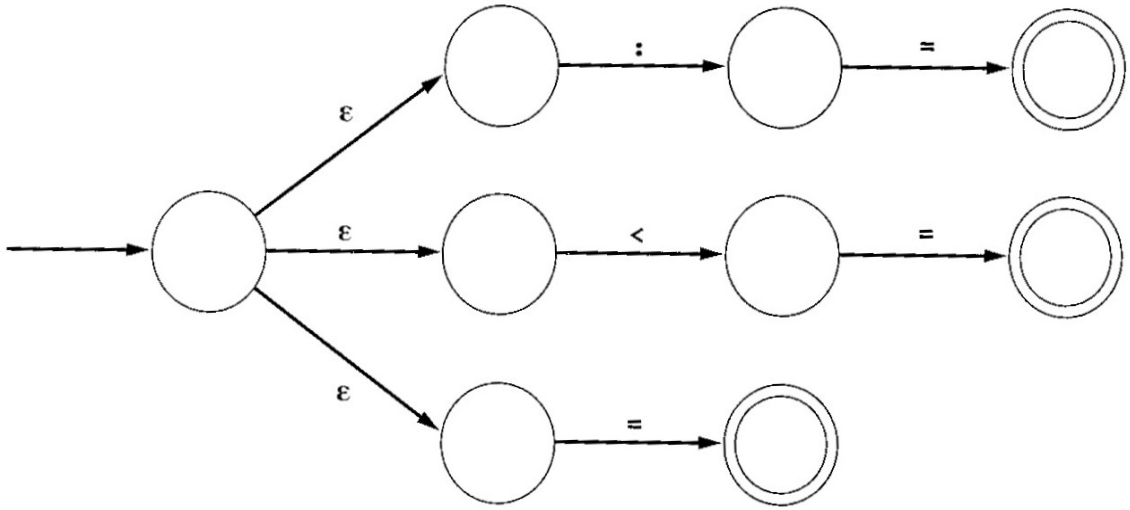

Ville være greiere generelt å gjøre det slik

Derfor

(1) Innfører ε-kant

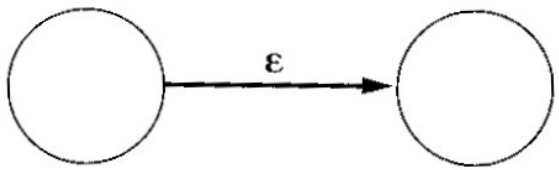

(2) Fjerner kravet om bare én a-kant ut fra hver tilstand

Thomson-konstruksjon I

(Ethvert regulært uttrykk skal bli automat på denne formen:

a:

ε:

rs:

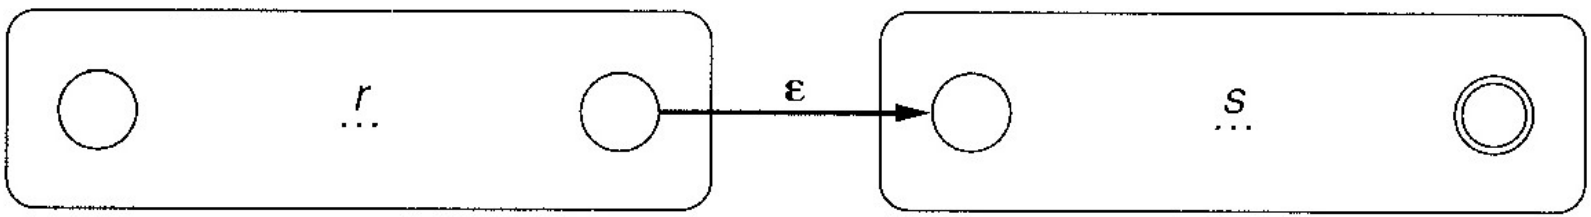

Thomson-konstruksjon II

r | s:

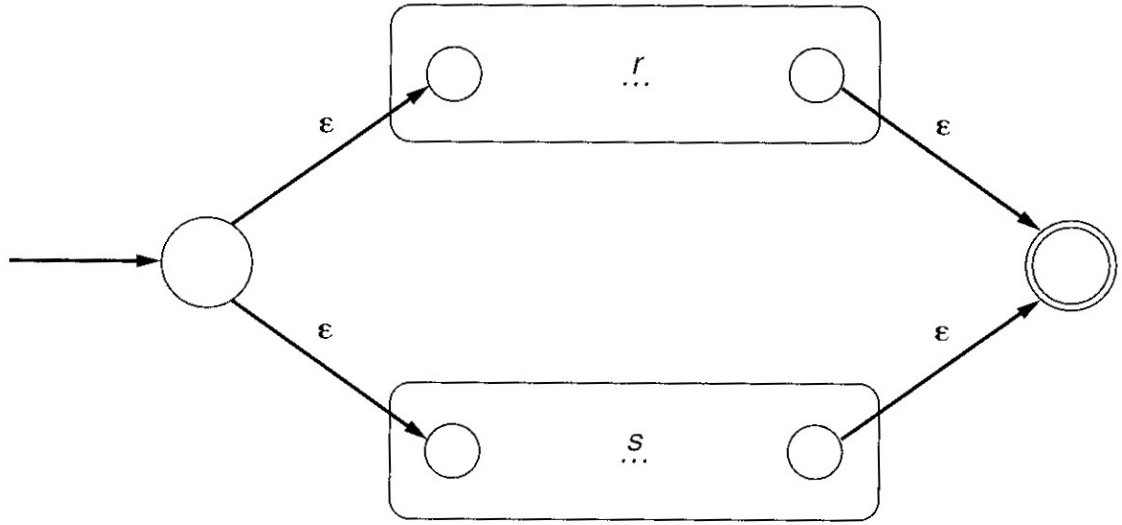

r*:

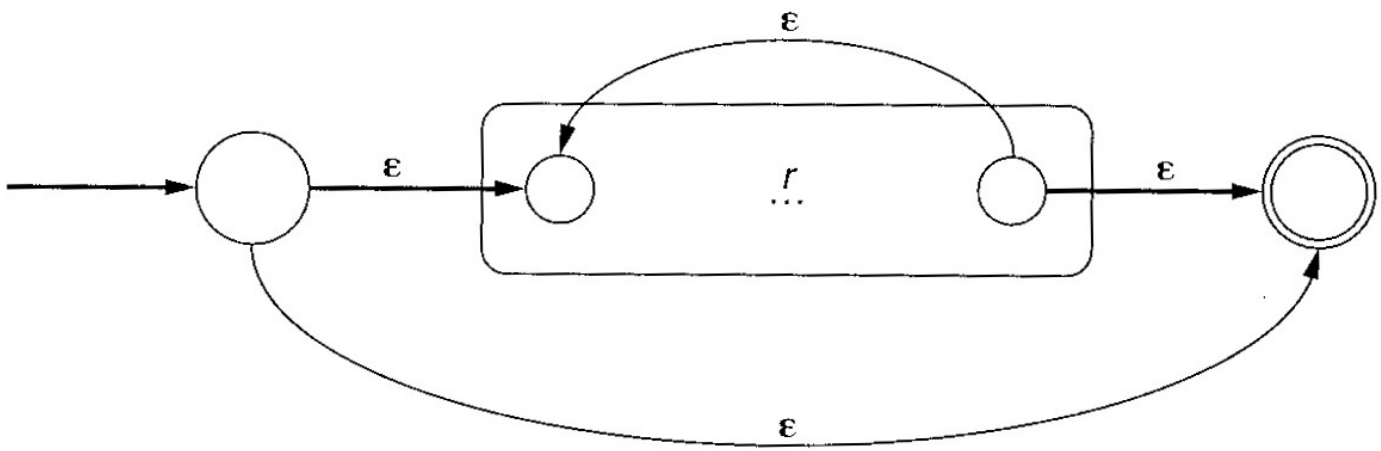

Eksempel Thomson-konstruksjon

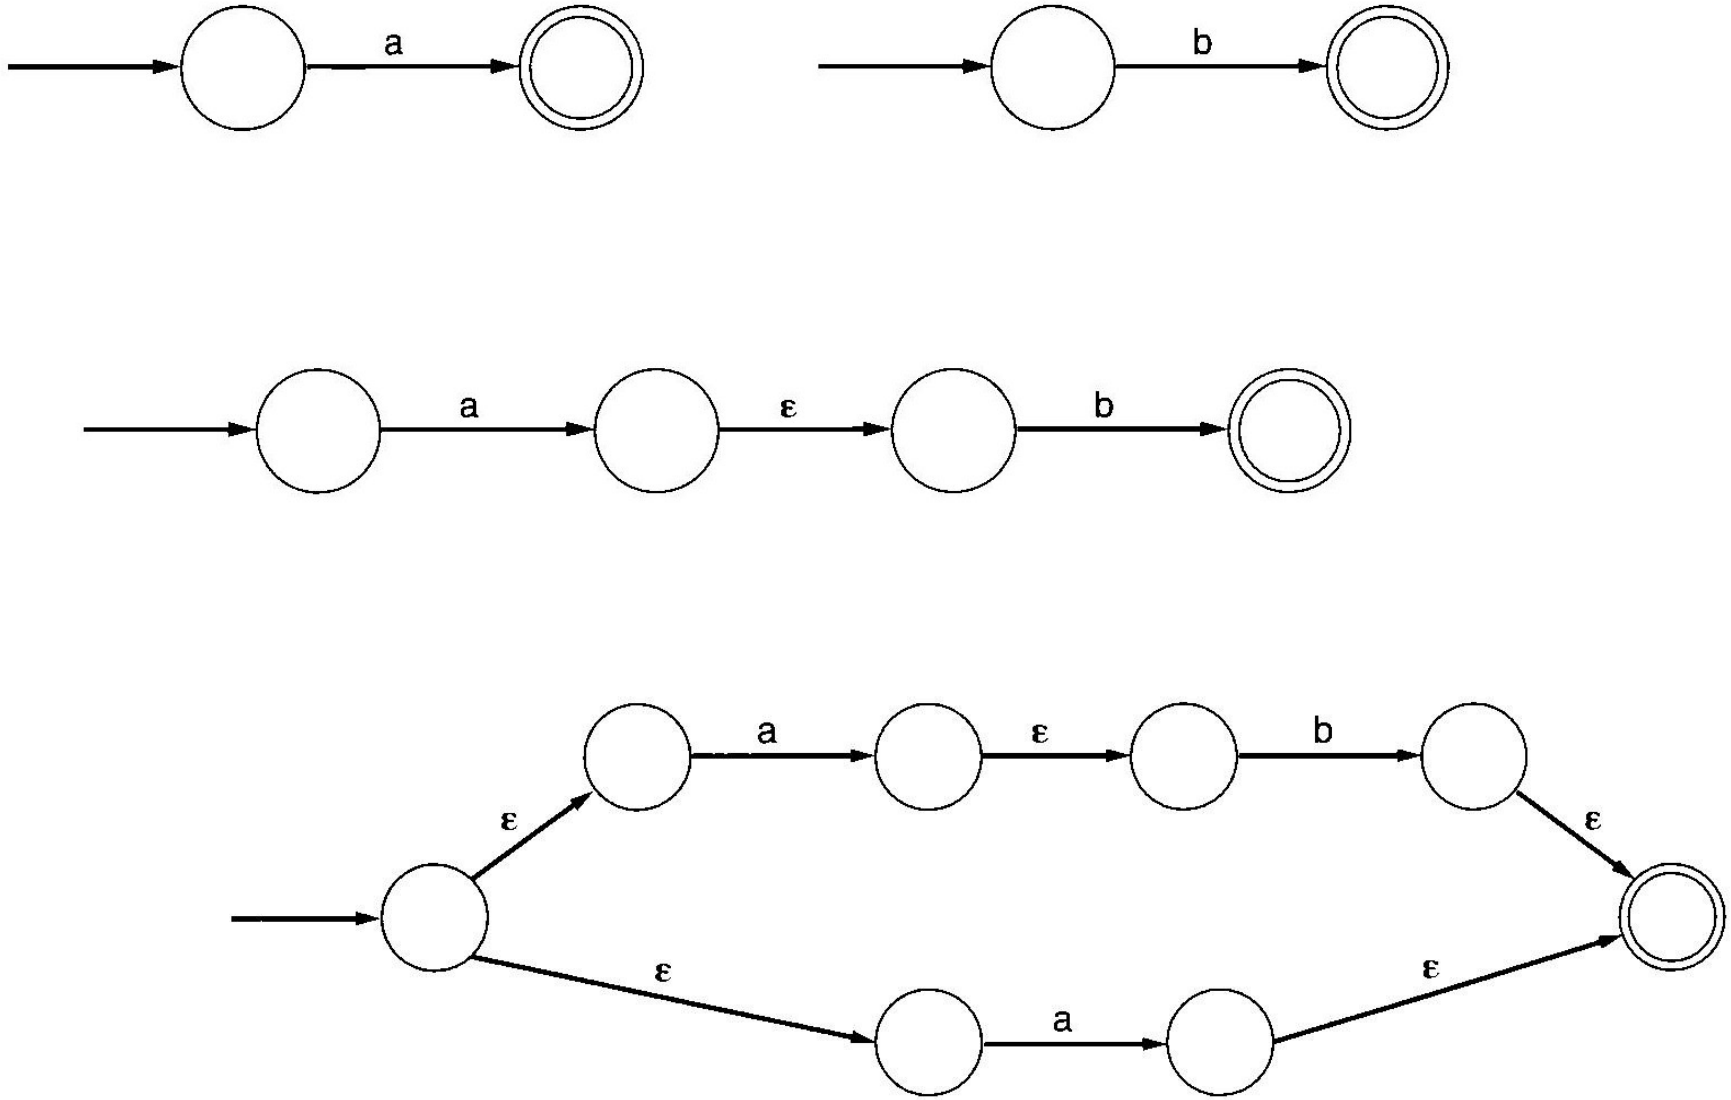

Transformasjon fra NFA: M til DFA: M’ $(\overline{M})$

"The subset construction" (side 70)

- DEFINISJONER

  Gitt en mengde (et ”utplukk”) S av M-tilstander. Vi definerer:

  – ε-tillukning av S: S selv, utvidet med alle M-tilstander man kan nå ved bare å bruke (en eller flere) ε-kanter fra S

  – Sa: Den mengden av M-tilstander man kan nå fra S ved å følge én a-kant.

- IDÉ VED KONSTRUKSJONEN

  – Hver tilstand S i M’ er definert ved en mengde av M-tilstander

  – Gitt streng α. I M’ skal denne føre til tilstanden S definert ved *alle de M-tilstander som α kan føre fram til* ved forskjellige ikke-deterministike valg i M.

Transformasjon fraNFA: M til DFA: M’

ALGORITME

1. Lag start-tilstanden i M’ som ε-tillukningen av {start-tilstanden i M}
2. Om S er en tilstand i M’, så gjelder:

(Må eventuelt opprette ny M'-tilstand)

3. Gjenta steg 2 for alle S i M’ og alle a i alfabetet til M’ ikke får flere nye tilstander.
4. De aksepterende tilstander i M’ er de S i M’ som inneholder minst én av de aksepterende tilstander i M.