MO401

Arquitetura de Computadores I

2006

Prof. Paulo Cesar Centoducatte

ducatte@ic.unicamp.br

www.ic.unicamp.br/~ducatte

MO401

Arquitetura de Computadores I

Revisão

Resumo #1/3: Pipelining & Desempenho

- Sobreposição de tarefas; fácil se as tarefas são independentes
- Speed Up ≤ Pipeline Depth; Se CPI ideal for 1, então:

$$\text{Speedup} = \frac{\text{Pipeline depth}}{1 + \text{Pipeline stall CPI}} \times \frac{\text{Cycle Time}_{\text{unpipelined}}}{\text{Cycle Time}_{\text{pipelined}}}$$

- Hazards limita o desempenho nos computadores:
  - Estrutural: é necessário mais recursos de HW
  - Dados (RAW,WAR,WAW): forwarding, compiler scheduling
  - Controle: delayed branch, prediction
- Tempo é a medida de desempenho: latência ou throughput
- CPI Law:

$$\text{CPU time} = \frac{\text{Seconds}}{\text{Program}} = \frac{\text{Instructions}}{\text{Program}} \times \frac{\text{Cycles}}{\text{Instruction}} \times \frac{\text{Seconds}}{\text{Cycle}}$$

Resumo #2/3: Caches

- Princípio da Localidade:
  - Programas acessam relativamente uma pequena porção do espaço de endereçamento em um dado instante de tempo.
    - » Localidadde Temporal : Localidade no Tempo
    - » Localidade Espacial : Localidade no Espaço

- Cache Misses: 3 categorias
  - Compulsory Misses
  - Capacity Misses
  - Conflict Misses

- Políticas de Escrita:
  - Write Through: (write buffer)
  - Write Back

Resumo #3/3: Cache Design

- Várias Dimensões interagindo
  - Tamanho da cache
  - Tamanho do block
  - associatividade
  - Política de "replacement"
  - Write-through vs Write-back

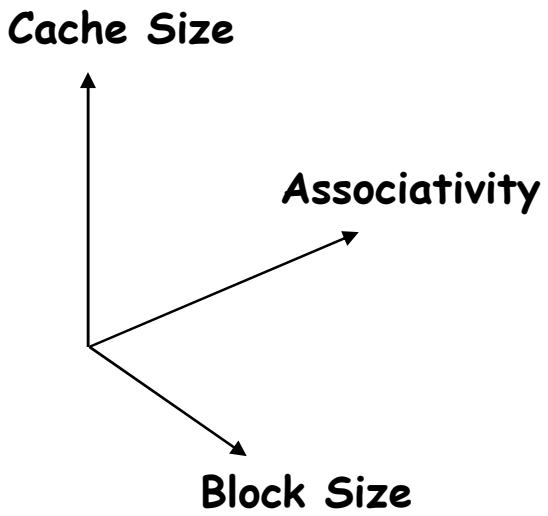

- Solução "ótima" é um compromisso
  - Depende da característica dos acessos
    - » workload
    - » I-cache, D-cache, TLB
  - Depende da razão tecnologia / custo

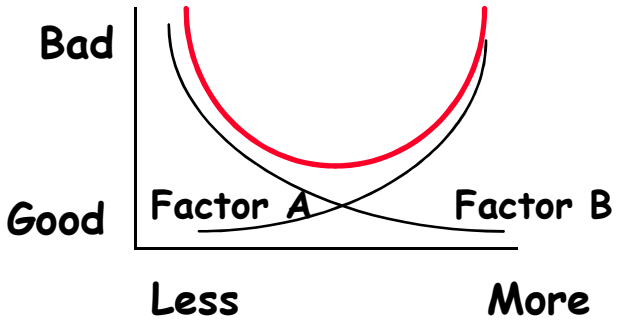

MO401

Arquitetura de Computadores I

Fundamentos

"Computer Architecture: A Quantitative Approach" - (Capítulo 1)

Sumário

- Introdução
  - O que é Arquitetura de Computadores?
- Tarefas do Projetista
- Tecnologia e Tendências na Computação
- Custo, Preço e suas Tendências
- Medidas
- Princípios Quantitativos
- Outros Aspectos

O que é Arquitetura de Computadores (AC)?

- 1950s a 1960s: Cursos de AC?

  Aritmética Computacional

- 1970s a meados dos anos 1980s: Cursos de AC?

  Projeto do Conjunto de Instruções (ISA), especialmente voltado para compiladores

- 1990s a 2000s: Cursos de AC?

  Projeto de CPU, Sistemas de Memórias, Sistemas de I/O, Multiprocessadores.

  - Enfoque Baseado em Desempenho

- 200? : Cursos de AC?

  Multi-Core, Embedded System

  - Enfoque Baseado em Desempenho e Consumo

Tarefas do Projetista

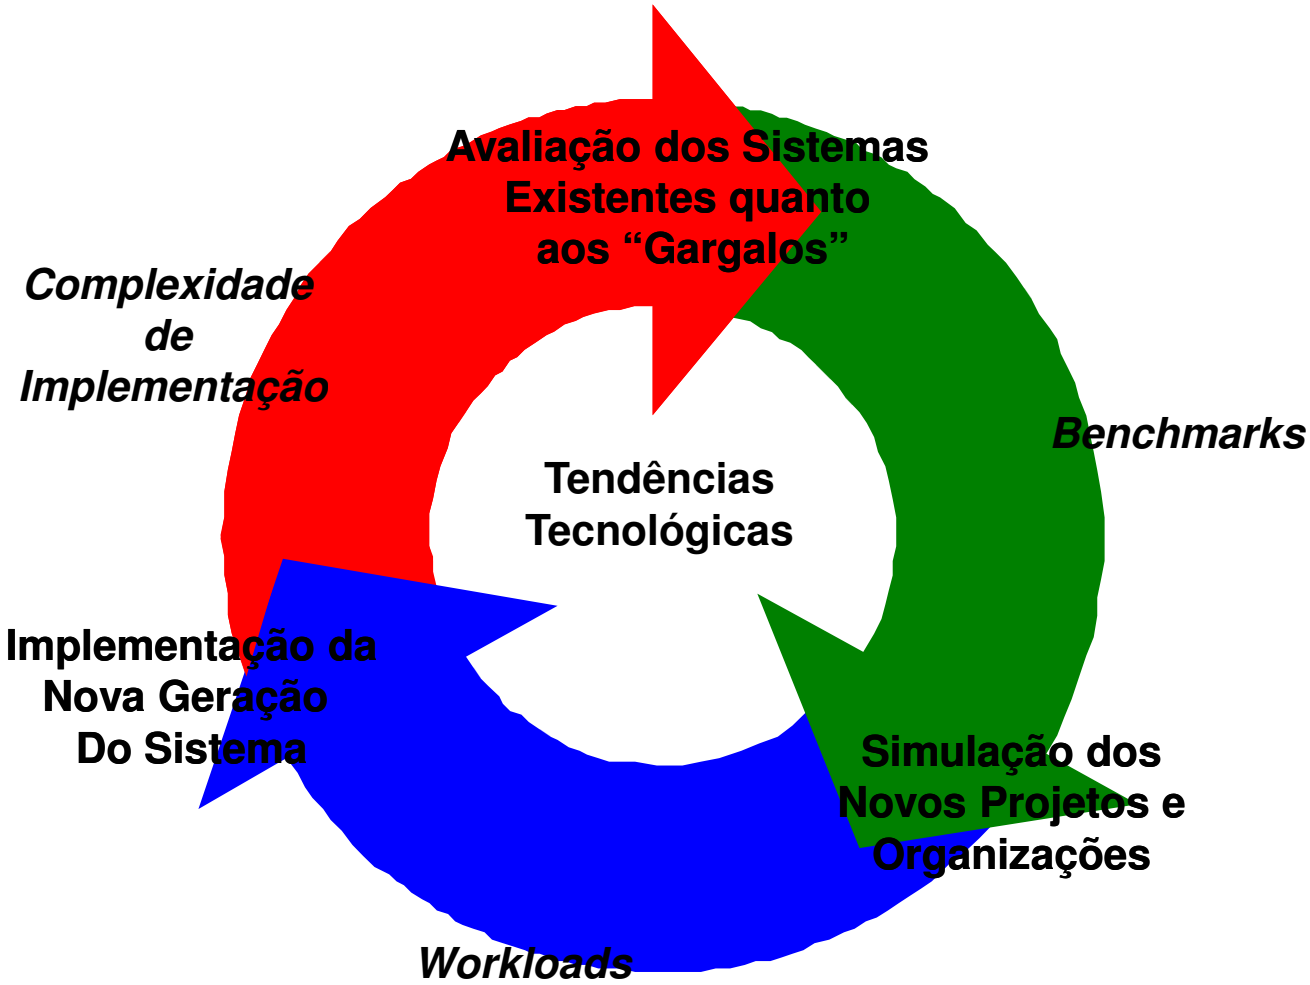

Tendências

- Gordon Moore (fundador da Intel), em 1965 observou que o número de transistores em um chip dobrava a cada ano (Lei de Moore)

  Continua valida até os dias de hoje !!!???

- O desempenho dos processadores, medidos por diversos benchmarks, também tem crescido de forma acelerada.

- A capacidade das memórias tem aumentado significativamente nos últimos 20 anos

  (E o custo reduzido)

Quais as Razões Desta Evolução nos Últimos Anos?

- Desempenho
  - Avanços tecnológicos
    - » Domínio de CMOS sobre as tecnologias mais antigas (TTL, ECL, …) em custo e desempenho
  - Avanços nas arquiteturas
    - » RISC, superscalar, VLIW,
    - » DRAM, SDRAM, …
    - » RAID, …
- Preço: Baixo custo devido a:
  - Desenvolvimento mais simples
    - » CMOS VLSI => sistemas menores, menos componentes
  - Alto volume (escala)
- .....

Tendências
Lei de Moore

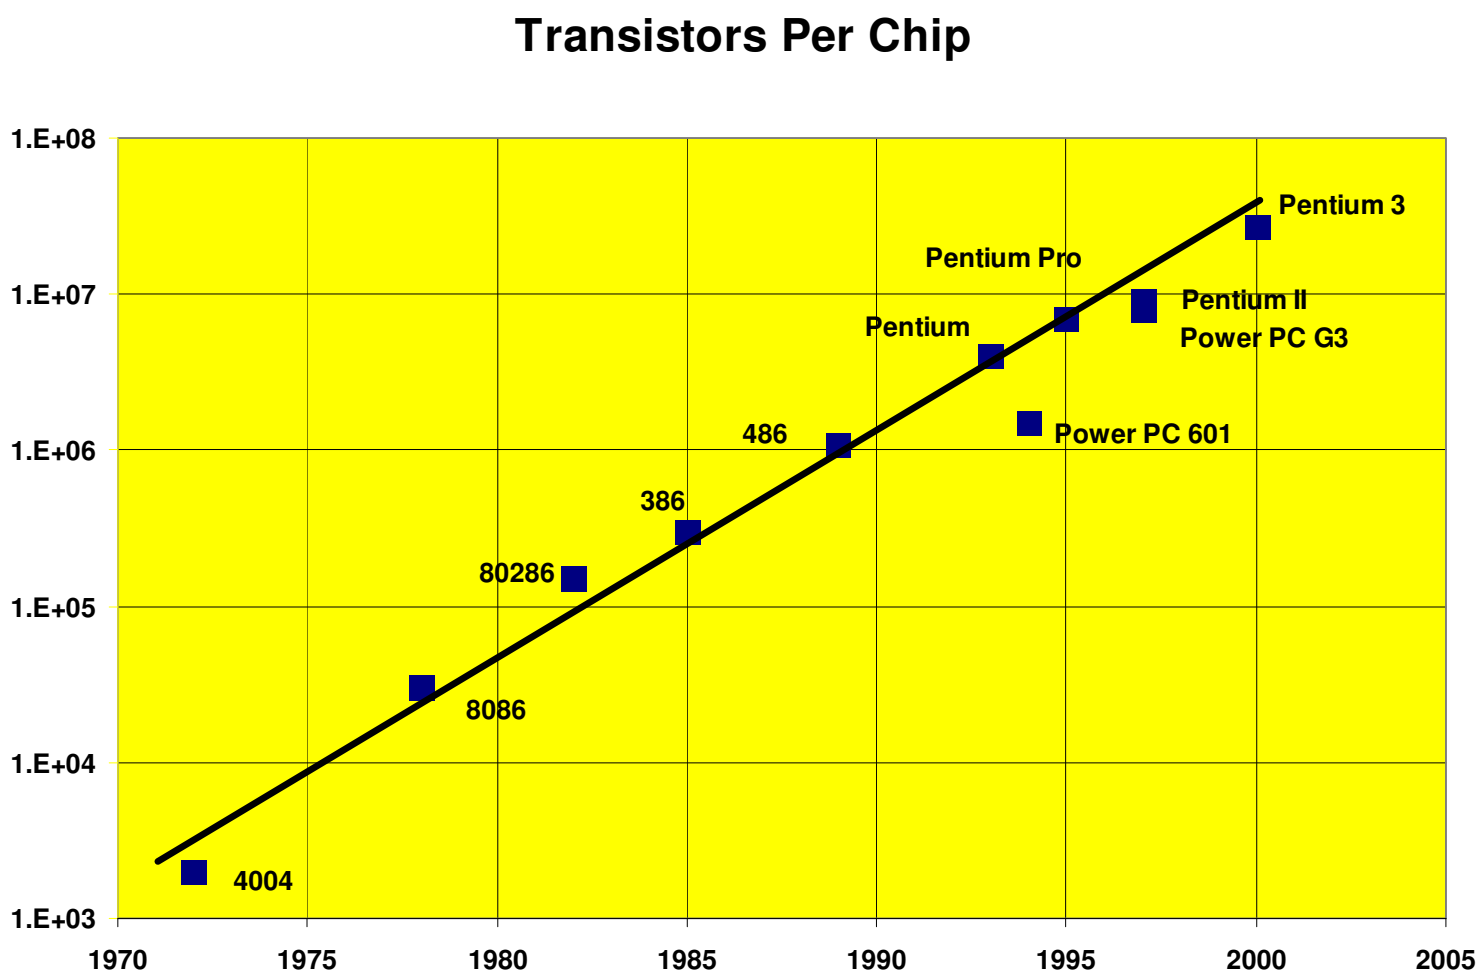

Tendência Tecnológica: Capacidade Microprocessadores

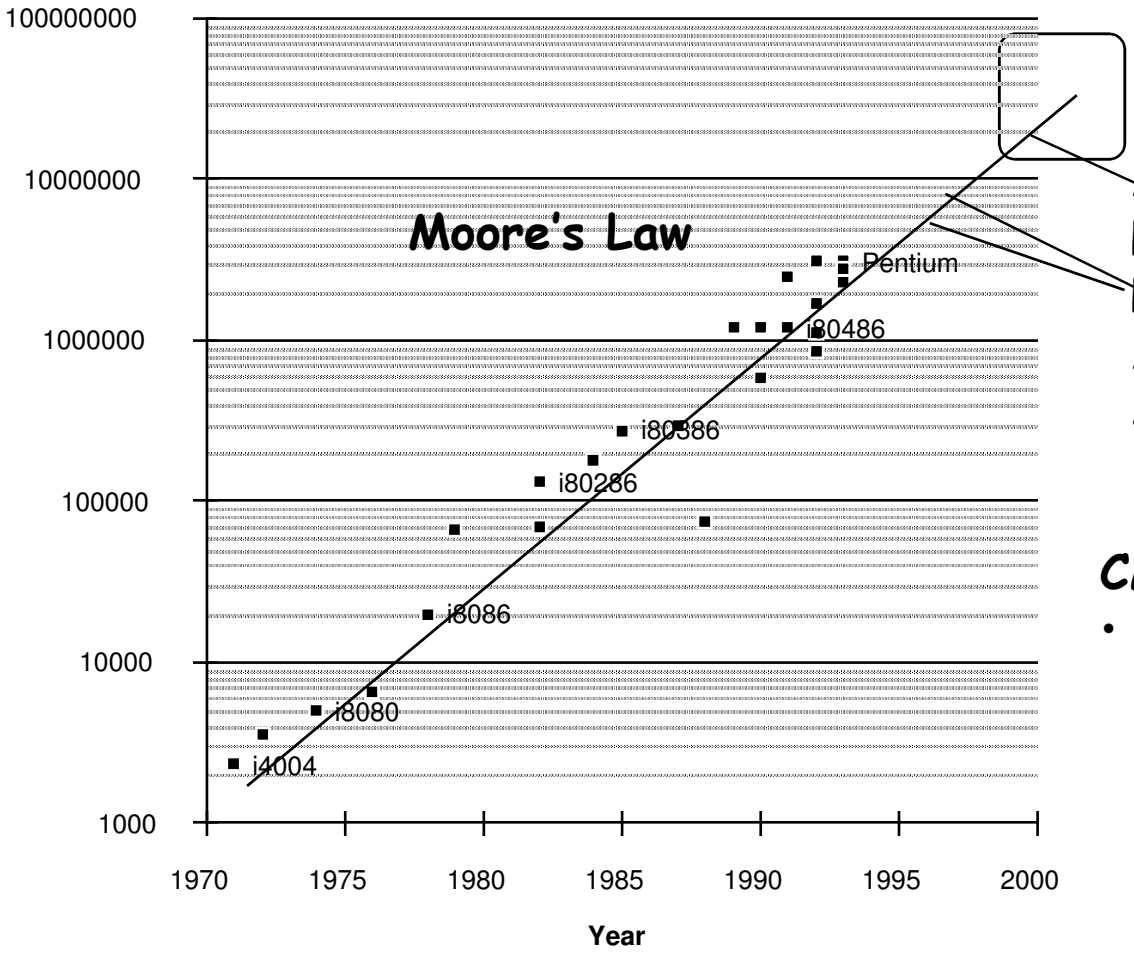

Alpha 21264: 15 milhões
Pentium Pro: 5.5 milhões
PowerPC 620: 6.9 milhões
Alpha 21164: 9.3 milhões
Sparc Ultra: 5.2 milhões

CMOS:

- **Die size: 2X a cada 3 anos**

Tendências
Desempenho dos Processadores

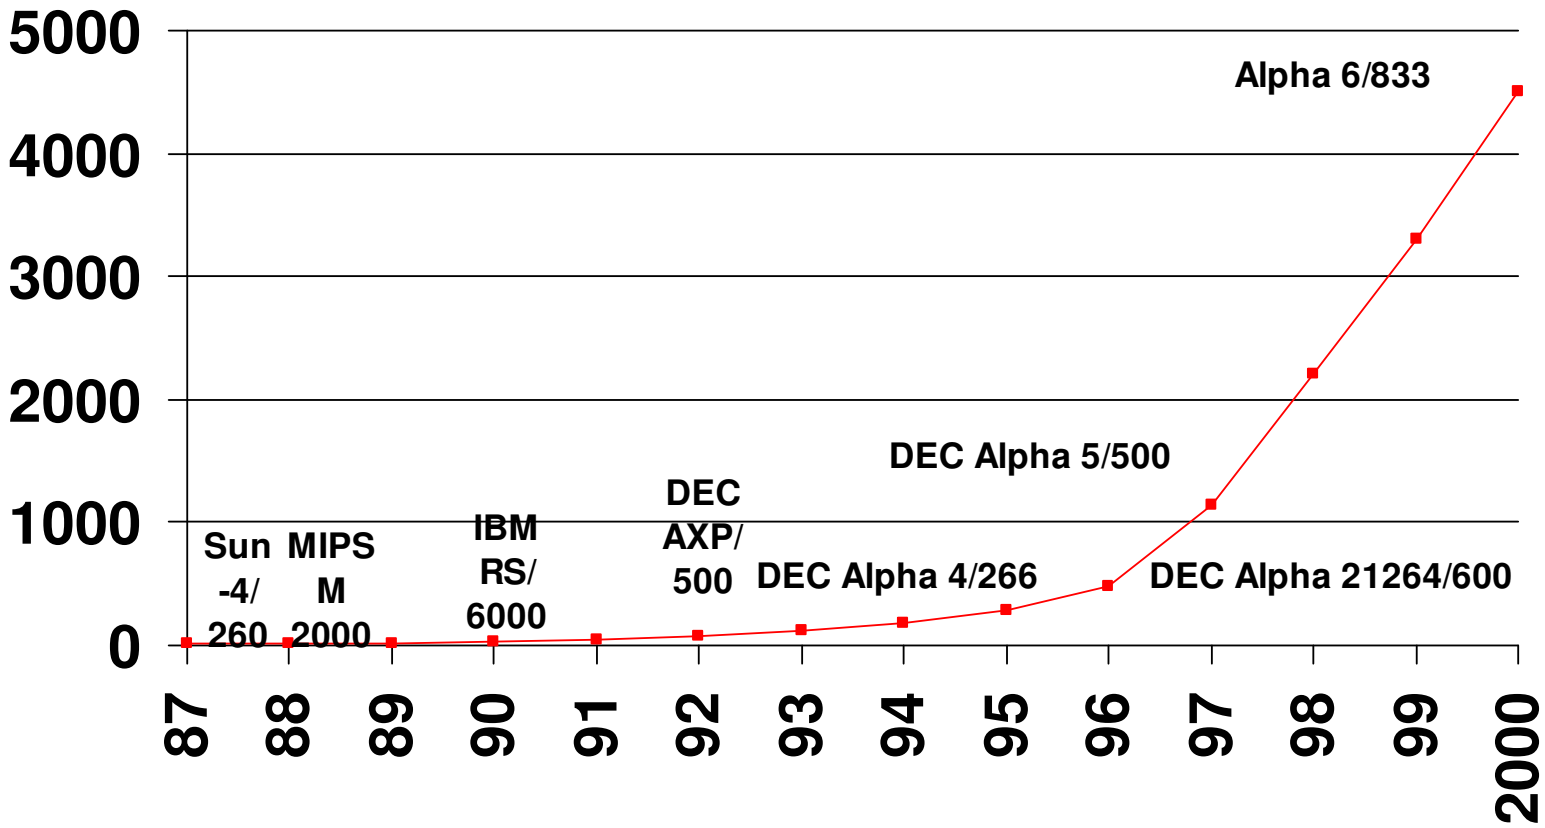

Tendências
Capacidade das Memórias

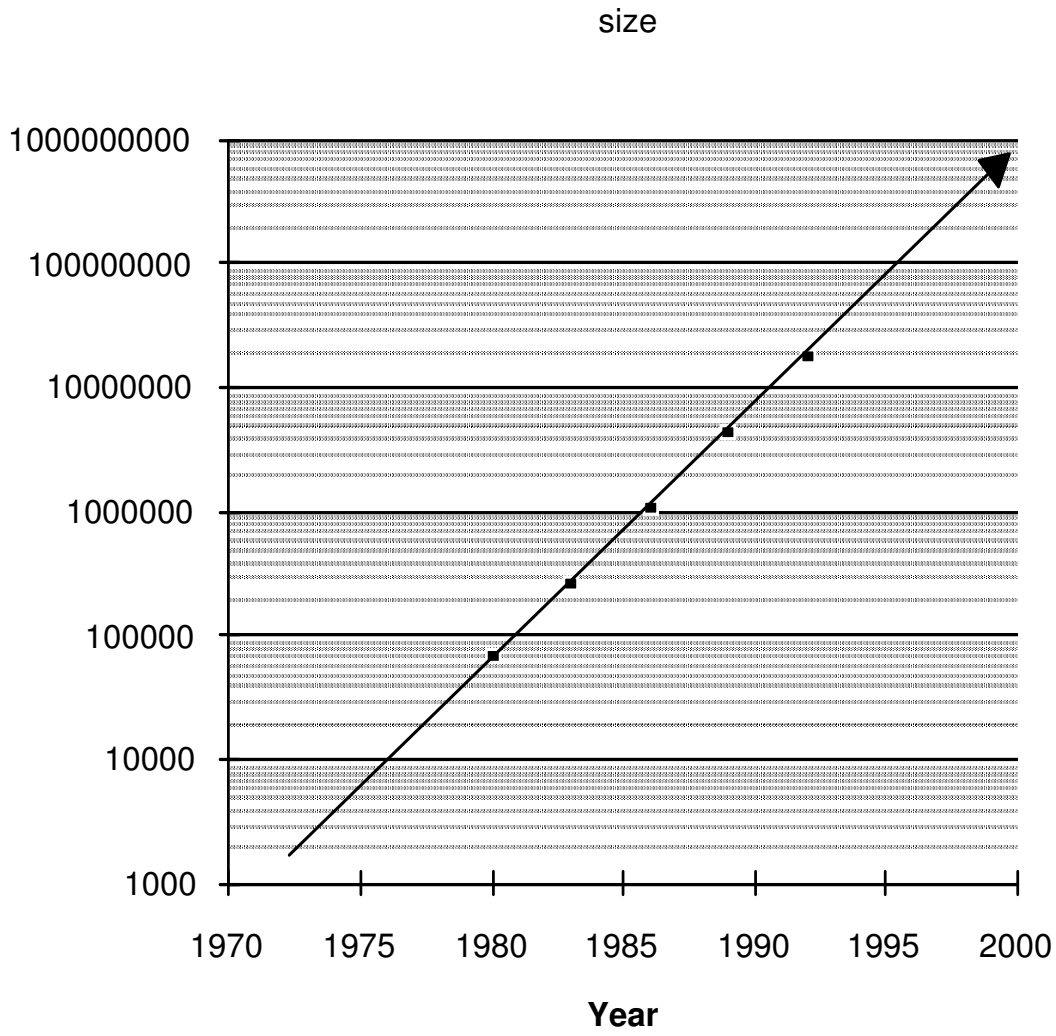

ano	Mbyte	cycle time
1980	0.0625	250 ns
1983	0.25	220 ns
1986	1	190 ns
1989	4	165 ns
1992	16	145 ns
1996	64	120 ns
2000	256	100 ns

Tendências
Velocidade

- Para a CPU o crescimento da velocidade tem sido muito acelerado
- Para Memória e disco o crescimento da velocidade tem sido modesto

Isto tem levado a mudanças significativas nas arquiteturas, SO e mesmo nas práticas de programação.

	Capacidade	Speed (latency)
Lógica	2x em 3 anos	2x em 3 anos
DRAM	4x em 3 anos	2x em 10 anos
Disco	4x em 3 anos	2x em 10 anos

Medidas
?

- Como descrever em forma numérica o desempenho dos computadores?

- Quais ferramentas (ou qual ferramental) usar para realizar e apresentar as medidas?

Métricas

Plane	DC to Paris	Speed	Passengers	Throughput (pmph)
Boeing 747	6.5 hours	610 mph	470	286,700
BAD/Sud Concorde	3 hours	1350 mph	132	178,200

- Tempo para executar uma tarefa (ExTime)
  - Execution time, response time, latency
- Tarefas por dia, hora, semana, segundo, ns, … (Desempenho)
  - Throughput, bandwidth

Métricas
Comparação

"X é n vezes mais rápido que Y" significa:

$$\frac{\text{ExTime(Y)}}{\text{ExTime(X)}} = \frac{\text{Performance(X)}}{\text{Performance(Y)}}$$

Velocidade do Concorde vs. Boeing 747

Throughput do Boeing 747 vs. Concorde

Métricas
Throughput

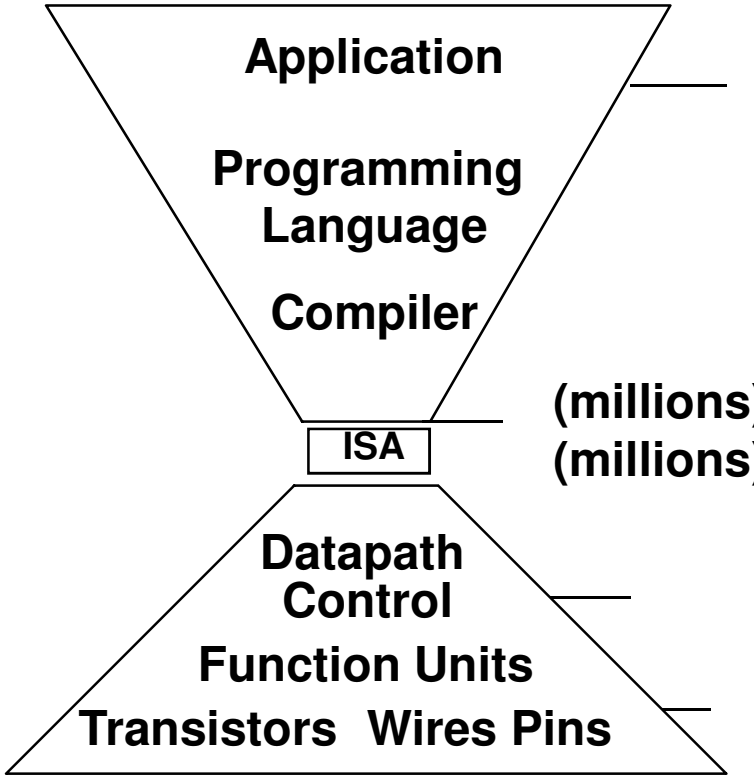

Respostas por dia, mês, ..
Operações por segundo

(millions) of Instructions per second: MIPS
(millions) of (FP) operations per second: MFLOP/s

Megabytes per second

Cycles per second (clock rate)

Métodos para Estimar o Desempenho

- Benchmarks, Traces, Mixes
- Hardware: custo, delay, área, consumo de energia
- Simulação (vários níveis)
  - ISA, RT, Gate, Circuito
- Teoria das Filas
- Regras Práticas
- "Leis"/Princípios

Benchmarks

- Aplicações Reais
  - Compiladores, processadores de texto, ...
  - Problema de portabilidade, dificil medir o tempo de execução
- Aplicações Modificadas
  - Melhora a portabilidade, pode ser refinado para medir um certo aspecto de interesse (exp: tempo de cpu)
- Kernels
  - Usados para avaliar caractrísticas específicas
  - Livermore Loops, Linpack
- Toy Benchmarks
  - 10 a 100 linhas de código, fácil de programar, avaliação inicial
- Benchmarks Sintéticos
  - Semelhantes aos Kernels
  - Whetstone, Dhrystone

Benchmarks

- Desktop
  - SPEC (http://www.spec.org)
- Servidores
  - SPEC
- Sistemas Embarcados
  - EEMBC (Embedded Microprocessor Benchmark Consortium) (http://www.eembc.org)
    - » Automotivo
    - » Consumidor
    - » Rede
    - » Automação de Escritório
    - » telecomunicações

Benchmarks

SPEC: Standard Performance Evaluation Corporative (http://www.spec.org)

- Primeira Versão - 1989
  - 10 programas ("SPECmarks")
- Segunda Versão - 1992
  - SPECInt92 (6 programas)
  - SPECfp92 (14 programas)
    - » Compiler Flags: livre
- Terceira Versão - 1995
  - SPECint95 (8 programas)
  - SPECfp95 (10 programas)
  - SPECint_base95, SPECfp_base95
    - » "benchmarks útil por 3 anos"
    - » Compiler Flags: controladas

Benchmarks

SPEC CPU2000 - CINT2000

Programa	Linguagem	Finalidade
164.gzip	C	Compression
175.vpr	C	FPGA Circuit Placement and Routing
176.gcc	C	C Programming Language Compiler
181.mcf	C	Combinatorial Optimization
186.crafty	C	Game Playing: Chess
197.parser	C	Word Processing
252.eon	C++	Computer Visualization
253.perlbmk	C	PERL Programming Language
254.gap	C	Group Theory, Interpreter
255.vortex	C	Object-oriented Database
256.bzip2	C	Compression
300.twolf	C	Place and Route Simulator

http://www.spec.org/osg/cpu2000/CINT2000/

Benchmarks

SPEC CPU2000 - CFP2000

Program	Linguagem	Finalidade
168.wupwise	Fortran 77	Physics / Quantum Chromodynamics
171.swim	Fortran 77	Shallow Water Modeling
172.mgrid	Fortran 77	Multi-grid Solver: 3D Potential Field
173.applu	Fortran 77	Parabolic / Elliptic Differential Equations
177.mesa	C	3-D Graphics Library
178.galgel	Fortran 90	Computational Fluid Dynamics
179.art	C	Image Recognition / Neural Networks
183.equake	C	Seismic Wave Propagation Simulation
187.facerec	Fortran 90	Image Processing: Face Recognition
188.ammp	C	Computational Chemistry
189.lucas	Fortran 90	Number Theory / Primality Testing
191.fma3d	Fortran 90	Finite-element Crash Simulation
200.sixtrack	Fortran 77	High Energy Physics Accelerator Design
301.apsi	Fortran 77	Meteorology: Pollutant Distribution

http://www.spec.org/osg/cpu2000/CFP2000/

Benchmarks – Exemplo de Resultado para SpecINT2000

http://www.spec.org/osg/cpu2000/results/res2000q3/cpu2000-20000718-00168.asc

Benchmarks	Base Ref Time	Base Run Time	Base Ratio	Peak Ref Time	Peak Run Time	Peak Ratio
164.gzip	1400	277	505*	1400	270	518*
175.vpr	1400	419	334*	1400	417	336*
176.gcc	1100	275	399*	1100	272	405*
181.mcf	1800	621	290*	1800	619	291*
186.crafty	1000	191	522*	1000	191	523*
197.parser	1800	500	360*	1800	499	361*
252.eon	1300	267	486*	1300	267	486*
253.perlbmk	1800	302	596*	1800	302	596*
254.gap	1100	249	442*	1100	248	443*
255.vortex	1900	268	710*	1900	264	719*
256.bzip2	1500	389	386*	1500	375	400*
300.twolf	3000	784	382*	3000	776	387*
SPECint_base2000			438			
SPECint2000						442

Intel OR840(1 GHz Pentium III processor)

Benchmarks
Como Apresentar o Desempenho?

Gerentes gostam de números.

Técnicos querem mais:

- Reprodutibilidade – informações que permitam que o experimento seja repetido (reproduzido)
- Consistência nos dados, ié se o experimento é repetido os dados devem ser compativeis entre si

Como Apresentar os Dados?

	Computador A	Computador B	Computador C
Programa P1 (secs)	1	10	20
Programa P2 (secs)	1000	100	20
Total Time (secs)	1001	110	40

Como Apresentar os Dados

- Média Aritmética (média aritmética ponderada)

$$\Sigma(T_i)/n \text{ or } \Sigma(W_i*T_i)$$

- Média Harmônica (média harmônica ponderada)

$$n/\Sigma(1/R_i) \text{ or } n/\Sigma(W_i/R_i)$$

- Média geométrica $\left(\Pi\ T_j / N_j \right)^{1/n}$

- Tempo de execução normalizado (e.g., X vezes melhor que SPARCstation 10 - Spec)
  - Não use média aritmética para tempos de execução normalizado (o resultado, quando comparado n máquinas, depende de qual máquina é usada como referência), use média geométrica

Como Apresentar os Dados

máquina	A	B
programa 1	10 => t1A	20 => t1B
programa 2	30 => t2A	5 => t2B

***Média aritmética normalizada em A*:**

(t1A/t1A + t2A/t2A)/2 = 1 < (t1B/t1A+t2B/t2A)/2 = 13/12

***Média aritmética normalizada em B*:**

(t1A/t1B + t2A/t2B)/2 = 13/4 > (t1B/t1B + t2B/t2B)/2 = 1

CONTRADIÇÃO!!!!

Média Geométrica :

((t1A* t2A)/(t1A*t2A))^-.5 = 1 > ((t1B*t2B)/(t1A*t2A))^-.5 = (1/3)^-.5 =>
normalizado em A

((t1A* t2A)/(t1B*t2B))^-.5 = 3^-.5 > ((t1B*t2B)/(t1B*t2B))^-.5 = 1 =>
normalizado em B

Custo, Preço e suas tendências

Custo de Circuito Integrado (IC)

$$\text{IC cost} = \frac{\text{Die cost} + \text{Testing cost} + \text{Packaging cost}}{\text{Final test yield}}$$

$$\text{Die cost} = \frac{\text{Wafer cost}}{\text{Dies per Wafer} \times \text{Die yield}}$$

$$\text{Dies per wafer} = \frac{\pi\,(\text{Wafer\_diam}/2)^2}{\text{Die\_Area}} - \frac{\pi \times \text{Wafer\_diam}}{\sqrt{2 \cdot \text{Die\_Area}}} - \text{Test\_Die}$$

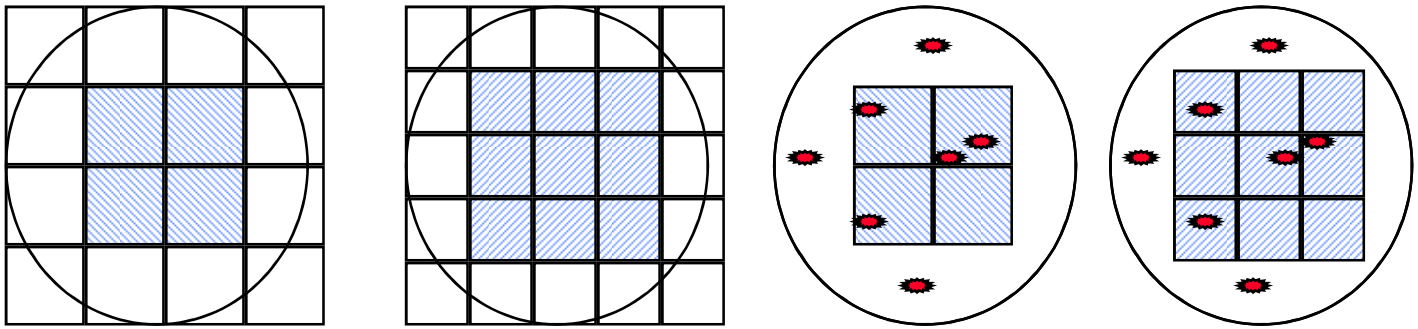

$$\text{Die Yield} = \text{Wafer\_yield} \times \left\{1 + \left(\frac{\text{Defect\_Density} \times \text{Die\_area}}{\alpha}\right)^{-\alpha}\right\}$$

Custo do Die é proporcional à (área do die)^4

Integrated Circuits Yield -Defects

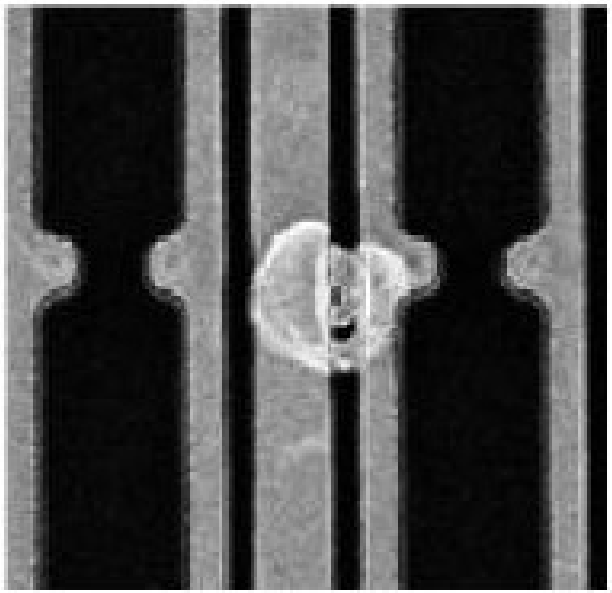

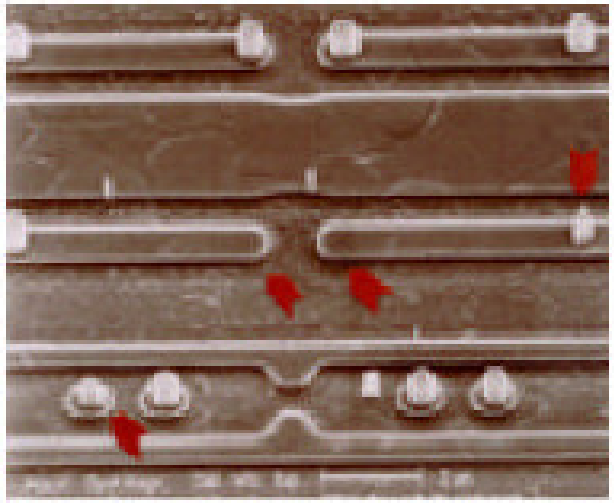

Examplos Reais

Chip	Metal layers	Line width	Wafer cost	Defect /cm^2	Area mm^2	Dies/ wafer	Yield	Die Cost
386DX	2	0.90	$900	1.0	43	360	71%	$4
486DX2	3	0.80	$1200	1.0	81	181	54%	$12
PowerPC 601	4	0.80	$1700	1.3	121	115	28%	$53
HP PA 7100	3	0.80	$1300	1.0	196	66	27%	$73
DEC Alpha	3	0.70	$1500	1.2	234	53	19%	$149
SuperSPARC	3	0.70	$1700	1.6	256	48	13%	$272
Pentium	3	0.80	$1500	1.5	296	40	9%	$417

– From "Estimating IC Manufacturing Costs," by Linley Gwennap, *Microprocessor Report*, August 2, 1993, p. 15

Abordagem Quantitativa

- Faça o caso comum ser mais rápido

- Amdahl's Law:
  - Relaciona o speedup total de um sistema com o speedup de uma porção do sistema

O speedup no desempenho obtido por uma melhoria é limitado pela fração do tempo na qual a melhoria é utilizada

Abordagem Quantitativa
Amdahl's Law

Speedup devido a uma melhoria E:

$$Speedup(E) = \frac{Execution\_Time\_Without\_Enhancement}{Execution\_Time\_With\_Enhancement} = \frac{Performance\_With\_Enhancement}{Performance\_Without\_Enhancement}$$

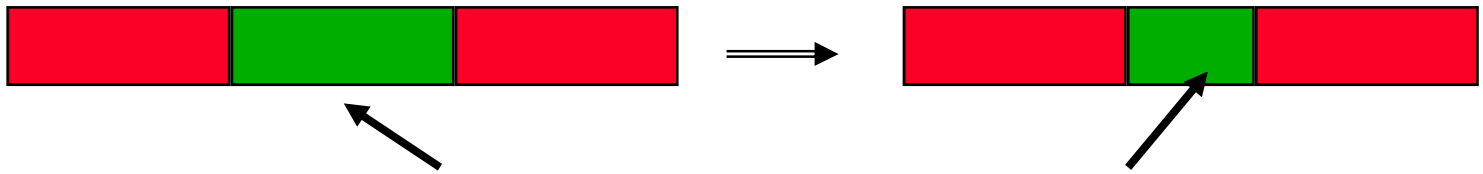

Fração melhorada

Abordagem Quantitativa
Amdahl's Law

Suponha que a melhoria E acelera a execução de uma fração F da tarefa de um fator S e que o restante da tarefa não é afetado pela melhoria E. Qual o speedup?

$T_{Old} = T_F + T_{nF}$

$T_{New} = T_F/S + T_{nF}$

$$\longrightarrow \quad \frac{T_{Old}}{T_{New}} = \frac{T_F + T_{nF}}{\frac{T_F}{S} + T_{nF}} = \frac{T_F + T_{nF}}{\frac{T_F + ST_{nF}}{S}}$$

$$Speedup = \frac{S(T_F + T_{nF})}{T_F + ST_{nF}}$$

Lim $_{TnF \to 0}$?

Lim $_{F \to 0}$?

Abordagem Quantitativa
Amdahl's Law

$$ExTime_{new} = ExTime_{old} \times \left[(1 - Fraction_{enhanced}) + \frac{Fraction_{enhanced}}{Speedup_{enhanced}} \right]$$

$$Speedup_{overall} = \frac{ExTime_{old}}{ExTime_{new}} = \frac{1}{(1 - Fraction_{enhanced}) + \frac{Fraction_{enhanced}}{Speedup_{enhanced}}}$$

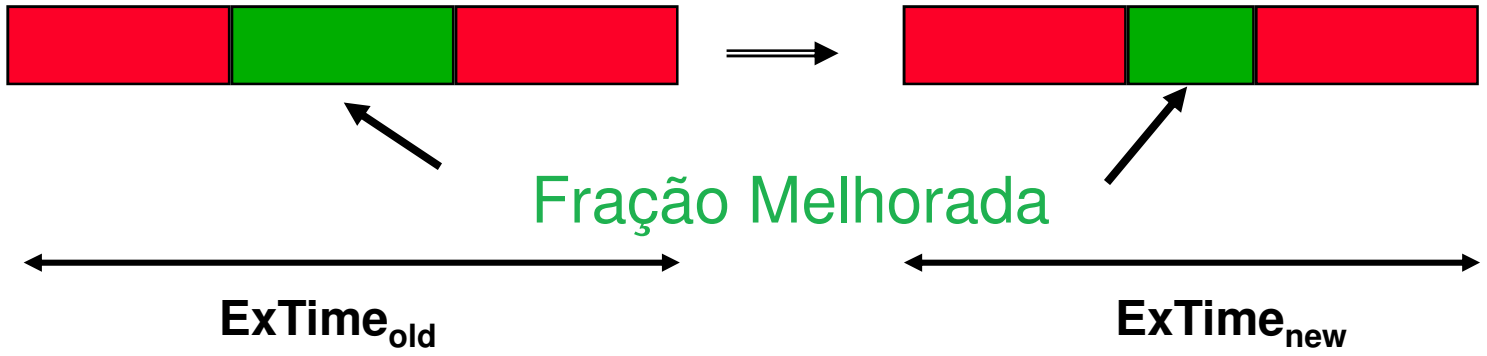

Abordagem Quantitativa
Amdahl's Law

- Exemplo: Suponha que as instruções de ponto flutuante foram melhoradas e executam 2 vezes mais rápidas, porém somente 10% das instruções, em um programa, são FP

$$ExTime_{new} = ExTime_{old} \times (0.9 + 0.1/2) = 0.95 \times ExTime_{old}$$

$$Speedup_{overall} = \frac{1}{0.95} = 1.053$$

Amdahl's Law

Execução de um programa em N processadores

$$\text{Fraction}_{\text{enhanced}} = \text{parallelizable part of program}$$

$$\text{Speedup}_{\text{enhanced}} = n$$

$$\text{ExTime}_{\text{new}} = \text{ExTime}_{\text{old}} \left(1 - \text{Fraction}_{\text{enhanced}}\right) + \frac{\text{ExTime}_{\text{old}} \times \text{Fraction}_{\text{enhanced}}}{n}$$

$$\text{Speedup}_{\text{overall}} = \frac{\text{ExTime}_{\text{old}}}{\text{ExTime}_{\text{new}}} = \frac{1}{\left(1 - \text{Fraction}_{\text{enhanced}}\right) + \frac{\text{Fraction}_{\text{enhanced}}}{\text{Speedup}_{\text{enhanced}}}}$$

$$\lim_{n \to \infty} \text{Speedup}_{\text{overall}} = 1 \,/\, \left(1 - \text{Fraction}_{\text{enhanced}}\right)$$

Amdahl's Law - Graph