Kódoptimalizálás

Az optimalizáció helye a fordítóprogramokban

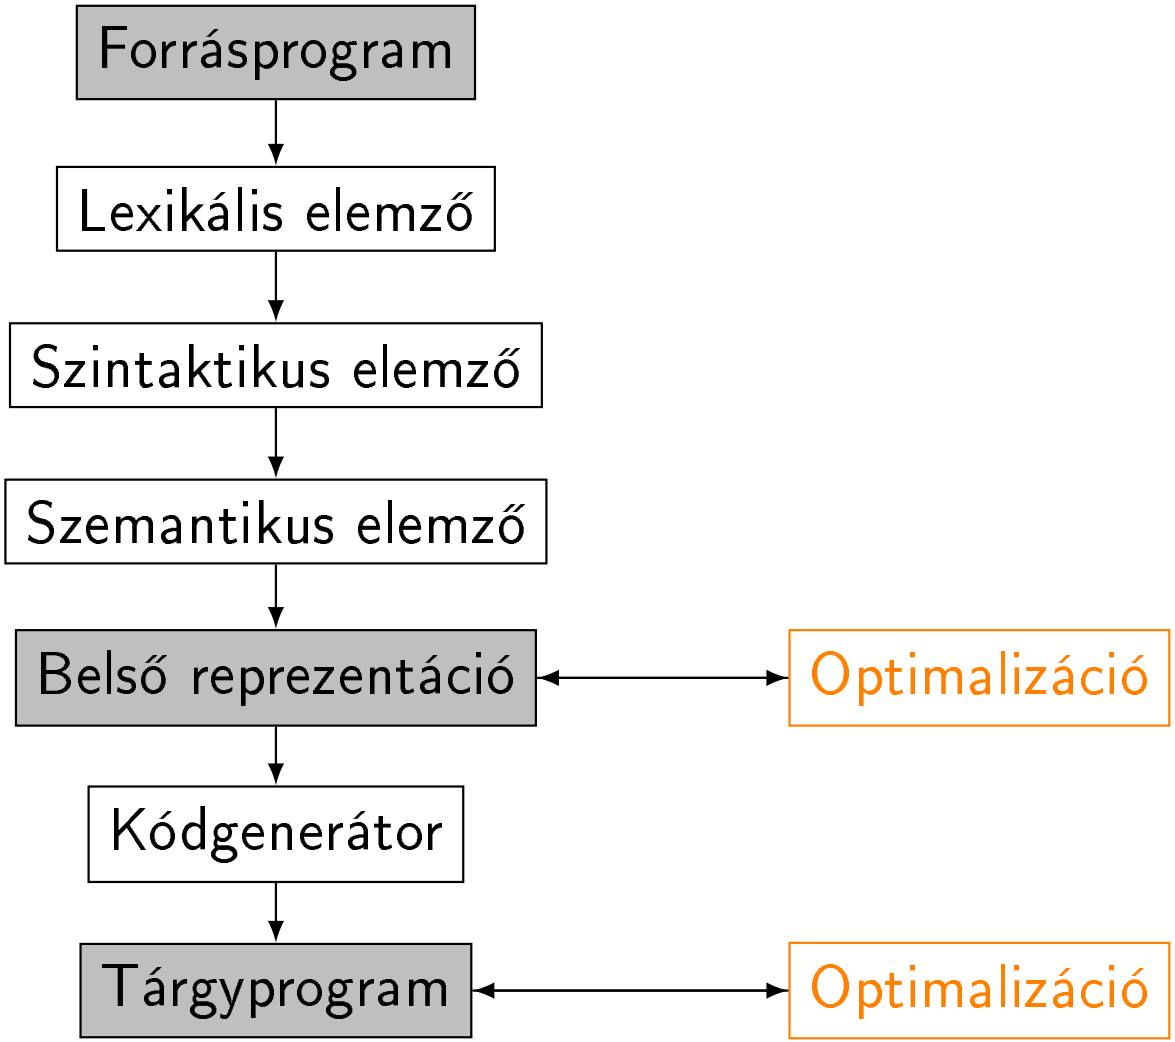

A kódoptimalizálás célja

- Hatékonyabb program létrehozása:
  - nagyobb sebesség
  - kisebb méret
- Ezek a célok időnként ellentmondanak egymásnak!

Követelmény a kódoptimalizálással szemben

- „Az optimalizált programnak ugyanúgy kell működnie, mint az eredetinek.” - Ez sok mindent jelenthet!
  - ugyanarra a bemenetre ugyanazt a kimenetet adja?
  - eseményvezérelt környezetben ugyanúgy viselkedik?
  - párhuzamos környezetben ugyanúgy viselkedik?
  - stb.
- Az adott nyelv szemantikája (jelentése) dönti el, hogy egy optimalizálási lépés megengedhető-e.

Kódoptimalizálási lépések osztályozása

- Mit optimalizálunk?
  - az eredeti programot (vagy annak egyszerűsített változatát): itt még vannak ciklusok, elágazások, kifejezéskiértékelés stb.
  - a tárgyprogramot: jellemzően assembly kódot
- Mi az átalakítás hatóköre?
  - lokális: kis programrészletek átalakítása
  - globális: a teljes program szerkezetét kell vizsgálni
- Mit használ ki az átalakítás?
  - általános optimalizálási stratégiák: algoritmusok javítása
  - gépfüggő optimalizálás: az adott architektúra sajátosságait használja ki

Lokális optimalizálás: alapblokk fogalma

Definíció: alapblokk

Egy programban egymást követő utasítások sorozatát alapblokknak nevezzük, ha

- az első utasítás kivételével egyik utasítására sem lehet távolról átadni a vezérlést

  (assembly programokban: ahová a `jmp`, `call`, `ret` utasítások „ugranak”; magas szintű nyelvekben: eljárások, ciklusok eleje, elágazások ágainak első utasítása, *goto* utasítások célpontjai)

- az utolsó utasítás kivételével nincs benne vezérlés-átadó utasítás

  (assembly programban: `jmp`, `call`, `ret`
  magas szintű nyelvekben: elágazás vége, ciklus vége, eljárás vége, goto)

- az utasítás-sorozat nem bővíthető a fenti két szabály megsértése nélkül

Alapblokk szerepe az optimalizálásban

- A definíció következményei:
  - egy alapblokknak pontosan egy belépési pontja van (az első utasítás)
  - az utasításai szekvenciálisan hajtódnak végre
  - ha rá kerül a vezérlés, akkor az összes utasítása pontosan egyszer hajtódik végre
- Lokális optimalizálás: egy alapblokkon belüli átalakítások

Alapblokkok meghatározása

- Jelöljük meg:
  - a program első utasítását
  - azokat az utasításokat, amelyekre távolról át lehet adni a vezérlést
  - a vezérlés-átadó utasításokat követő utasításokat
- Minden megjelölt utasításhoz tartozik egy alapblokk, ami a következő megjelölt utasításig (vagy az utolsó utasításig) tart.

Alapblokkok: példa

```
main: mov eax,[Cimke1]
      cmp eax,[Cimke2]
      jz igaz
      dec dword [Cimke1]
      inc dword [Cimke2]
      jmp vege
igaz: inc dword [Cimke1]
      dec dword [Cimke2]
vege: ret
```

Tömörítés

- Cél: minél kevesebb konstans és konstans értékű változó legyen!
- *konstansok összevonása:* a fordítási időben kiértékelhető kifejezések kiszámítása

Eredeti kód

```
a := 1 + b + 3 + 4;
```

Optimalizált kód

```
a := 8 + b;
```

- *konstans továbbterjesztése:* a fordítási időben kiszámítható értékű változók helyettesítése az értékükkel

Eredeti kód

```
a := 6;
b := a / 2;
c := b + 5;
```

Optimalizált kód

```
a := 6;
b := 3;
c := 8;
```

Azonos kifejezések többszöri kiszámításának elkerülése

Eredeti kód

```
x := 20 - (a * b);
y := (a * b) ^ 2;
```

Optimalizált kód

```
t := a * b;
x := 20 - t;
y := t ^ 2;
```

- Ez csak látszólag növeli a program méretét!
  - az `a*b` kifejezés kiértékelése is több assembly utasítás
  - a `t` változó lehet egy regiszter is
- Megvalósítás a gyakorlatban:
  - az utasításokból egy címkézett, irányított körmentes gráfot építünk,
  - ebből generálható az optimalizált kód

Változó továbbterjesztése

Eredeti kód

```
x := a + b;
y := x;
z := y;
```

Optimalizált kód

```
x := a + b;
y := x;
z := x;
```

- Ha az `y` változóra a továbbiakban már nincs szükség, akkor `y := x` törölhető!
  (De ez a törlés már globális optimalizálás...)
- Ez is megoldható az előzőleg említett gráfos módszerrel.

Ablakoptimalizálás

- Ez egy módszer a lokális optimalizálás egyes fajtáihoz.
- Ablak:
  - egyszerre csak egy néhány utasításnyi részt vizsgálunk a kódból
  - a vizsgált részt előre megadott mintákkal hasonlítjuk össze
  - ha illeszkedik, akkor a mintához megadott szabály szerint átalakítjuk
  - ezt az „ablakot” végigcsúsztatjuk a programon
- Az átalakítások megadása:
  - $\{minta \rightarrow helyettesítés\}$ szabályhalmazzal
  - a mintában lehet paramétereket is használni

Ablakoptimalizálás: példa

- ablak mérete: 1 utasítás
- szabályhalmaz:
  {`mov` *reg*`,0` $\rightarrow$ `xor` *reg,reg*
  `add` *reg*`,0` $\rightarrow$; *elhagyható*}

Eredeti kód

```
add eax,0
mov ebx,eax
mov ecx,0
```

Optimalizált kód

Ablakoptimalizálás: példa

- ablak mérete: 1 utasítás
- szabályhalmaz:
  {`mov` *reg*`,0` $\rightarrow$ `xor` *reg*`,`*reg*
  `add` *reg*`,0` $\rightarrow$; *elhagyható*}

Eredeti kód

```
add eax,0
mov ebx,eax
mov ecx,0
```

Optimalizált kód

```
; elhagyott utasítás
```

Ablakoptimalizálás: példa

- ablak mérete: 1 utasítás
- szabályhalmaz:
  {`mov` *reg*`,0` $\rightarrow$ `xor` *reg,reg*
  `add` *reg*`,0` $\rightarrow$ `;` *elhagyható*}

Eredeti kód

```
add eax,0
mov ebx,eax
mov ecx,0
```

Optimalizált kód

```
; elhagyott utasítás
mov ebx,eax
```

Ablakoptimalizálás: példa

- ablak mérete: 1 utasítás
- szabályhalmaz:
  {`mov` *reg*`,0` → `xor` *reg*`,`*reg*
  `add` *reg*`,0` → ; *elhagyható*}

Eredeti kód

```
add eax,0
mov ebx,eax
mov ecx,0
```

Optimalizált kód

```
; elhagyott utasítás
mov ebx,eax
xor ecx,ecx
```

Tipikus egyszerűsítések ablakoptimalizáláshoz

- felesleges műveletek törlése: nulla hozzáadása vagy kivonása
- egyszerűsítések: nullával szorzás helyett a regiszter törlése
- nulla mozgatása helyett a regiszter törlése
- regiszterbe töltés és ugyanoda visszaírás esetén a visszaírás elhagyható
- utasításismétlések törlése: ha lehetséges, az ismétlések törlése

Globális optimalizálás

- a teljes program szerkezetét meg kell vizsgálni
- vezérlésfolyam-gráf:
  - Adott alapblok után mely alapblokkok következhetnek?
- adatáram-analízis:
  - Mely változók értékeit számolja ki egy adott alapblokk?
  - Mely változók értékeit melyik alapblokk használja fel?
- lehetővé teszi:
  - az azonos kifejezések többszöri kiszámításának kiküszöbölését akkor is, ha különböző alapblokkokban szerepelnek
  - konstansok és változók továbbterjesztését alapblokkok között is
  - elágazások, ciklusok optimalizálását

Kódkiemelés

Eredeti kód

```
if( x < 10 )
{
  a = 0;
  b++;
}
else
{
  b--;
  a = 0;
}
```

Optimalizált kód

```
a = 0;
if( x < 10 )
{
  b++;
}
else
{
  b--;
}
```

Kódsüllyesztés

Eredeti kód

```
if( x < 10 )
{
  x = 0;
  b++;
}
else
{
  b--;
  x = 0;
}
```

Optimalizált kód

```
if( x < 10 )
{
  b++;
}
else
{
  b--;
}
x = 0;
```

Mi lenne, ha itt *kódkiemelést* alkalmaznánk?

Ciklusok kifejtése

Eredeti kód

```
for( int i=0; i<4; ++i )
{
  a += t[i];
}
```

Optimalizált kód

```
a += t[0];
a += t[1];
a += t[2];
a += t[3];
```

Mérlegelni kell, hogy a méret és a sebesség mennyire fontos...

Parciális kifejtés

Eredeti kód

```
for( int i=0; i<4; ++i )
{
  a += t[i];
}
```

Optimalizált kód

```
for( int i=0; i<4; i+=2 )
{
  a += t[i];
  a += t[i+1];
}
```

Ciklusok összevonása

Eredeti kód

```
for( int i=0; i<4; ++i )
{
  t1[i] = 0;
}
for( int i=0; i<4; ++i )
{
  t2[i] = 1;
}
```

Optimalizált kód

```
for( int i=0; i<4; i++ )
{
  t1[i] = 0;
  t2[i] = 1;
}
```

Frekvenciaredukálás

- költséges utasítások „átköltöztetése” ritkábban végrehajtódó alapblokkba
- példa:
  - ciklusinvariánsnak nevezzük azokat a kifejezéseket, amelyeknek a ciklus minden lefutásakor azonos az értékük
  - a ciklusinvariánsok (esetenként) kiemelhetők a ciklusból

Eredeti kód

```
cin >> a;
cin >> h;
while( h > 0 )
{
  cout << h*h*sin(a);
  cin >> h;
}
```

Optimalizált kód

```
cin >> a;
cin >> h;
double s = sin(a);
while( h > 0 )
{
  cout << h*h*s;
  cin >> h;
}
```

Erős redukció

- a ciklusban lévő költséges művelet (legtöbbször szorzás) kiváltása kevésbé költségessel

Eredeti kód

```
for( int i=a; i<b; i+=c )
{
  cout << 3*i;
}
```

Optimalizált kód

```
int t1 = 3*a;
int t2 = 3*c;
for( int i=a; i<b; i+=c )
{
  cout << t1;
  t1 += t2;
}
```