

Lic. Eng<sup>a</sup> Informática

1º ano

2011/12

A.J.Proen  a

### Tema

## Avaliação de Desempenho (IA-32)

## Estrutura do tema Avaliação de Desempenho (IA-32)

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

### Análise do desempenho na execução de aplicações (1)

$$\text{Core}_{\text{time}} = \text{N}^{\circ}_{\text{instr}} * \text{CPI} * \text{T}_{\text{clock}}$$

### "Análise do desempenho": para quê?

#### – para avaliar Sistemas de Computação

- identificação de métricas
  - lat  encia, velocidade, ...
- ligação entre métricas e fatores na arquitectura que influenciam o desempenho de um n  cleo

$$\text{Core}_{\text{time}} = \text{N}^{\circ}_{\text{instr}} * \text{CPI} * \text{T}_{\text{clock}}$$

e ...

#### – ... construi-los mais r  pidos

#### – ... melhorar a efici  ncia de execu  o de applic

### Análise dos componentes da f  rmula:

- **Core<sub>time</sub>**
  - inclui tempo de execu  o no CPU, acessos    mem  ria, ...
- **N<sup>o</sup>instr**
  - efectivamente executadas; depende essencialmente de:
    - efici  ncia do compilador
    - do instruction set
- **CPI (Clock-cycles Per Instruction)**
  - tempo m  dio de exec de 1 instr, em ciclos; depende essencial/
    - complexidade da instru  o (e acessos    mem  ria ...)
    - paralelismo na execu  o da instru  o
- **T<sub>clock</sub>**
  - per  odo do clock; depende essencialmente de:
    - complexidade da instru  o (ao n  vel dos sistemas digitais)
    - micro-electr  nica

## "Análise do desempenho": para quê?

### – ... melhorar a eficiência de execução de aplic.

- análise de técnicas de otimização
  - 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 expressão em vários locais
- reduz o nº de vezes um cálculo é efetuado
- tira partido de algoritmos sofisticados para
  - alocação eficiente dos registos
  - selecção e ordenação de código
- ... mas está limitado por fatores, incluindo
  - nunca modificar o comportamento correto do programa
  - limitado conhecimento do programa e seu contexto
  - necessidade de ser rápido!

### – certas otimizações estão-lhe vedadas...

- ### – certas otimizações estão vedadas aos compiladores; ex.:
- 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...?

## Estrutura do tema Avaliação de Desempenho (IA-32)

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

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

#### Algumas técnicas de otimização:

- 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 subexpressões comuns

#### Metodologia a seguir:

- apresentação de alguns conceitos
- análise de um programa exemplo a otimizar
- 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
  - $16*x \rightarrow x<<4$
  - 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:  $i^2n$ ,  $(i-1)^2n$ ,  $(i+1)^2n$

```
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:  $i^2n$

```
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
```

### Análise detalhada de um exemplo: o procedimento a otimizar (1)

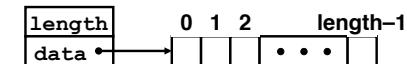
```
void combine1(vec_ptr v, int *dest)
{
    int i;
    *dest = 0;
    for (i = 0; i < vec_length(v); i++) {
        int val;
        get_vec_element(v, i, &val);
        *dest += val;
    }
}
```

#### Procedimento

- calcula a soma de todos os elementos do vector
- guarda o resultado numa localização destino
- estrutura e operações do vetor definidos via ADT

#### Tempos de execução: que/como medir?

### O vetor ADT:



#### Procedimentos associados

`vec_ptr new_vec(int len)`

- cria vetor de comprimento especificado

`int get_vec_element(vec_ptr v, int index, int *dest)`

- recolhe um elemento do vetor 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 vetor

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

### Análise detalhada de um exemplo: tempos de execução (1)

```
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

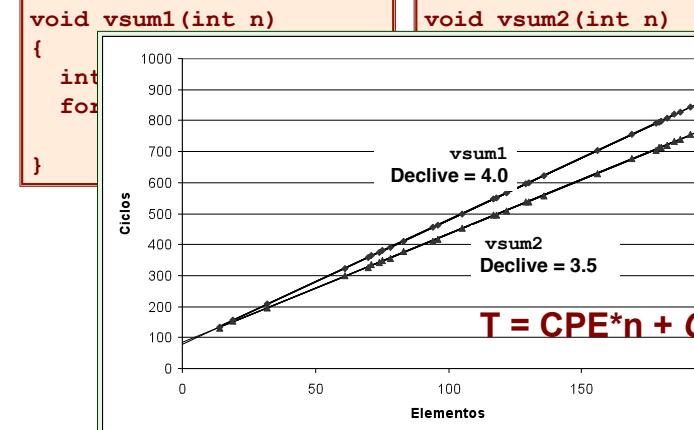
- **como medi-lo**: efetuar várias medições de tempo para dimensões variáveis de ciclos, e calculá-lo através do traçado gráfico: o declive da recta *best fit*, obtida pelo método dos mínimos quadrados:
  - análise gráfica de um exemplo...

## 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)



## Análise detalhada de um exemplo: o procedimento a otimizar (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 vetor
  - guarda o resultado numa localização destino
  - estrutura e operações do vetor definidos via ADT
- Tempo de execução (inteiros) :**
  - compilado sem qq otimização: 42.06 CPE
  - compilado com -O2: 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!

### Otimização 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 fora 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 argumento
  - depende de outras partes do estado global

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

- otimização 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 invocar de procedimentos

### Otimização 2:

- evitar invocação de `get_vec_element` para ir buscar cada elemento do vetor
  - 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];
    }
}
```

### Otimização 3:

- não é preciso guardar resultado em `dest` a meio dos cálculos
  - a variável local `sum` é alocada a um registo
  - poupa 2 acessos à memória por ciclo (1 leitura + 1 escrita)
- **CPE:** de 6.00 para **2.00** (compilado com `-O2`)
  - acessos à memória 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

### Otimizações

- reduzir invocação func e acessos à memória 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 quando acumulou em *temp*
  - causa: unidade de FP do IA32
    - memória usa formato com 64-bit, registo usa 80
    - os dados causaram *overflow* com 64 bits, mas não com 80