Kap. 8 del 1 – kodegenerering
INF5110 – v2006

Arne Maus,
Ifi UiO

Pensumoversikt - kodegenerering

8.1 Bruk av mellomkode

8.2 Basale teknikker for kode-generering

8.3 Kode for referanser til datastrukturer (ikke 8.3.2)

8.4 Kode for genereing for kontroll-setninger og logiske uttrykk

(8.5 Kode-generering for prosedyrer og kall)

---------(resten ikke pensum)—

8.6 Kode produsert av to kommersielle kompilatorer

8.7 TM: En enkel maskin

8.8 Kode-gen for Tiny på TM

8.9 og 8.10 Optimalisering

+Pensum:

En del fra utdelt kap 9 fra Aho, Sethi og Ullmann ' s kompilatorbok ("Drage-boka") :

9.2,9.4, 9.5 og 9.6

Hvordan er instruksjonene i en virkelig CPU?

- Ofte: et antall Registere (8-128) hvor add, mult, sub, shift … går mellom disse.
- Load og store fra register til/fra memory
- Base- og indeks-registre (spesielle, eller alle kan være det)
- En instruksjon brytes ned i en rad mikro-instruksjoner
- Viktig:
  - Pipe-line (opp til 22 mikro instr er under utførelse samtidig!)
  - Spekulativ utføring:
    - av neste, neste-neste instrukjon
    - gjetter på hopp (utfører 'begge' grener)
- Få rene stakk-baserte maskiner

Logisk diagram over en Pentium 4

- Advanced Dynamic Execution
  - Deep, out-of-order, speculative execution engine
    - Up to 126 instructions in flight
    - Up to 48 loads and 24 stores in pipeline[1]

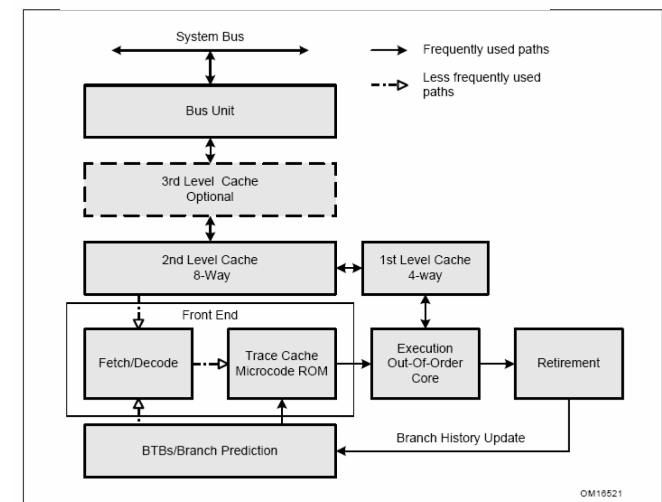

Figure 2-2. The Intel NetBurst Microarchitecture

Intel – utviklet fra 8bit-16bit-32bit -64bit

- Variabelt format – 722-sider manual – noen hundre instr.

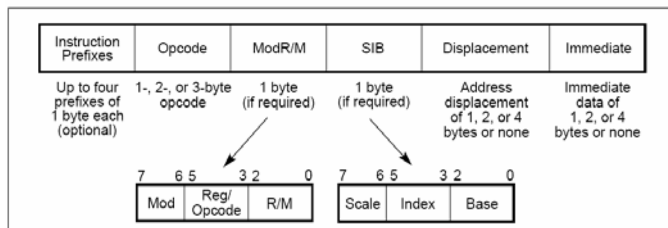

Figure 2-1. IA-32 Instruction Format

5.1.2 Binary Arithmetic Instructions

The binary arithmetic instructions perform basic binary integer computations on byte, word, and doubleword integers located in memory and/or the general purpose registers.

ADD	Integer add
ADC	Add with carry
SUB	Subtract

Hukommelses nivåene – størrelse og hastighet

Type	størrelse	rel hastighet
Register	8-128	1
cache L1 data og instr.	12-512 kb	1-2
cache L2	0.5-2Mb	5-10
cache L3 (Itanium)	noen Mb	?
hoved Mem	o.5-2 Gb	100
Disk	80-800 Gb	1 000 000

8.1 Bruk av mellomkode

- Man kan godt generere maskinkode direkte fra syntakstreet
- Men: Det kan være greit å overføre programmet til en lineær form: "mellom-kode"
- Vi skal se på to former:
  - Treadresse-kode (TA-kode)
    - Setter navn på mellomresultater
    - Forholødsvis lett å snu om på rekkefølgen av koden (optimalisering)
  - P-kode (Pascal-kode – a la Javas "byte-kode)
    - var opprinnelig beregnet på interpretering
    - Mellomresultaten på en stakk (operasjonene komme postfiks)
- Mange valg, f.eks.:
  - Bevarer vi symboltabellene
  - Er det operasjoner for array-aksess (eller blir de løst opp i flere, enklere operasjoner?)
- I fremstillingen 'blandes' hele tiden:
  - Lage kode (som virker)
  - Optimalise koden

Tre-adresse (TA)-kode - eks

2*a+(b-3)

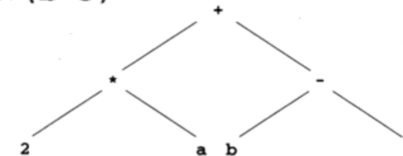

Tre-adresse (TA) kode

```
t1 = 2 * a
t2 = b - 3
t3 = t1 + t2
```

En alternativ kode

```
t1 = b - 3
t2 = 2 * a
t3 = t2 + t1
```

t_1 t_2, t_3,... er temporære variable

TA grunnform

x = y *op* z

op = +, - , *, /, < , > ,....
and, or

Også:

x = op y

op = not, -, (int)

Andre TA-koder:
x = y
if_false x goto L
Label L
read x
write x
...

Oversettelsen til treadresse-kode

```
1 read x; { input an integer }
2 if 0 < x then { don't compute if x <= 0 }
3   fact := 1;
4   repeat
5     fact := fact * x;
6     x := x - 1
7   until x = 0;
8   write fact { output factorial of x }
9 end
```

```
1  read x
2  t1 = x > 0
   if_false t1 goto L1
3  fact = 1
4  label L2
5  t2 = fact * x
   fact = t2
6  t3 = x - 1
   x = t3
7  t4 = x == 0
   if_false t4 goto L2
8  write fact
   label L1
9  halt
```

Spørsmål:
- -Er det egne instruksjoner for int, long, float,..?
- -Hvordan er variable representert?
  - -ved navn
  - -peker til deklarasjon i symb.tabell
  - -ved maskinadresse
- -Hvordan er hver instruksjon lagret?
  - -kvadrupler
  - -tripler der også "adressen" er navn på en temporær

En mulig datastruktur for å lagre en treadresse-struktur

operasjonskodene:

```
typedef enum {rd,gt,if_f,asn,lab,mul,
              sub,eq,wri,halt,. . .} OpKind;
typedef enum {Empty,IntConst,String} AddrKind;
typedef struct
        { AddrKind kind;
          union
          { int val;
            char * name;
          } contents;
        } Address;
typedef struct
        { OpKind op;
          Address addr1,addr2,addr3;
        } Quad;
```

Hver adresse har denne formen

op: - opcode
addr1: - kind, val/name
addr2: - kind, val/name
addr3: - kind, val/name

P-kode (Pascal – kode – utfører beregning på en stakk) - del I

koden utføres 'normalt (etter hverandre + jump, **men** beregninger på stakk)

```
"push" koder (=load på stakken):
ldv   ;  load value
ldc   ;  load constant
lda   ;  load adress
```

```
2*a+(b-3)
```

```
ldc 2        ; load constant 2
lod a        ; load value of variable a
mpi          ; integer multiplication
lod b        ; load value of variable b
ldc 3        ; load constant 3
sbi          ; integer subtraction
adi          ; integer addition
```

P-kode II

```
x := y + 1

lda x        ; load address of x
lod y        ; load value of y
ldc 1        ; load constant 1
adi          ; add
sto          ; store top to address
             ; below top & pop both
```

P-kode for fakultets-funksjonen

Blir typisk mange flere enn TA-instruksjoner for samme program (Hver PA instruksjon har to, én eller ingen adresser)

```
lda x        ; load address of x
rdi          ; read an integer, store to
             ; address on top of stack (& pop it)
lod x        ; load the value of x
ldc 0        ; load constant 0
grt          ; pop and compare top two values
             ; push Boolean result
fjp L1       ; pop Boolean value, jump to L1 if false
lda fact     ; load address of fact
ldc 1        ; load constant 1
sto          ; pop two values, storing first to
             ; address represented by second
lab L2       ; definition of label L2
lda fact     ; load address of fact
lod fact     ; load value of fact
lod x        ; load value of x
mpi          ; multiply
sto          ; store top to address of second & pop
lda x        ; load address of x
lod x        ; load value of x
ldc 1        ; load constant 1
sbi          ; subtract
sto          ; store (as before)
lod x        ; load value of x
ldc 0        ; load constant 0
equ          ; test for equality
fjp L2       ; jump to L2 if false
lod fact     ; load value of fact
wri          ; write top of stack & pop
lab L1       ; definition of label L1
stp
```

Generering av P-kode (I)

Grammar Rule	Semantic Rules
$exp_1 \rightarrow$ **id** = exp_2	exp_1 .pcode = "**lda**" ‖ **id** .strval ++ exp_2 .pcode ++ "**stn**"
$exp \rightarrow aexp$	exp .pcode = $aexp$ .pcode
$aexp_1 \rightarrow aexp_2$ + $factor$	$aexp_1$ .pcode = $aexp_2$ .pcode ++ $factor$ .pcode ++ "**adi**"
$aexp \rightarrow factor$	$aexp$ .pcode = $factor$ .pcode
$factor \rightarrow$ (exp)	$factor$ .pcode = exp .pcode
$factor \rightarrow$ **num**	$factor$ .pcode = "**ldc**" ‖ **num** .strval
$factor \rightarrow$ **id**	$factor$ .pcode = "**lod**" ‖ **id** .strval

`(x=x+3)+4`

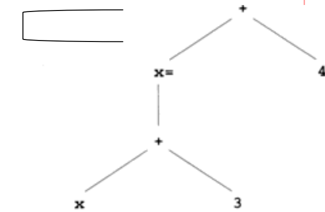

Generering av P-kode (II)

`(x=x+3)+4`

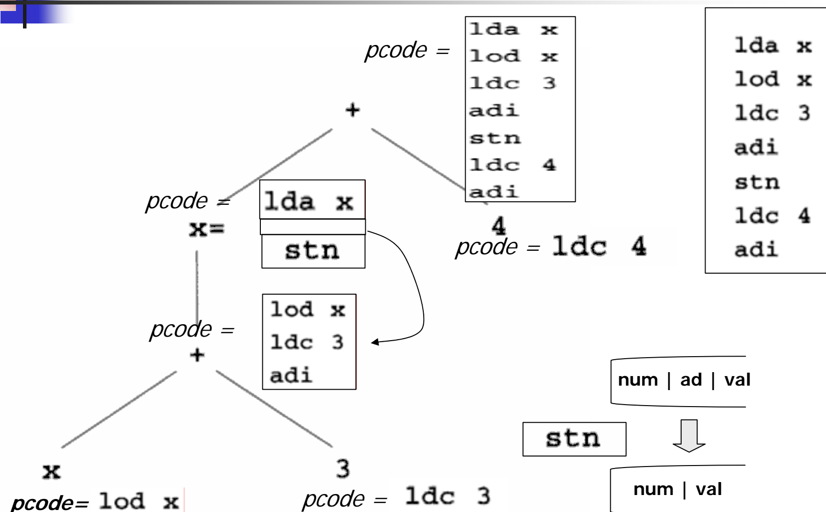

Generering av treadresse-kode

`(x=x+3)+4`

Grammar Rule	Semantic Rules
$exp_1 \rightarrow$ **id** = exp_2	exp_1 .name = exp_2 .name exp_1 .tacode = exp_2 .tacode ++ **id** .strval ‖ "=" ‖ exp_2 .name
$exp \rightarrow aexp$	exp .name = $aexp$ .name exp .tacode = $aexp$ .tacode
$aexp_1 \rightarrow aexp_2$ + $factor$	$aexp_1$ .name = newtemp( ) $aexp_1$ .tacode = $aexp_2$ .tacode ++ $factor$ .tacode ++ $aexp_1$ .name ‖ "=" ‖ $aexp_2$ .name ‖ "+" ‖ $factor$ .name
$aexp \rightarrow factor$	$aexp$ .name = $factor$ .name $aexp$ .tacode = $factor$ .tacode
$factor \rightarrow$ (exp)	$factor$ .name = exp .name $factor$ .tacode = exp .tacode
$factor \rightarrow$ **num**	$factor$ .name = **num** .strval $factor$ .tacode = ""
$factor \rightarrow$ **id**	$factor$ .name = **id** .strval $factor$ .tacode = ""

Generering av treadresse-kode

```
t1 = x + 3
x = t1
t2 = t1 + 4
```

(x=x+3)+4

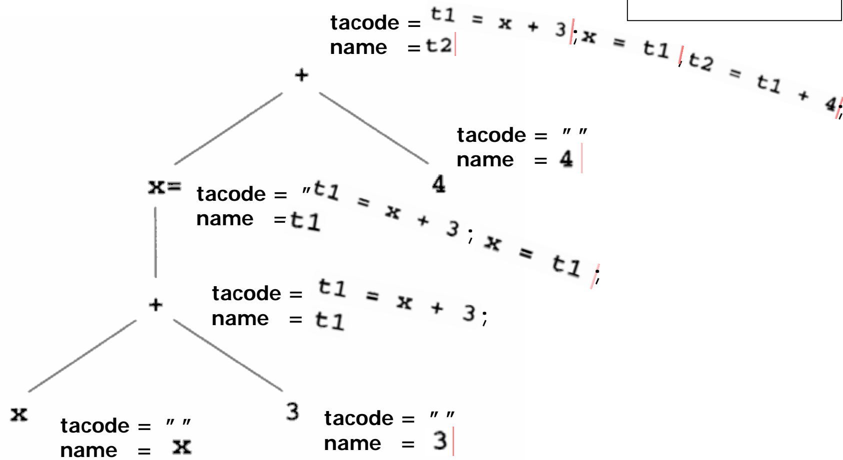

Kodegenerering kan gjøres ved rekursiv gjennomgang av syntakstreet

Tre-node:

```
typedef enum {Plus,Assign} Optype;
typedef enum {OpKind,ConstKind,IdKind} NodeKind;
typedef struct streenode
      { NodeKind kind;
        Optype op; /* used with OpKind */
        struct streenode *lchild,*rchild;
        int val; /* used with ConstKind */
        char * strval;
          /* used for identifiers and numbers */
      } STreeNode;
typedef STreeNode *SyntaxTree;
```

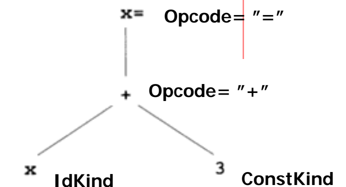

Kode-skisse til generelt bruk

procedure *genCode (T: treenode)*;
begin
  if *T is not nil* **then**
    generate code to prepare for code of left child of T ; ← **Prefiks - operasjoner**
    genCode(left child of T) ; ← **rek kall**
    generate code to prepare for code of right child of T ; ← **Infiks - operasjoner**
    genCode(right child of T) ; ← **rek kall**
    generate code to implement the action of T ; ← **Postfiks - operasjoner**
end;

Generering av P-kode

```
void genCode( SyntaxTree t)
{ char codestr[CODESIZE];
  /* CODESIZE = max length of
  if (t != NULL)
  { switch (t->kind)
    { case OpKind:
        switch (t->op)
        { case Plus:
            genCode(t->lchild)   ← rek.kall
            genCode(t->rchild)   ← rek.kall
            emitCode("adi");
            break;
          case Assign:
            sprintf(codestr,"%s %s",
                          "lda",t->strval);
            emitCode(codestr);
            genCode(t->lchild);   ← rek.kall
            emitCode("stn");
            break;
          default:
            emitCode("Error");
            break;
        }
        break;
      case ConstKind:
        sprintf(codestr,"%s %s","ldc",t->strval);
        emitCode(codestr);
        break;
      case IdKind:
        sprintf(codestr,"%s %s","lod",t->strval);
        emitCode(codestr);
        break;
      default:
        emitCode("Error");
        break;
    }
  }
}
```

Kunne vært gjort under parsering med Yacc

```
%{
#define YYSTYPE char *
    /* make Yacc use strings as values */

/* other inclusion code ... */
%}

%token NUM ID

%%

exp     : ID
          { sprintf(codestr,"%s %s","lda",$1);
            emitCode(codestr); }
          '=' exp
          { emitCode("stn"); }
        | aexp
        ;

aexp    : aexp '+' factor {emitCode("adi");}
        | factor
        ;

factor  : '(' exp ')'
        | NUM       { sprintf(codestr,"%s %s","ldc",$1);
                      emitCode(codestr); }
        | ID        { sprintf(codestr,"%s %s","lod",$1);
                      emitCode(codestr); }
        ;

%%
/* utility functions ... */
```

Verdiene på stakken er strenger

← Merk: Denne aksjonen kommer **før** uttrykket

Fra P-kode til TA-kode ("Statisk simulering")

(x=x+3)+4

P-kode:

```
lda x
lod x
ldc 3
adi
stn
ldc 4
adi
```

Stakk:

Stadier:

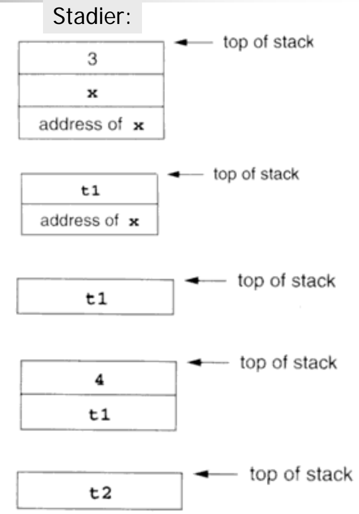

Ønskemål:

```
t1 = x + 3
x = t1
t2 = t1 + 4
```

Fra TA-kode til P-kode - I ("makro-eksansjon")

(x=x+3)+4

Makro:

```
lda a
lod b ; or ldc b if b is a const
lod c ; or ldc c if c is a const
adi
sto
```

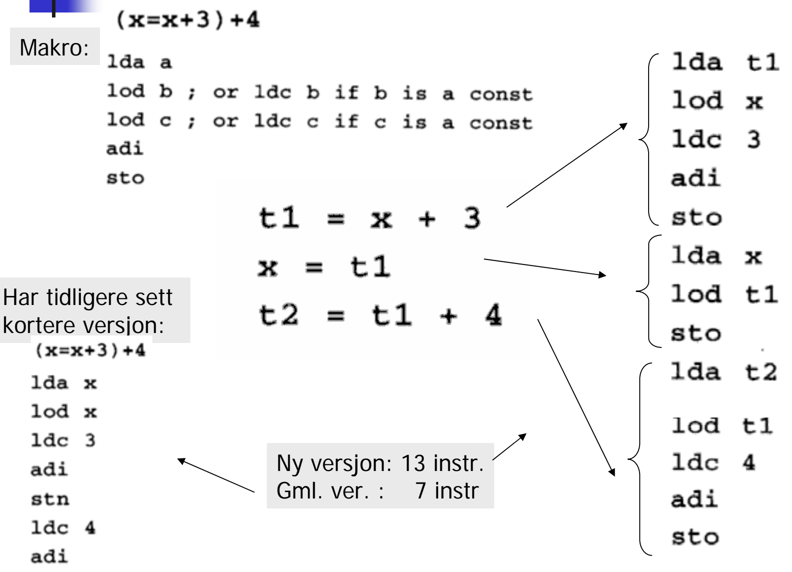

```
t1 = x + 3
x = t1
t2 = t1 + 4
```

```
lda t1
lod x
ldc 3
adi
sto
lda x
lod t1
sto
lda t2
lod t1
ldc 4
adi
sto
```

Har tidligere sett kortere versjon:

```
(x=x+3)+4
lda x
lod x
ldc 3
adi
stn
ldc 4
adi
```

Ny versjon: 13 instr.
Gml. ver. : 7 instr

Fra TA-kode til P-kode II

Prøver å lage bedre kode

```
t1 = x + 3
x = t1
t2 = t1 + 4
```

Tegner opp "data-flyt" –grafen / treet

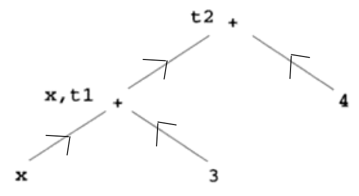

En rettet graf uten løkker (DAG)

Må gjøre forskjell på temporære og program-variable.
Kan da se det som:

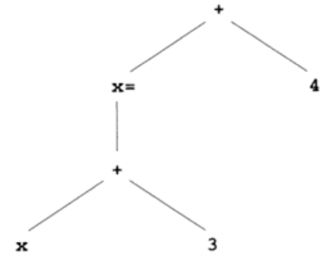


```
lda x
lod x
ldc 3
adi
stn
ldc 4
adi
```

Kap. 8.3 – Aksess av datastruktur, trenger mer fleksibel adresse-beregning

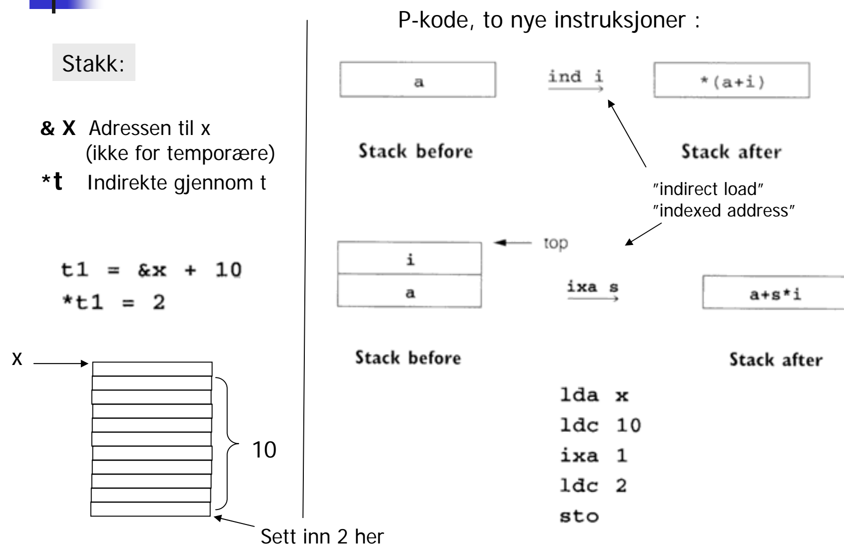

Litt generelt til kap. 8.3

- Det lages nokså "lavnivå" TA-kode og P-kode
- Man kan ikke lenger se hva slags konstrukturer den kommer fra
- Det er ikke opplagt at dette er det fornuftigste om mellom-koden skal oversettes videre til maskin-kode, f.eks:
  - Beholde en ikke-lokal eller ikke-global variabel på formen:
    X: (rel.niv.=2, reladr=3)
  - Istedenfor å oversette til formen:
    fp.al.al.(reladr=3) i TA-kode eller P-kode
- Kan kanskje like gjerne se oversettelse til lav-nivåTA-kode eller P-kode som eksempel på oversettelse direkte til maskin-kode

TA-kode og P-kode for strukt/record-aksess (Tilsvarende for "fp" til metode-kall)

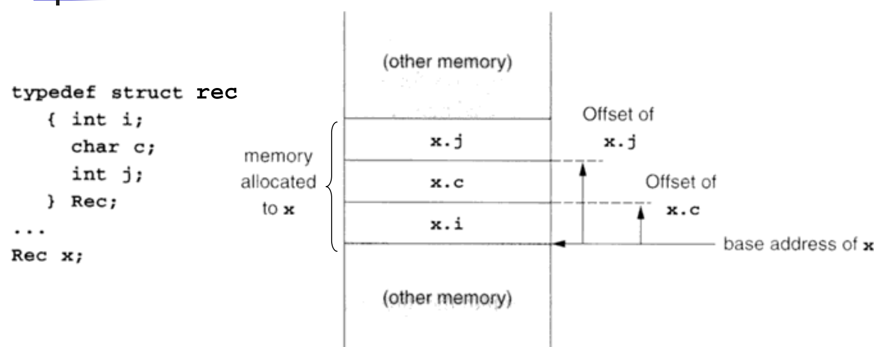

Skal se på

1. En variable av typen Rec ligger statisk allokert (som "x" over)
2. Vi har en peker til en struct/record (f.eks. "fp" til metodekall)

Generering av TA-kode

Statisk allokert variabel

```
x.j = x.i;
```

```
t1 = &x + field_offset(x,j)
t2 = &x + field_offset(x,i)
*t1 = *t2
```

ville være like logisk å oppgi her struct-typen, altså "rec"

Peker til struct (kan for eksempel være "fp" metode kall)

```
typedef struct treeNode
  { int val;
    struct treeNode * lchild, * rchild;
  } TreeNode;
...
TreeNode *p;
```

Now, consider two typical assignments

```
p->lchild = p;
p = p->rchild;
```

These statements translate into the three-address code

```
t1 = p + field_offset(*p,lchild)
*t1 = p
t2 = p + field_offset(*p,rchild)
p = *t2
```

Eller altså "Tree Node"

Generering av TA og P-kode

```
int   *X;
```

```
*x = i;
```

translates into the P-code

```
lod x
lod i
sto
```

Her kan C-koden nyttes direkte som TA-kode

and the assignment

```
i = *x;
```

translates into the P-code

```
lda i
lod x
ind 0
sto
```

```
Rec   x;
```

```
x.j = x.i;
```

can be translated into the P-code

```
lda x
lod field_offset(x,j)
ixa 1
lda x
ind field_offset(x,i)
sto
```

TreeNode *p;

```
p->lchild = p;
p = p->rchild;
```

```
lod p
lod field_offset(*p,lchild)
ixa 1
lod p
sto
lda p
lod p
ind field_offset(*p,rchild)
sto
```

8.4 : If/while – kap.8.3

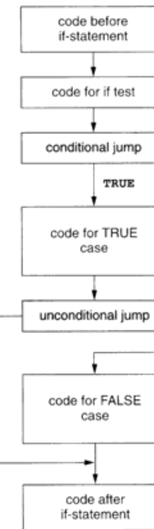

if-stmt → **if** (*exp*) *stmt* | **if** (*exp*) *stmt* **else** *stmt*
while-stmt → **while** (*exp*) *stmt*

```
if ( E ) S1 else S2
```

Skisse av TA-kode

```
<code to evaluate E to t1>
if_false t1 goto L1
<code for S1>
goto L2
label L1
<code for S2>
label L2
```

Skisse av P-kode

```
<code to evaluate E>
fjp L1
<code for S1>
ujp L2
lab L1
<code for S2>
lab L2
```

while - setning

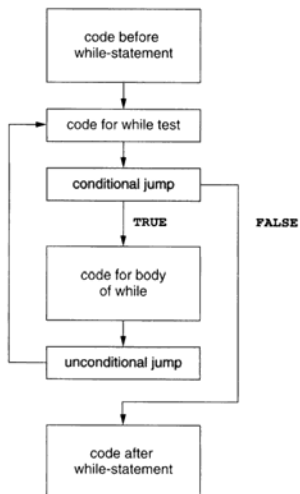


```
while ( E ) S
```

TA-kode

```
label L1
<code to evaluate E to t1>
if_false t1 goto L2
<code for S>
goto L1
label L2
```

P-kode

```
lab L1
<code to evaluate E>
fjp L2
<code for S>
ujp L1
lab L2
```

Behandling av boolske uttykk

- Mulighet 1: Behandle som vanlige uttrykk
- Mulighet 2: Behandling ved 'kort-slutning'

Eksempel i C – siste del beregnes bare dersom første del er sann:

```
if ((p!=NULL) && (p->val==0)) ...
```

a **and** $b \equiv$ **if** a **then** b **else false** a **or** $b \equiv$ **if** a **then true else** b

```
(x!=0)&&(y==x)
```

P-kode:

```
lod x
ldc 0
neq
fjp L1
lod y
lod x
equ
ujp L2
lab L1
lod FALSE
lab L2
```

(Arrows: *a* from `fjp L1` to `lab L1`; *b* from `ujp L2` to `lab L2`.)

Merk:

Om dette uttrykket stod i sammenhengen:

if <utr> then S1 else S2

så kunne hoppet "a" til L1 gå direkte til else – grenen og alt fra-og-med hoppet "b" kunne fjernes (men vi har en :
  fjp   s2
for selve if-testen. Den måtte med i alle tilfelle)

Oversettelse av if/while-setninger

stmt → *if-stmt* | *while-stmt* | **break** | **other**
if-stmt → **if (** *exp* **)** *stmt* | **if (** *exp* **)** *stmt* **else** *stmt*
while-stmt → **while (** *exp* **)** *stmt*
exp → **true** | **false**

Tre-node:

```
typedef enum {ExpKind,IfKind,
       WhileKind,BreakKind,OtherKind} NodeKind;
typedef struct streenode
         { NodeKind kind;
           struct streenode * child[3];
           int val; /* used with ExpKind */
         } STreeNode;
typedef STreeNode *SyntaxTree;
```

Angir bare false eller true

```
if(true)while(true)if(false)break else other
```

binder sammen

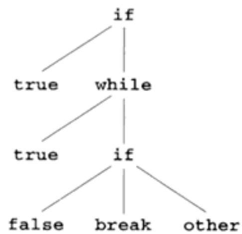

Ser noe merkelig ut når alle boolske uttrykk er konstanter:

```
ldc true
fjp L1
lab L2
ldc true
fjp L3
ldc false
fjp L4
ujp L3
ujp L5
lab L4
Other
lab L5
ujp L2
lab L3
lab L1
```

Rekursiv prosedyre for P-kodegenerering

```
void genCode( SyntaxTree t, char * label)
{ char codestr[CODESIZE];
  char * lab1, * lab2;
  if (t != NULL) switch (t->kind)
  { case ExpKind:
      if (t->val==0) emitCode("ldc false")
      else emitCode("ldc true");
      break;
    case IfKind:
      genCode(t->child[0],label);
      lab1 = genLabel();
      sprintf(codestr,"%s %s","fjp",lab1);
      emitCode(codestr);
      genCode(t->child[1],label);
      if (t->child[2] != NULL)
      { lab2 = genLabel();
        sprintf(codestr,"%s %s","ujp",lab2
        emitCode(codestr);}
      sprintf(codestr,"%s %s","lab",lab1);
      emitCode(codestr);
      if (t->child[2] != NULL)
      { genCode(t->child[2],label);
        sprintf(codestr,"%s %s","lab",lab2
        emitCode(codestr);}
      break;
    case WhileKind:
      lab1 = genLabel();
      sprintf(codestr,"%s %s","lab",lab1);
      emitCode(codestr);
      genCode(t->child[0],label);
      lab2 = genLabel();
      sprintf(codestr,"%s %s","fjp",lab2);
      emitCode(codestr);
      genCode(t->child[1],lab2);
      sprintf(codestr,"%s %s","ujp",lab1);
      emitCode(codestr);
      sprintf(codestr,"%s %s","lab",lab2);
      emitCode(codestr);
      break;
    case BreakKind:
      sprintf(codestr,"%s %s","ujp",label);
      emitCode(codestr);
      break;
    case OtherKind:
      emitCode("Other");
      break;
    default:
      emitCode("Error");
      break;
  }
}
```

Kall på metoder (skissemessig)

Ved kallstedet

Begin-argument-computation instructi
<code to compute the arguments>
Call instruction

Selve funksjonen

Entry instruction
<code for the function body>
Return instruction

TA-kode - eksempel

```
int f(int x, int y)
{ return x+y+1; }
```

TA-koden for funksjonen:

```
entry f
t1 = x + y
t2 = t1 + 1
return t2
```

```
f(2+3,4)
```

translates to the three-address code

```
begin_args
t1 = 2 + 3
arg t1
arg 4
call f
```