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 de técnicas de otimização (*s/w*)

- técnicas independentes da máquina *... já visto...*
- **técnicas de otimização de código (dep. máquina)**
  - análise sucinta de um CPU atual, P6 (*já visto...*)
  - ***loop unroll* sem e com paralelismo**
  - ***inline functions***
  - **identificação de potenciais limitadores de desempenho**
  - dependentes da hierarquia da memória
- **outras técnicas de otimização**
  - **na compilação**: otimizações efectuadas pelo `Gcc`
  - **na identificação dos "gargalos" de desempenho**
    - *code profiling* e uso dum *profiler* para apoio à otimização
    - **lei de Amdahl**

Técnicas de otimização dependentes da máquina: loop unroll (1)

```
void combine5(vec_ptr v, int *dest)
{
  int length = vec_length(v);
  int limit = length-2;
  int *data = get_vec_start(v);
  int sum = 0;
  int i;
  /* junta 3 elem's no mesmo ciclo */
  for (i = 0; i < limit; i+=3) {
    sum += data[i] + data[i+1]
           + data[i+2];
  }
  /* completa os restantes elem's */
  for (; i < length; i++) {
    sum += data[i];
  }
  *dest = sum;
}
```

Otimização 4:

- juntar várias (**3**) iterações num simples ciclo
- amortiza *overhead* dos ciclos em várias iterações
- termina extras no fim
- **CPE: 1.33**

Técnicas de otimização dependentes da máquina: loop unroll (2)

- **loads** podem encadear, uma vez que não há dependências
- apenas um conjunto de instruções de controlo de ciclo

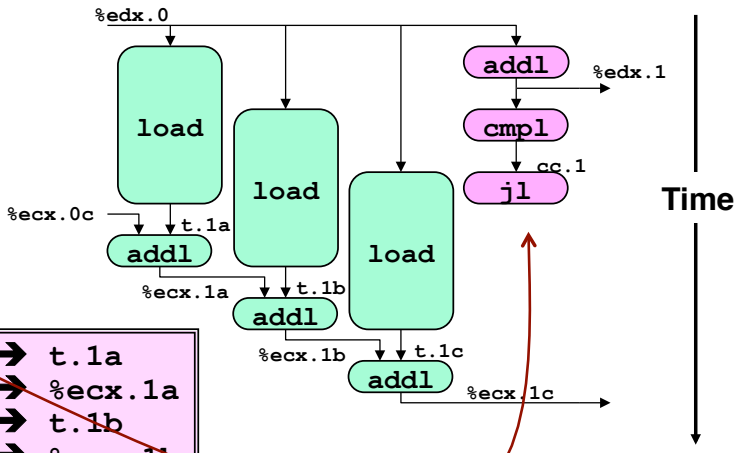


```
load (%eax,%edx.0,4)    ➔ t.1a
iaddl t.1a, %ecx.0c     ➔ %ecx.1a
load 4(%eax,%edx.0,4)   ➔ t.1b
iaddl t.1b, %ecx.1a     ➔ %ecx.1b
load 8(%eax,%edx.0,4)   ➔ t.1c
iaddl t.1c, %ecx.1b     ➔ %ecx.1c
iaddl $3,%edx.0         ➔ %edx.1
cmpl %esi, %edx.1       ➔ cc.1
jl  -taken cc.1
```

Técnicas de otimização dependentes da máquina: loop unroll (3)

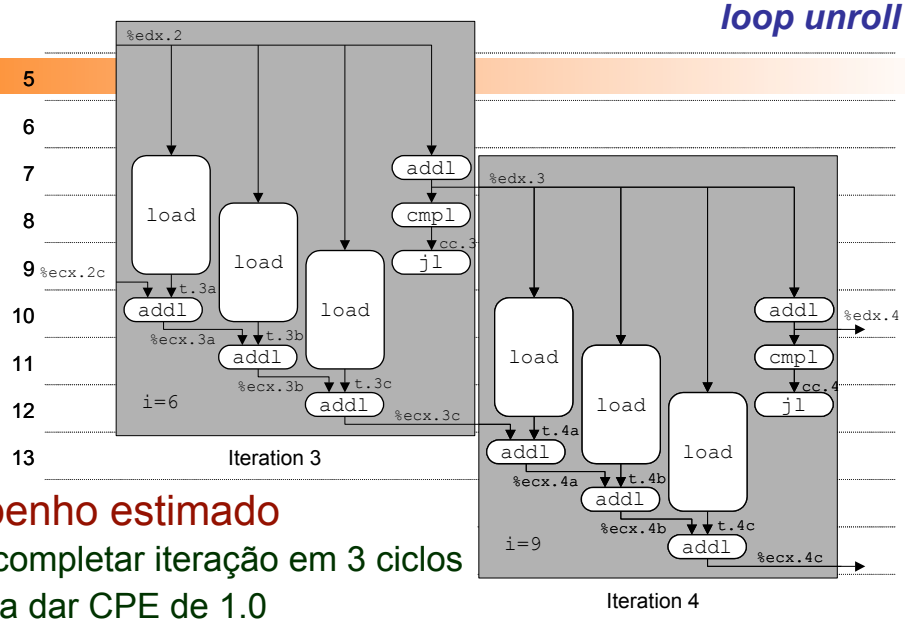

- Desempenho estimado
  - pode completar iteração em 3 ciclos
  - deveria dar CPE de 1.0
- Desempenho medido
  - CPE: 1.33
  - 1 iteração em cada 4 ciclos

Técnicas de otimização dependentes da máquina: loop unroll (4)

Valor do **CPE** para várias situações de *loop unroll*:

Grau de *Unroll*		1	2	3	4	8	16
Inteiro	Soma	2.00	1.50	1.33	1.50	1.25	1.06
Inteiro	Produto	4.00					
fp	Soma	3.00					
fp	Produto	5.00					

- apenas melhora nas somas de inteiros
  - restantes casos há restrições com a latência da unidade
- efeito não é linear com o grau de *unroll*
  - há efeitos subtis que determinam a atribuição exacta das operações

Computação sequencial *versus* ...

- a computação…

$$((((((((((((1 * x_0) * x_1) * x_2) * x_3) * x_4) * x_5) * x_6) * x_7) * x_8) * x_9) * x_{10}) * x_{11})$$

… o desempenho

–N elementos, D ciclos/operação

–N*D ciclos

Computação sequencial ... *versus* paralela!

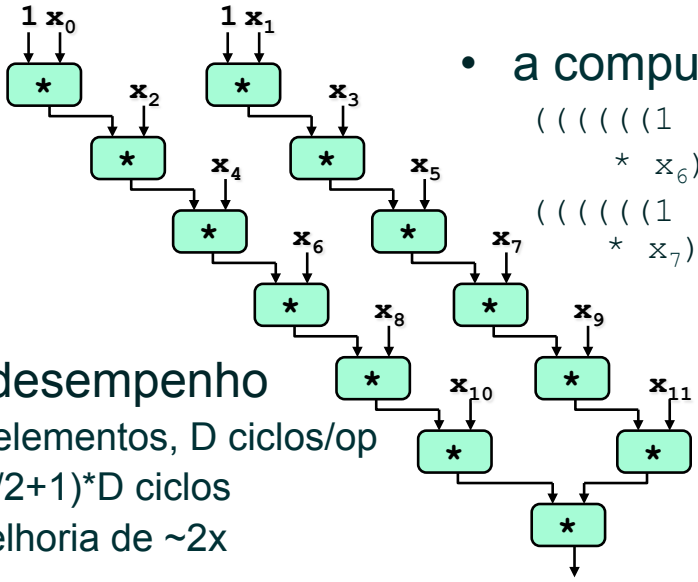

- a computação…

$$((((((1 * x_0) * x_2) * x_4) * * x_6) * x_8) * x_{10}) *$$
$$((((((1 * x_1) * x_3) * x_5) * * x_7) * x_9) * x_{11})$$

… o desempenho

–N elementos, D ciclos/op

–(N/2+1)*D ciclos

–melhoria de ~2x

Técnicas de otimização dependentes da máquina: loop unroll com paralelismo (1)

```
void combine6(vec_ptr v, int *dest)
{
  int length = vec_length(v);
  int limit = length-1;
  int *data = get_vec_start(v);
  int x0 = 1;
  int x1 = 1;
  int i;
  /* junta 2 elem's de cada vez */
  for (i = 0; i < limit; i+=2) {
    x0 *= data[i];
    x1 *= data[i+1];
  }
  /* completa os restantes elem's */
  for (; i < length; i++) {
    x0 *= data[i];
  }
  *dest = x0 * x1;
}
```

... *versus* paralela!

Otimização 5:

- acumular em 2 produtos diferentes
  - pode ser feito em paralelo, se OP fôr associativa!
- juntar no fim

- Desempenho
  - **CPE: 2.0**
  - melhoria de 2x

Técnicas de otimização dependentes da máquina: loop unroll com paralelismo (2)

- os dois produtos no interior do ciclo não dependem um do outro…
- e é possível encadeá-los
- *iteration splitting*, na literatura

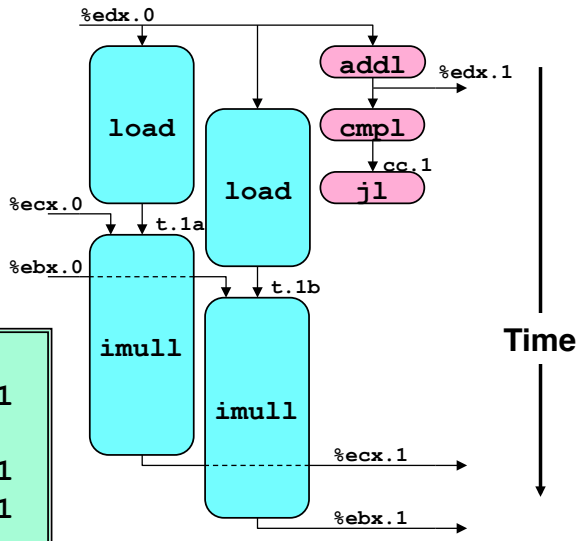


```
load (%eax,%edx.0,4)   ➔ t.1a
imull t.1a, %ecx.0     ➔ %ecx.1
load 4(%eax,%edx.0,4)  ➔ t.1b
imull t.1b, %ebx.0     ➔ %ebx.1
iaddl $2,%edx.0        ➔ %edx.1
cmpl %esi, %edx.1      ➔ cc.1
jl-taken cc.1
```

Técnicas de otimização dependentes da máquina: loop unroll com paralelismo (3)

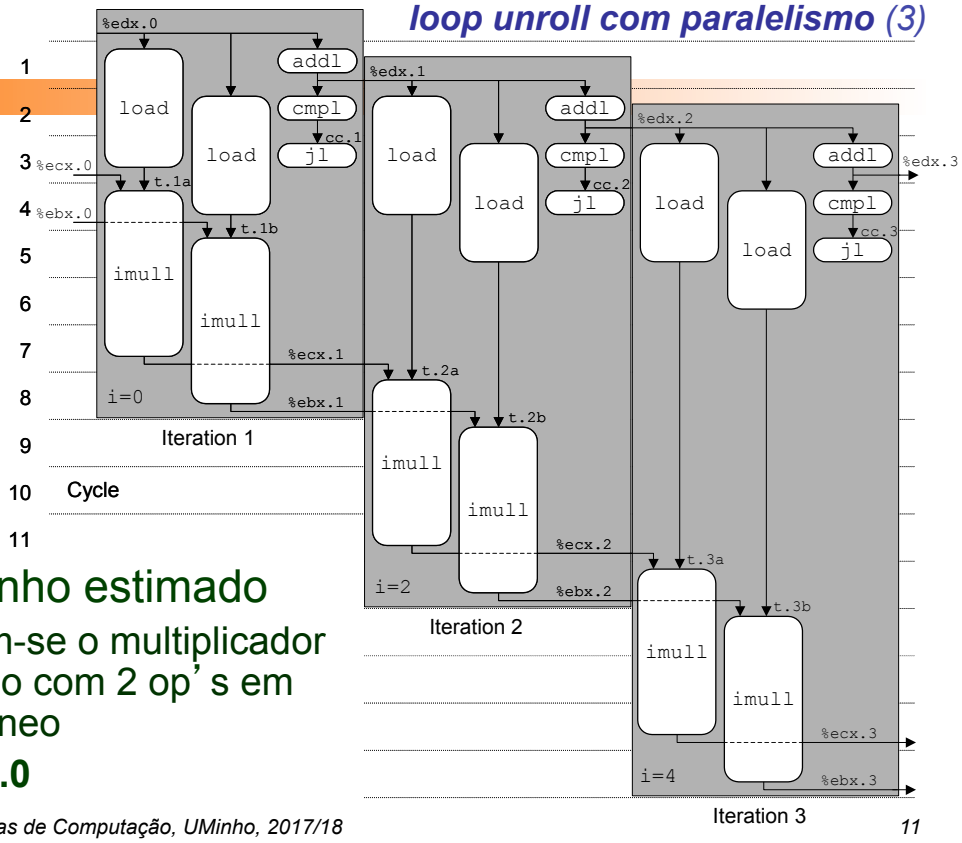

Desempenho estimado

- mantém-se o multiplicador ocupado com 2 op's em simultâneo
- **CPE: 2.0**

Técnicas de otimização de código: análise comparativa de `combine`

Método	**Inteiro**		**Real** (precisão simples)	
	+	*****	**+**	*****
***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**
***Unroll* 4x**	**1.50**	**4.00**	**3.00**	**5.00**
***Unroll* 16x**	**1.06**	**4.00**	**3.00**	**5.00**
***Unroll* 2x, paral. 2x**	**1.50**	**2.00**	**2.00**	**2.50**
***Unroll* 4x, paral. 4x**	**1.50**	**2.00**	**1.50**	**2.50**
***Unroll* 8x, paral. 4x**	**1.25**	**1.25**	**1.50**	**2.00**
Otimização Teórica	**1.00**	**1.00**	**1.00**	**2.00**
Rácio Pior : Melhor	***39.7***	***33.5***	***27.6***	***80.0***

- Precisa de muitos registos!
  - para guardar somas/produtos
  - apenas 6 registos (p/ inteiros) disponíveis no IA-32
    - tb usados como apontadores, controlo de ciclos, …
  - 8 registos de fp
  - quando os registos são insuficientes, temp's vão para a *stack*
    - elimina ganhos de desempenho
      (ver *assembly* em produto inteiro com *unroll* 8x e paralelismo 8x)
  - re-nomeação de registos não chega
    - não é possível referenciar mais operandos que aqueles que o *instruction set* permite
    - … principal inconveniente do *instruction set* do IA-32
- Operações a paralelizar têm de ser associativas
  - a soma e multipl de fp num computador não é associativa!
    - (3.14+1e20)-1e20 nem sempre é igual a 3.14+(1e20-1e20)…

- **`combine`**
  - produto de inteiros
  - *unroll* 8x e paralelismo 8x
  - 7 variáveis locais partilham 1 registo (`%edi`)
    - observar os acessos à *stack*
    - melhoria desempenho é comprometida...
    - *register spilling* na literatura

```
.L165:
      imull (%eax),%ecx
      movl -4(%ebp),%edi
      imull 4(%eax),%edi
      movl %edi,-4(%ebp)
      movl -8(%ebp),%edi
      imull 8(%eax),%edi
      movl %edi,-8(%ebp)
      movl -12(%ebp),%edi
      imull 12(%eax),%edi
      movl %edi,-12(%ebp)
      movl -16(%ebp),%edi
      imull 16(%eax),%edi
      movl %edi,-16(%ebp)
   …
      addl $32,%eax
      addl $8,%edx
      cmpl -32(%ebp),%edx
      jl .L165
```

Análise de técnicas de otimização (*s/w*)

- técnicas de otimização de código (indep. máquina)
  - *já visto...*
- técnicas de otimização de código (dep. máquina)
  - dependentes do processador *(já visto...)*
- **outras técnicas de otimização**
  - na compilação: otimizações efectuadas pelo `Gcc`
  - na identificação dos "gargalos" de desempenho
    - *code profiling*
    - uso dum *profiler* para apoio à otimização
    - **lei de Amdahl**
  - dependentes da hierarquia da memória
    - a localidade espacial e temporal dum programa
    - influência da *cache* no desempenho

Antes,
96% na função
`ProportRegionGrow`

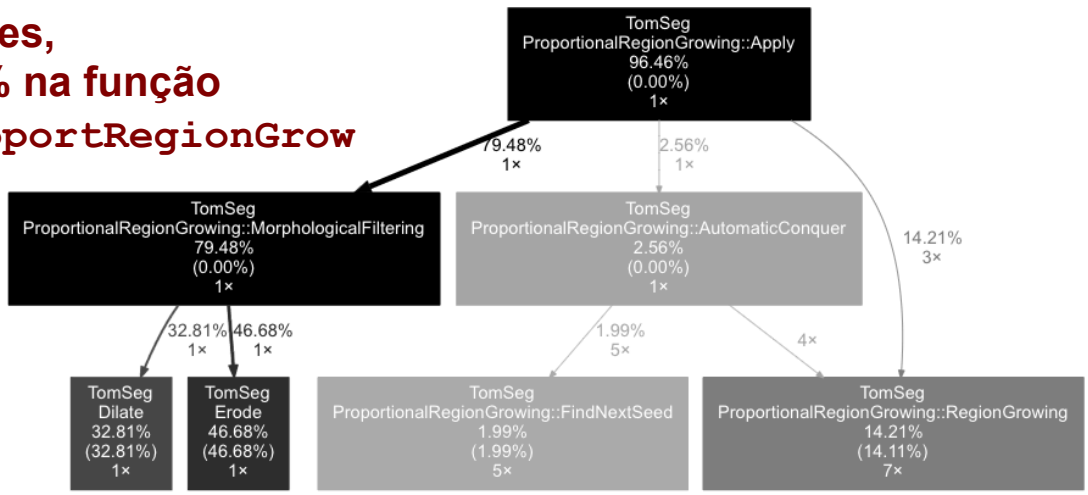

Figure 5.7.: Call-graph of the first version of *Propor. Region Growing* (DS3)

Code profiling:
análise visual da melhoria de código duma função

Depois, apenas 36% na mesma função!

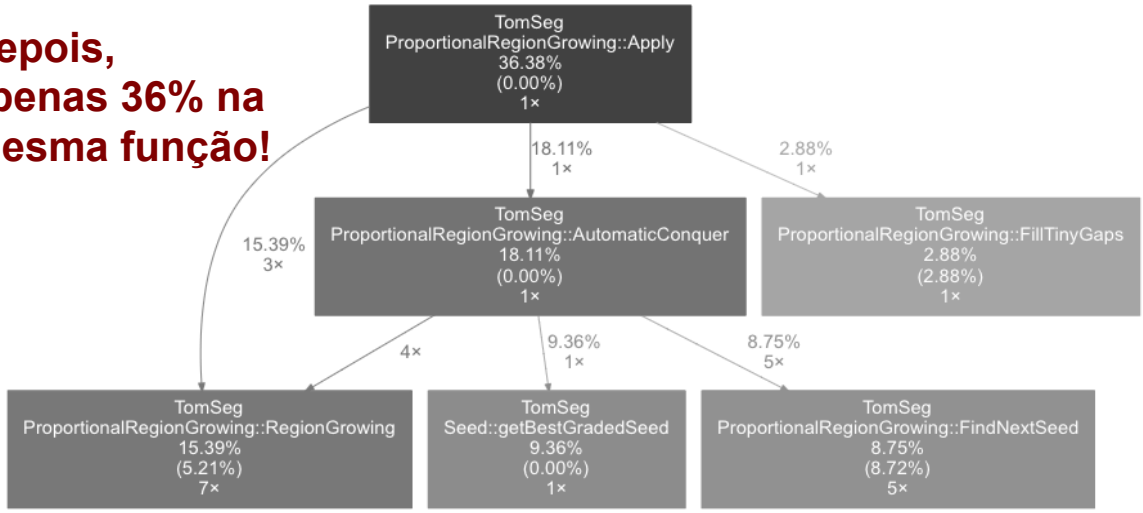

Figure 5.9.: Call-graph from the last version of *Propor. Region Growing* (DS3)

Lei de Amdahl

O ganho no desempenho – *speedup* –
obtido com a melhoria do tempo de execução de uma parte do sistema,
está limitado pela fração de tempo que essa parte do sistema pode ser usada.

$$Speedup_{overall} = \frac{Tempo\_exec_{antigo}}{Tempo\_exec_{novo}} = \frac{1}{\Sigma\,(f_i\,/\,s_i)}$$

f_i - fracções com melhoria s_i
s_i - *speedup* de cada fracção

Ex.1: Se **10%** de um prog executa **90x** mais rápido, então

***Overall speedup* = 1.11**

Ex.2: Se **90%** de um prog executa **90x** mais rápido, então

***Overall speedup* = 9.09**

Paralelismo:
se N_{proc} ≡ ***speedup***, trocar s_i por N_{proc}