

Dagens tema:

Semantisk sjekking

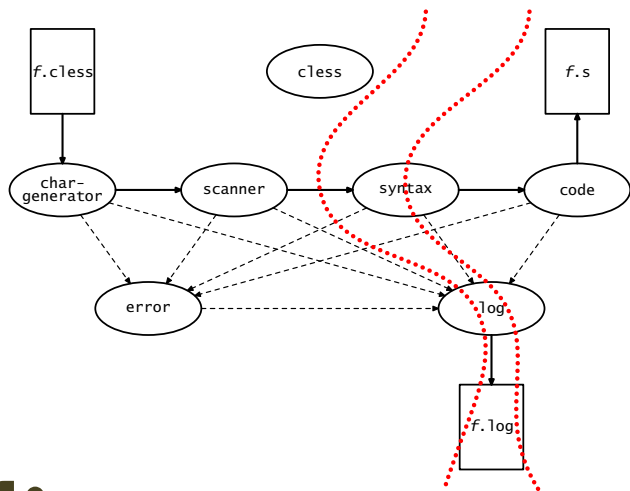
- Hvordan finne deklarasjoner?
- Typesjekking
- Hvordan programmere sjekking av riktig navnebruk?

Maskinkode

- Litt datamaskinhistorie
- Hva er maskin- og assemblerkode?
- x86-prosessoren
- Programkode og variabler

Del-0

Del-1 Del-2



Hva sjekkes ikke?

Noen kompilatorer er «snille» og forteller brukeren at han/hun har skrevet noe som er riktig men dumt.

```
int f (int x)
{
  return x+1;
  x = x+2;
  return x;
}
```

Vår kompilator skal ikke gjøre det. Hvorfor ikke?

- Prosjektet er stort nok allerede.
- Hvor mye dum kode skal man varsle om?

```
int f (int x)
{
  if (x<0) {
    return -1;
  } else if (x>0) {
    return 1;
  }
}
```

```
for (i=1; i<=9; i=i+2) {
  if (i==2) {
    ...
  }
}
```

Hva skal gjøres med deklarasjoner?

Sjekking av deklarasjoner

En kompilator må sjekke riktig navnebruk:

- Alle navn må være deklart.
- Det må ikke forekomme dobbeltdeklarasjoner.
- Deklarerte navn må brukes riktig (enkel variabel kontra array kontra funksjon).

Hvordan finne navn?

Hvordan kople navn og deklarasjon?

```
int a;   int b;  
  
int f ()  
{  
    int a;   a = b;   exit(0);  
}  
  
int c;  
  
int g (int a)  
{  
    int b;   b = a + c;   f();  
}
```

Alle deklarasjoner er objekter av en subklasse av Declaration:

```
abstract class Declaration extends SyntaxUnit {  
    String name, assemblerName;  
    Type type;  
    boolean visible = false;  
    Declaration nextDecl = null;
```

Alle deklarasjoner står i en deklarasjonsliste:

```
abstract class DeclList extends SyntaxUnit {  
    Declaration firstDecl = null;  
    DeclList outerScope;
```

Alle variabler har en peker til sin deklarasjon, og den må vi sette nå. Det skjer i en funksjon check.

```
class Variable extends Operand {  
    String varName;  
    VarDecl declRef = null;  
    Expression index = null;
```

Det samme gjelder for funksjoner representert av et FunctionCall-objekt.

Lokale variabler

Det enkleste er å sjekke om et navn refererer til en lokal variabel:

```
int f ()  
{  
    int c;    int v;  
    c = 11;  v = c+1;  
    return v;  
}
```

Metoden `check` kan få med en parameter som peker til den lokale deklarasjonslisten.

Globale navn

Navn kan imidlertid være deklarerert «lenger ute». I C_b kan vi ha opptil fire nivåer:

```
int a;
```

```
int f (int b)
{
```

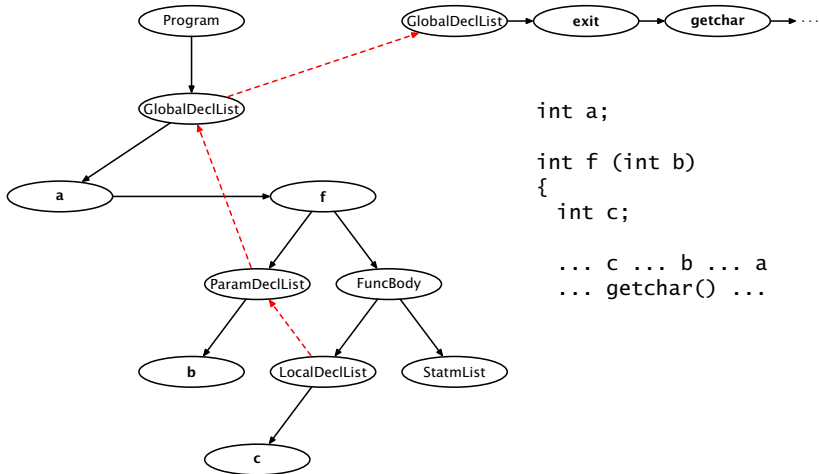
```
    int c;
```

```
    ... c ... b ... a ... getchar() ...
```

Hvordan finner globale navn?

Det enkleste er å la hvert DeclList-objekt ha en peker `outerScope` til sin nærmeste omliggende deklarasjonsliste.

Hvordan finne navn?



```

int a;

int f (int b)
{
  int c;

  ... c ... b ... a
  ... getchar() ...
}
  
```

Sjekk riktig bruk

```
abstract class Declaration extends SyntaxUnit {
    String name, assemblerName;
    Type type;
    boolean visible = false;
    Declaration nextDecl = null;

    abstract void checkWhetherArray(SyntaxUnit use);
    abstract void checkWhetherFunction(int nParamsUsed, SyntaxUnit use);
    abstract void checkWhetherSimpleVar(SyntaxUnit use);
}
```

For å sjekke at et navn er riktig brukt, kalles en `checkWhether...`-metode.

Eksempel

Vi har funnet uttrykket `a[2]` som er en `<variable>`. Navnet `a` må da være deklart som en `GlobalArrayDecl` eller `LocalArrayDecl`. Vi sjekker dette slik i metoden `Variable.check`:

- 1 Finn Declaration `fDecl`; ... `fDecl = ...`;
- 2 Kall `fDecl.checkWhetherArray(this)`;

Om `a` er galt deklart, skrives det ut en feilmelding og kompileringen stopper.

```
class GlobalArrayDecl extends VarDecl {
    :
    @Override void checkWhetherArray(SyntaxUnit use) {
        /* OK */
    }

    @Override void checkWhetherSimpleVar(SyntaxUnit use) {
        Syntax.error(use,
            name + " is an array and no simple variable!");
    }
}
```

checkWhetherFunction er felles for alle variabler:

```
abstract class VarDecl extends Declaration {
    :
    @Override void checkWhetherFunction(int nParams, SyntaxUnit use) {
        Syntax.error(use, name + " is a variable and no function!");
    }
}
```

Dobbeltdeklarasjoner

Det er lurt å ha en metode `addDecl` i `DeclList`:

```
abstract class DeclList extends SyntaxUnit {
    Declaration firstDecl = null;
    DeclList outerScope;

    void addDecl(Declaration d) {
        :
    }
}
```

Hint

Den enkleste måten å sjekke dobbeltdeklarasjoner på er å legge en test i `addDecl`.

Når kan vi se et navn?

Skjuling av navn

Som i de fleste språk vil en indre deklarasjon skjule en ytre.

```
int a;
int f (int a)
{
  int a;    ... a ...
}
```

Dette håndteres automatisk av vårt opplegg.

Når kan vi se et navn?

Deklarasjonsrekkefølgen

Husk at navn i C_b først er kjent *etter* at de er deklarerert.

```
int f1 ()  
{  
    outint(v);  
}  
  
int v;  
:
```

... så dette programmet skal gi feilmelding.

Hint

En variabel visible i Declaration gjør det enkelt å vite når en deklarasjon er blitt synlig.



Testutskrift med -logB

For å sjekke navnebindingen må check fortelle om alle bindinger som gjøres, hvis brukeren angir opsjonen -logB.

- Testutskriftene forteller om check har vært innom alle delene av programmet der navn kan forekomme.
- Testutskriftene forteller om navnebindingen har vært gjort korrekt.

Opsjonen -B

```

1  int a;   int b;
2
3  int f ()
4  {
5      int a;   a = b;   exit(0);
6  }
7
8  int c;
9
10 int g (int a)
11 {
12     int b;   b = a + c;   f();
13 }

```

Binding: Line 5: a refers to declaration in line 5
 Binding: Line 5: b refers to declaration in line 1
 Binding: Line 5: exit refers to declaration in the libr
 Binding: Line 12: b refers to declaration in line 12
 Binding: Line 12: a refers to declaration in line 10
 Binding: Line 12: c refers to declaration in line 8
 Binding: Line 12: f refers to declaration in line 3

Typesjekk

Kompilatoren må også sjekke at typereglerne følges.

- Alle deklarasjoner angir typen sin. (Funksjoner angir typen på returverdien.)
- Alle uttrykk og deluttrykk har en type:
 - Tallkonstanter er int.
 - Variabler har typen angitt i deklarasjonen.
 - Funksjonskall har funksjonens type (dvs typen til returverdien).
 - $a == b$ etc har typen int.
 - $a + b$ etc har typen til a og b .

Hva kan gå galt?

a==b a og b har ulik type.

a+b a og b har ulik type.

a[i] i er ikke int.

f(a) a har annen type enn i deklarasjonen av f.

return a; a har gal type som returverdi.

Hva kan ikke gå galt?

a = b kan ikke gi typefeil. (Kompilatoren vår vil automatiske generere kode for konvertering.)

Hva må sjekkes?

Noen nyttige funksjoner

```
abstract public class Type {
    abstract public int size();
    abstract public String typeName();

    abstract public void checkSameType(int lineNum, Type otherType, String what);
    abstract public void checkType(int lineNum, Type correctType, String what);
    public void genJumpIfZero(String jumpLabel) {}
}
```

```
abstract public class BasicType extends Type {
    @Override public void checkSameType(int lineNum, Type otherType, String what) {
        if (this != otherType)
            Error.error(lineNum,
                what + " should have the same type, not " + typeName() +
                " and " + otherType.typeName() + ".");
    }

    @Override public void checkType(int lineNum, Type correctType, String what) {
        if (this != correctType)
            Error.error(lineNum,
                what + " is " + typeName() +
                ", not " + correctType.typeName() + ".");
    }
}
```



Hvordan programmere sjekkingen?

Alle programelementer (dvs objekter av en subklasse av SyntaxUnit) har en check-metode med lokal deklarasjonsliste som parameter.

```
class WhileStatm extends Statement {
    Expression test = new Expression();
    StatmList body = new StatmList();

    @Override void check(DeclList curDecls) {
        test.check(curDecls);
        body.check(curDecls);
    }
}
```

Med disse kan vi traversere hele syntakstreet.

Hvordan programmere sjekkingen?

- På vei *nedover* i syntakstreet vil check
 - sørge for at alle navn koples til sin deklarasjon
 - sjekke at navnet er brukt riktig (vanlig variabel/array/funksjon)
 - sette `visible=true` (om aktuelt)
- På vei *oppover* vil den
 - sjekke typer
 - sette riktig type på «seg selv» (om aktuelt)

Et eksempel til

```
class Variable extends Operand {
    String varName;
    VarDecl declRef = null;
    Expression index = null;

    @Override void check(DeclList curDecls) {
        Declaration d = curDecls.findDecl(varName,this);
        if (index == null) {
            d.checkWhetherSimpleVar(this);
            valType = d.type;
        } else {
            d.checkWhetherArray(this);
            index.check(curDecls);
            index.valType.checkType(lineNum, Types.intType, "Array index");
            valType = ((ArrayType)d.type).elemType;
        }
        declRef = (VarDecl)d;
    }
}
```

Datamaskinenes historie



Menneskene har alltid prøvd å lage maskiner for å løse sine problemer.

Midt på 1800-tallet var det store problemet *tabeller* med feil.

Charles Babbage konstruerte på 1830-tallet sin *Difference Engine* som kunne lage tabeller automatisk ved å løse differensligninger. (Den ble først ferdig i 1991.)

Han arbeidet også med en *Analytical Engine* som skulle bli en generell beregningsmaskin.

The difference engine
på Science Museum i
London.



De første moderne datamaskiner

Problemet i 1930-årene var kanoner. Det er mulig å beregne en prosjektilbane, men det er mye arbeid for en matematiker.

U.S. Army Ordnance Department Ballistic Research Laboratory trengte data for dusinvis av nye kanoner.

Løsning

Lag *arbeidsbeskrivelse*, og la egne «beregnerne» gjøre jobben.

Tidlige datamaskiner

Fra en eldre utgave av *Webster's Dictionary*:

computer n, one that computes; *specif*: an automatic electronic machine for performing calculations



Problem

Hver bane tok opptil 20 timer å beregne (selv med elektrisk bordregnemaskin), og man trengte 2-4000 ulike baner for hver kanon.


Løsning

Lag en maskin som gjør dette automatisk.

Moore School of Electrical Engineering ved Universitetet i Pennsylvania gjorde det med penger fra *Ballistic Research Laboratory*. Resultatet ble **Eniac** som ble ferdig i 1945. Den kunne beregne en kulebane på drøyt 10 s.

Eniac målte
2½×1×30 m, veide
30 tonn og inneholdt
18 000 radorør.

Den var i drift til 1955.



Oppbyggingen av Eniac

Tanken var å kopiere en menneskelig beregner. Den har **Aritmetisk enhet** («ALU») tilsvarte regnemaskinen med de fire regneartene:

+ - × :

Regnemaskinen har et tall for videre beregning; datamaskinen har et **register**.

Minnet tilsvarte et ark med mellomresultater.

Datamaskinen kunne overføre innholdet av registeret til eller fra en celle i minnet.

Programmet tilsvarte beregnerens arbeidsbeskrivelse. Det skulle følges helt slavisk.

Programmet

Et program for datamaskinen inneholdt de samme elementene som beregnerens arbeidsbeskrivelse:

Aritmetiske operasjoner var mulig i de fire regneartene; svaret kom i registeret.

Mellomlagring av data skjedde ved at registeret ble kopiert til en angitt celle i minnet.



Hopp til en angitt instruksjon var nødvendig for å kunne gå i løkker.

Tester i forbindelse med hopp var typisk på om registeret var < 0 , $= 0$ eller > 0 .

Programmene ble etter hvert kodet som tall (mens Eniac ble kodet med kabler).

En moderne datamaskin


har grovt sett samme oppbygning den dag i dag.



x86-prosessoren

Denne prosessoren er den mest suksessrike gjennom tidene.

- Introdusert i 1978 med **8086**.
- Produseres fremdeles (som x86-64).
- Brukes i de fleste PC-er.



Minnet inneholder tre former for data:

- 1 **Data** inneholder globale variabler.
- 2 **Stakken** inneholder parametre.
- 3 **Koden** er programmet (dvs instruksjonene i numerisk form).

Prosessoren inneholder:

- 1 En regneenhet (kalt ALU = «Arithmetic Logic Unit») som kan
 - 1 utføre de fire regneartene (+, -, × og :)
 - 2 sammenligne to tall
 - 3 avgjøre om programmet skal hoppe
 - 4 flytte tall
- 2 Registre
 - %EAX, %ECX og %EDX benyttes til beregninger og sammenligninger. (%AL er en del av %EAX.)
 - %EBP («Extended Base Pointer») og %ESP («Extended Stack Pointer») peker på data i minnet.
- 3 En flyttallsenhet

Prosessoren

movl	$\langle v_1 \rangle, \langle v_2 \rangle$	Flytt $\langle v_1 \rangle$ til $\langle v_2 \rangle$.
cdq		Omform 32-bits %EAX til 64-bits %EDX:%EAX.
leal	$\langle v_1 \rangle, \langle v_2 \rangle$	Flytt <i>adressen</i> til $\langle v_1 \rangle$ til $\langle v_2 \rangle$.
pushl	$\langle v \rangle$	Legg $\langle v \rangle$ på stakken.
popl	$\langle v \rangle$	Fjern toppen av stakken og legg verdien i $\langle v \rangle$.
addl	$\langle v_1 \rangle, \langle v_2 \rangle$	Addér $\langle v_1 \rangle$ til $\langle v_2 \rangle$.
subl	$\langle v_1 \rangle, \langle v_2 \rangle$	Subtraher $\langle v_1 \rangle$ fra $\langle v_2 \rangle$.
imull	$\langle v_1 \rangle, \langle v_2 \rangle$	Multipliser $\langle v_1 \rangle$ med $\langle v_2 \rangle$.
idivl	$\langle v \rangle$	Del %EDX:%EAX med $\langle v \rangle$; svar i %EAX.
call	$\langle lab \rangle$	Kall funksjonen i $\langle lab \rangle$.
ret		Returner fra funksjonen.
cmpl	$\langle v_1 \rangle, \langle v_2 \rangle$	Sammenligning $\langle v_1 \rangle$ og $\langle v_2 \rangle$.
jmp	$\langle lab \rangle$	Hopp til $\langle lab \rangle$.
sete	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om $=$, ellers $\langle v \rangle = 0$.
setne	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om \neq , ellers $\langle v \rangle = 0$.
setl	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om $<$, ellers $\langle v \rangle = 0$.
setle	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om \leq , ellers $\langle v \rangle = 0$.
setg	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om $>$, ellers $\langle v \rangle = 0$.
setge	$\langle v \rangle$	Sett $\langle v \rangle = 1$ om \geq , ellers $\langle v \rangle = 0$.



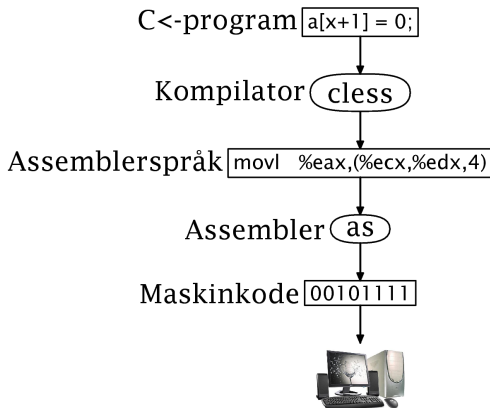
Formålet

Vårt oppdrag er å lage en kompilator:

Inndata er

trerepresentasjonen av C-programmet laget i del 1.

Utdata er en fil med x86 assemblerkode.



Maskinkode

Dette er den *numeriske representasjonen* av instruksjonene; vi skal ikke benytte den i dette kurset.

Assemblerkode

Dette er den *tekstlige representasjonen* av instruksjonene.

$\underbrace{\text{func:}}_{\text{Navnelapp}} \quad \underbrace{\text{movl}}_{\text{Instruksjon}} \quad \underbrace{\text{\$0,\%eax}}_{\text{Parametre}} \quad \underbrace{\text{\# Initier til 0.}}_{\text{Kommentar}}$

Noen eksempler

```

.text
Start:  movl    $17,%eax    # Legg verdien 17 i %EAX
        movl    $-2,%edx   # Legg verdien -2 i %EDX
        addl    %edx,%eax  # Addér %EDX til %EAX
        jmp     Start     # Hopp til Start
  
```

NB! Direktivet **.text** forteller at vi skal legge instruksjonene i kodelageret. (Dette er standard.)

Et eksempel

```

int v;

int main ()
{
    v = 65;
    putchar(v+1);
    putchar(10);
}

        .data
        .tmp: .fill 4 # Temporary storage
        .globl v
        v: .fill 4 # int v;
        .text
        .globl main
main:    pushl %ebp # Start function main
        movl %esp,%ebp
        movl $65,%eax # 65
        movl %eax,v # v =
        movl v,%eax # v
        pushl %eax
        movl $1,%eax # 1
        movl %eax,%ecx
        popl %eax
        addl %ecx,%eax # Compute +
        pushl %eax # Push parameter #1
        call putchar # Call putchar
        addl $4,%esp # Remove parameters
        movl $10,%eax # 10
        pushl %eax # Push parameter #1
        call putchar # Call putchar
        addl $4,%esp # Remove parameters
        .exit$main:
        movl %ebp,%esp
        popl %ebp
        ret # End function main

```



Modulen code

```
package no.uio.ifi.cflat.code;

import java.io.*;
import no.uio.ifi.cflat.cflat.Cflat;
import no.uio.ifi.cflat.error.Error;
import no.uio.ifi.cflat.log.Log;

public class Code {
    private static PrintWriter codeFile;
    private static boolean generatingData = false;

    public static final String tmpLabel = ".tmp";
```

Modulen 'code'

```
public static void init() {
    String codeFileName;

    if (Cflat.sourceBaseName == null) return;
    codeFileName = Cflat.sourceBaseName + ".s";
    try {
        codeFile = new PrintWriter(codeFileName);
    } catch (FileNotFoundException e) {
        Error.error("Cannot create code file " + codeFileName + "!");
    }

    genVar(tmpLabel, false, 4, "Temporary storage");
}

public static void finish() {
    codeFile.close();
}
```



Modulen 'code'

```

private static void printLabel(String lab, boolean justALabel) {
    if (lab.length() > 6) {
        codeFile.print(lab + ":");
        if (! justALabel) codeFile.print("\n      ");
    } else if (lab.length() > 0) {
        codeFile.printf("%-8s", lab+":");
    } else {
        codeFile.print("      ");
    }
}

public static void genInstr(String lab, String instr,
                           String arg, String comment) {
    if (generatingData) {
        codeFile.println("      .text");
        generatingData = false;
    }

    printLabel(lab, (instr+arg+comment).equals(""));
    codeFile.printf("%-7s %-23s ", instr, arg);
    if (comment.length() > 0) {
        codeFile.print("# " + comment);
    }
    codeFile.println();
}

```



Lag riktig kode!

Oppsummering

Det finnes mange mulige kodebiter som gjør det samme. I kompendiet står angitt ganske nøyaktig hvilke som skal brukes.

NB!

Det er viktigere at koden er riktig enn at den er rask!