Lic. Ciências da Computação

1º ano

2007/08

A.J.Proença

Tema

Avaliação de Desempenho (IA32)

Estrutura do tema Avaliação de Desempenho (IA32)

1. A avaliação de sistemas de computação
2. Técnicas de optimização de código (IM)
3. Técnicas de optimização de *hardware*
4. Técnicas de optimização de código (DM)
5. Outras técnicas de optimização
6. Medição de tempos

"*Análise do desempenho*": para quê?

- **para avaliar Sistemas de Computação**
  - identificação de métricas
    - latência, velocidade, ...
  - ligação entre métricas e factores na arquitectura que influenciam o desempenho

$$CPU_{Time} = N^{o}_{instr} * CPI * T_{clock}$$

e . . .

- **. . . construi-los mais rápidos**
- **. . . melhorar o desempenho das aplicações**

Análise dos componentes da fórmula:

- **CPU_{Time}**
  - inclui tempo de execução no CPU, acessos à mem, ...
- **N^{o}_{instr}**
  - efectivamente executadas; depende essencial/ de:
    - eficiência do compilador
    - do *instruction set*
- **CPI (*Clock-cycles Per Instruction*)**
  - tempo médio de exec de 1 instr, em ciclos; depende essencial/:
    - complexidade da instrução (e acessos à memória ...)
    - paralelismo na execução da instrução
- **T_{clock}**
  - período do *clock*; depende essencial/ de:
    - complexidade da instrução (ao nível dos sistemas digitais)
    - microelectrónica

"*Análise do desempenho*": para quê?

– **. . . melhorar o desempenho das aplicações**

- análise de técnicas de optimização
  - algoritmo / **codificação / compilação** / *assembly*
  - compromisso entre legibilidade e eficiência...
  - potencialidades e limitações dos compiladores...
  - técnicas independentes / dependentes da máquina
  - uso de *code profilers*
- técnicas de medição de tempos
  - escala microscópica / macroscópica
  - uso de *cycle counters* / *interval counting*

– **um compilador moderno já inclui técnicas que**

- explora oportunidades para simplificar expressões
- usa um único cálculo de expr em vários locais
- reduz o nº de vezes um cálculo é efectuado
- tiram partido de algoritmos sofisticados para
  - alocação eficiente dos registos
  - selecção e ordenação de código
- ... **mas** está limitado por factores, incluindo
  - nunca modificar o comportamento correcto do programa
  - limitado conhecimento do programa e seu contexto
  - necessidade de ser rápido!

– **certas optimizações estão-lhe vedadas...**

– **certas optimizações estão vedadas aos compiladores:**

- pode trocar **`twiddle1`** por **`twiddle2`** ?

```
void twiddle1(int *xp,int *yp)
{
  *xp += *yp;
  *xp += *yp;
}
```

```
void twiddle2(int *xp,int *yp)
{
  *xp += 2* *yp;
}
```

teste: **`xp`** igual a **`yp`**; que acontece?

- pode trocar **`func1`** por **`func2`** ?

```
int f(int n)
int func1 (x)
{
  return f(x)+f(x)+f(x)+f(x);
}
```

```
int f(int n)
int func2 (x)
{
  return 4*f(x);
}
```

teste: e se **`f`** for...?

```
int counter = 0;

int f(int x)
{
  return counter++;
}
```


Estrutura do tema Avaliação de Desempenho (IA32)

1. A avaliação de sistemas de computação
2. Técnicas de optimização de código (IM)
3. Técnicas de optimização de *hardware*
4. Técnicas de optimização de código (DM)
5. Outras técnicas de optimização
6. Medição de tempos

"Independentes da máquina": aplicam-se a qualquer processador / compilador

Algumas técnicas de optimização:

- movimentação de código
  - reduzir frequência de execução (compiladores têm limitações)
- simplificação de cálculos
  - substituir operações por outras mais simples
- partilha de cálculos
  - identificar e explicitar sub-expressões comuns

Metodologia a seguir:

- apresentação de alguns conceitos
- análise de um programa exemplo a optimizar
- introdução de uma técnica de medição de desempenho

- **Movimentação de código**
  - Reduzir a frequência da realização de cálculos
    - se produzir sempre o mesmo resultado
    - especialmente retirar código do interior de ciclos

```
for (i = 0; i < n; i++)
  for (j = 0; j < n; j++)
    a[n*i + j] = b[j];
```

→

```
for (i = 0; i < n; i++) {
  int ni = n*i;
  for (j = 0; j < n; j++)
    a[ni + j] = b[j];
}
```


- A maioria dos compiladores é eficiente a lidar com código com *arrays* e estruturas simples com ciclos
- **Código gerado pelo GCC:**

```
for (i = 0; i < n; i++)
  for (j = 0; j < n; j++)
    a[n*i + j] = b[j];
```

→

```
for (i = 0; i < n; i++) {
  int ni = n*i;
  int *p = a+ni;
  for (j = 0; j < n; j++)
    *p++ = b[j];
}
```

```
  imull %ebx,%eax          # i*n
  movl  8(%ebp),%edi       # a
  leal  (%edi,%eax,4),%edx # p = a+i*n (ajustado 4*)
.L40:                      # Ciclo interior
  movl  12(%ebp),%edi      # b
  movl  (%edi,%ecx,4),%eax # b+j (ajustado 4*)
  movl  %eax,(%edx)        # *p = b[j]
  addl  $4,%edx            # p++ (ajustado 4*)
  incl  %ecx               # j++
  jl    .L40               # loop if j<n
```


- **Substituir operações "caras" por outras +simples**
  - **`shift`** ou **`add`** em vez de **`mul`** ou **`div`**
    - **`16*x`** → **`x<<4`**
    - escolha pode ser dependente da máquina
  - reconhecer sequência de produtos

```
for (i = 0; i < n; i++)
  for (j = 0; j < n; j++)
    a[n*i + j] = b[j];
```

→

```
int ni = 0;
for (i = 0; i < n; i++) {
  for (j = 0; j < n; j++)
    a[ni + j] = b[j];
  ni += n;
}
```

- **Partilhar sub-expressões comuns**
  - reutilizar partes de expressões
  - compiladores não são particularmente famosos a explorar propriedades aritméticas

```
/* Soma vizinhos de i,j */
up =    val[(i-1)*n + j];
down =  val[(i+1)*n + j];
left =  val[i*n   + j-1];
right = val[i*n   + j+1];
sum = up + down + left + right;
```

3 multiplicações: i*n, (i–1)*n, (i+1)*n

```
int inj = i*n + j;
up =    val[inj - n];
down =  val[inj + n];
left =  val[inj - 1];
right = val[inj + 1];
sum = up + down + left + right;
```

1 multiplicação: i*n

```
  leal -1(%edx),%ecx   # i-1
  imull %ebx,%ecx      # (i-1)*n
  leal 1(%edx),%eax    # i+1
  imull %ebx,%eax      # (i+1)*n
  imull %ebx,%edx      # i*n
```


O vector ADT:

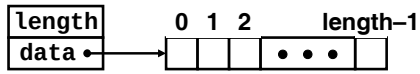

- **Procedimentos associados**

  `vec_ptr new_vec(int len)`
  - cria vector de comprimento especificado

  `int get_vec_element(vec_ptr v, int index, int *dest)`
  - recolhe um elemento do vector e guarda-o em *dest
  - devolve 0 se fora de limites, 1 se obtido com sucesso

  `int *get_vec_start(vec_ptr v)`
  - devolve apontador para início dos dados do vector

- Idêntico às implementações de *arrays* em Pascal, ML, Java
  - **i.e., faz sempre verificação de limites (*bounds*)**


```
void combine1(vec_ptr v, int *dest)
{
  int i;
  *dest = 0;
  for (i = 0; i < vec_length(v); i++) {
    int val;
    get_vec_element(v, i, &val);
    *dest += val;
  }
}
```

- **Procedimento**
  - calcula a soma de todos os elementos do vector
  - guarda o resultado numa localização destino
  - estrutura e operações do vector definidos via ADT
- **Tempos de execução: que/como medir?**


```
void combine1(vec_ptr v, int *dest)
{
  int i;
  *dest = 0;
  for (i = 0; i < vec_length(v); i++) {
    int val;
    get_vec_element(v, i, &val);
    *dest += val;
  }
}
```

Tempos de execução: que/como medir?

- **que medir**: em programas iterativos (com ciclos), uma medida útil é a duração da operação para cada um dos elementos da iteração:
  - **ciclos** (de *clock*) **por elemento, CPE**
- **como medi-lo**: efectuar várias medições de tempo para dimensões variáveis de ciclos, e calculá-lo através do traçado gráfico: o declive da recta *best fit*, obtida pelo método dos mínimos quadrados:
  - análise gráfica de um exemplo...

Análise detalhada de um exemplo: tempos de execução (2)

```
void vsum1(int n)
{
  int i;
  for (i=0; i<n; i++)
     c[i] = a[i] + b[i];
}
```

```
void vsum2(int n)
{
  int i;
  for (i=0; i<n; i+=2){
     c[i]  = a[i]  + b[i];
     c[i+1]= a[i+1]+ b[i+1];
  }
}
```


Análise detalhada de um exemplo: tempos de execução (3)

```
void vsum1(int n)
{
  int
  for
}
```

```
void vsum2(int n)
{
                    [i];
                    [i+1];
```

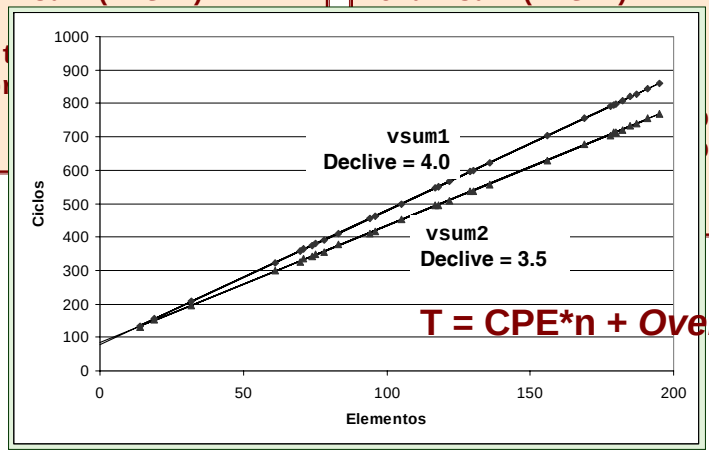

T = CPE*n + *Overhead*

Análise detalhada de um exemplo: o procedimento a optimizar (2)

```
void combine1(vec_ptr v, int *dest)
{
  int i;
  *dest = 0;
  for (i = 0; i < vec_length(v); i++) {
    int val;
    get_vec_element(v, i, &val);
    *dest += val;
  }
}
```

- **Procedimento**
  - calcula a soma de todos os elementos do vector
  - guarda o resultado numa localização destino
  - estrutura e operações do vector definidos via ADT
- **Tempo de execução** (inteiros) **:**
  - compilado sem qq optimização: 42.06 CPE
  - compilado com **-02**: 31.25 CPE

Análise detalhada do exemplo: à procura de ineficiências...

Versão goto

```
void combine1-goto(vec_ptr v, int *dest)
{
    int i = 0;
    int val;
    *dest = 0;
    if (i >= vec_length(v))  goto done;
  loop:
    get_vec_element(v, i, &val);
    *dest += val;
    i++;
    if (i < vec_length(v))
      goto loop
  done:
}
```

1 iteração

Ineficiência óbvia:

- função **vec_length** invocada em cada iteração
- … mesmo sendo para calcular o mesmo valor!

Optimização 1:

- mover invocação de **`vec_length`** para fora do ciclo interior
  - o valor não altera de iteração para iteração
- **CPE:** de 31.25 para **20.66** (compilado com **`-O2`**)
  - `vec_length` impõe um *overhead* constante, mas significativo

```
void combine2(vec_ptr v, int *dest)
{
  int i;
  int length = vec_length(v);
  *dest = 0;
  for (i = 0; i < length; i++) {
    int val;
    get_vec_element(v, i, &val);
    *dest += val;
  }
}
```


Por que razão o compilador não moveu `vec_len` para for a do ciclo?

- a função pode ter efeitos colaterais
  - altera o estado global de cada vez que é invocada
- a função poderá não devolver os mesmos valores consoante o arg
  - depende de outras partes do estado global

Por que razão o compilador não analisou o código de `vec_len`?

- optimização interprocedimental não é usada extensivamente devido ao seu elevado custo

Warning:

- o compilador trata invocação de procedimentos como uma *black box*
- as optimizações são pobres em redor de invoc de procedimentos

Optimização 2:

- evitar invocação de **`get_vec_element`** para ir buscar cada elemento do vector
  - obter apontador para início do *array* antes do ciclo
  - dentro do ciclo trabalhar apenas com o apontador
- **CPE:** de 20.66 para **6.00** (compilado com **`-O2`**)
  - invocação de funções é dispendioso
  - validação de limites de *arrays* é dispendioso

```
void combine3(vec_ptr v, int *dest)
{
  int i;
  int length = vec_length(v);
  int *data = get_vec_start(v);
  *dest = 0;
  for (i = 0; i < length; i++) {
    *dest += data[i];
  }
}
```


Optimização 3:

- não é preciso guardar resultado no dest a meio dos cálculos
  - a variável local `sum` é alocada a um registo
  - poupa 2 acessos à mem por ciclo (1 leitura + 1 escrita)
- **CPE:** de 6.00 para **2.00** (compilado com **`-O2`**)
  - acessos à mem são dispendiosos

```
void combine4(vec_ptr v, int *dest)
{
  int i;
  int length = vec_length(v);
  int *data = get_vec_start(v);
  int sum = 0;
  for (i = 0; i < length; i++)
    sum += data[i];
  *dest = sum;
}
```

Combine3

```
.L18:
        movl (%ecx,%edx,4),%eax
        addl %eax, (%edi)
        incl %edx
        cmpl %esi,%edx
        jl .L18
```

Combine4

```
.L24:
        addl (%eax,%edx,4),%ecx

        incl %edx
        cmpl %esi,%edx
        jl .L24
```

Desempenho comparativo

- Combine3
  - 5 instruções em 6 ciclos de *clock*
  - `addl` tem de ler **e** escrever na memória
- Combine4
  - 4 instruções em 2 ciclos de *clock*

- ***Aliasing***
  - 2 referências distintas à memória especificam a mesma localização
- **Example**
  - `v: [3, 2, 17]`
  - `combine3(v, get_vec_start(v)+2)  --> ?`
  - `combine4(v, get_vec_start(v)+2)  --> ?`
- **Observações**
  - fácil de acontecer em C, por permitir
    - operações aritméticas com endereços
    - acesso directo a valores armazenados de *structures*
  - criar o hábito de usar variáveis locais
    - para acumular resultados dentro de ciclos
    - como forma de avisar o compilador para não se preocupar com *aliasing*


```
void abstract_combine4(vec_ptr v, data_t *dest)
{
  int i;
  int length = vec_length(v);
  data_t *data = get_vec_start(v);
  data_t t = IDENT;
  for (i = 0; i < length; i++)
    t = t OP data[i];
  *dest = t;
}
```

Tipos de dados

- Usar declarações distintas para `data_t`
  - `int`
  - `float`
  - `double`

Operações

- Usar definições diferentes para `OP` e `IDENT`
  - `+ / 0`
  - `* / 1`

Optimizações

- reduzir invocação func e acessos à mem dentro do ciclo

Método	Inteiro		Real (prec simp)	
	+	*	+	*
Abstract `-g`	42.06	41.86	41.44	160.00
Abstract `-O2`	31.25	33.25	31.25	143.00
Move `vec_length`	20.66	21.25	21.15	135.00
Acesso aos dados	6.00	9.00	8.00	117.00
Acum. em temp	2.00	4.00	3.00	5.00

- Anomalia no desempenho
  - cálculos de produtos de FP excepcional/ lento com todos
  - aceleração considerável qdo. acumulou em temp
  - causa: unidade de FP do IA32
    - mem usa formato com 64-bit, registo usa 80
    - os dados causaram *overflow* com 64 bits, mas não com 80