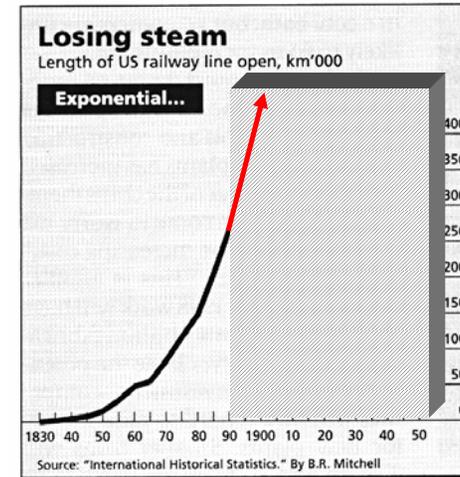
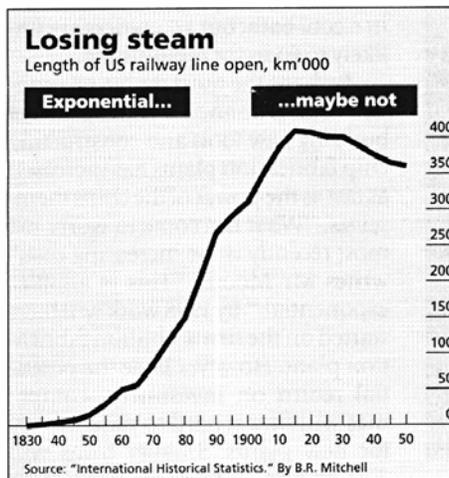


Aula 03: Análise de Performance e Benchmarks

O Perigo das Previsões...

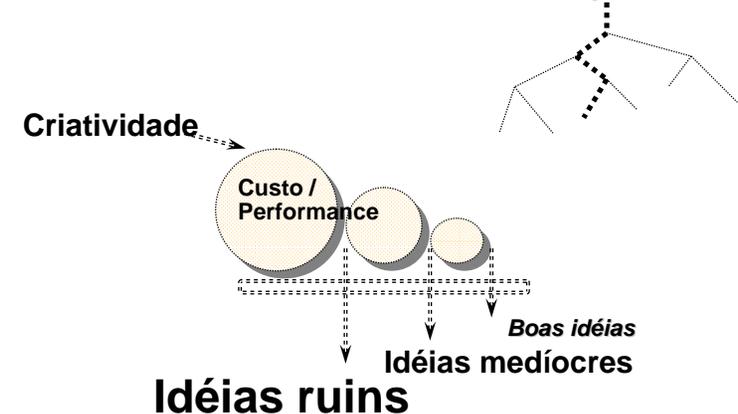


O Perigo das Previsões...



Medidas e Avaliações A Era RISC

- Arquitetura como processo iterativo:
- Busca da solução ótima em todos os níveis dos sistemas de computadores



Ferramentas para Medidas de Performance

- *Benchmarks, Traces, Mixes*
- Custo, atraso, área, estimativa de potência
- Simulação (muitos níveis)
 - ISA, RT, *Gate*, Circuito
- Teoria das filas
- Basic Rules
- Leis fundamentais

Performance (e Custo)

Avião	DC à Paris	Veloc.	Passageiros	Throughput (pmp)
Boeing 747	6.5 horas	610 mph	470	286,700
BAD/Sud Concorde	3 horas	1350 mph	132	178,200

- **Tempo para rodar tarefa (ExTime ou ET)**
 - tempo de execução, tempo de resposta, latência
- **Tarefas por dia, hora, semana, sec, ns ... (Performance)**
 - *Throughput, bandwidth*

Performance (e Custo)

"X é n vezes mais veloz que Y" significa

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

- **Velocidade** do Concorde vs. Boeing 747
- **Throughput** do Boeing 747 vs. Concorde

Terminologia de Performance

"X é n% mais veloz que Y" significa:

$$\frac{ExTime(Y)}{ExTime(X)} = \frac{Performance(X)}{Performance(Y)} = 1 + \frac{n}{100}$$

$$n = \frac{100(Performance(X) - Performance(Y))}{Performance(Y)}$$

Exemplo

Exemplo: Y leva 15 segundos para completar tarefa, X leva 10 segundos. Quantos % X é mais rápido?

$$\frac{ExTime(Y)}{ExTime(X)} = \frac{15}{10}$$

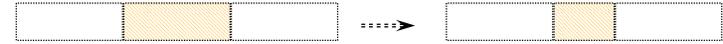
$$n = \frac{100(1.5 - 1.0)}{1.0}$$

$$n = 50\%$$

Lei de Amdahl

Speedup devido à melhoria E:

$$Speedup(E) = \frac{ExTime \text{ sem E}}{ExTime \text{ com E}} = \frac{Performance \text{ com E}}{Performance \text{ sem E}}$$



Suponha que melhoria E acelere porção F da tarefa por um fator S, e que restante da tarefa permanece sem alteração, então

$$ExTime(E) =$$

$$Speedup(E) =$$

Lei de Amdahl

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

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

Em última análise, performance de qualquer sistema será limitada por porção que não é melhorada...

Lei de Amdahl

- Instruções de ponto flutuante são melhoradas para rodar 2X mais rápidas, mas somente 10% das instruções são de ponto flutuante (FP).

$$ExTime_{new} =$$

$$Speedup_{overall} =$$

Lei de Amdahl

- Instruções de ponto flutuante são melhoradas para rodar 2X mais rápidas, mas somente 10% das instruções são de ponto flutuante (FP).

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

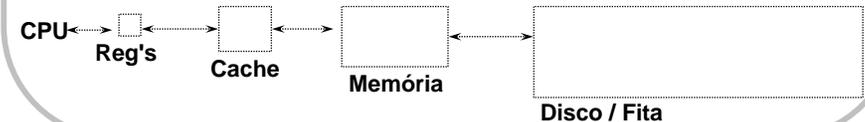
$$\text{Speedup}_{\text{overall}} = \frac{1}{0.95} = 1.053$$

Corolário: *Make the common case fast*

- Todas as instruções requerem busca de instrução, somente uma fração requer busca ou escrita de dados.
 - Otimize acessos à instruções em vez de otimizar o acesso a dados
- Programas exibem localidade de referência
 - Localidade espacial
 - Localidade temporal



- Acesso a memórias menores é mais rápido
 - Mantenha hierarquia de memória de modo a fazer acessos mais freqüentes estar localizados nas memórias menores.

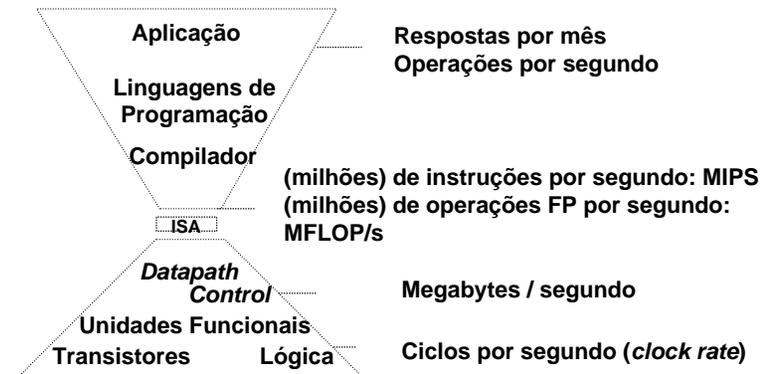


Regra Básica:

Make the common case fast

- Os casos mais simples são usualmente mais freqüentes e mais fáceis de serem otimizados!!!
- Faça as coisas simples e rápidas em hardware e certifique-se de que as demais sejam feitas corretamente em software.

Métricas de Performance



Aspectos da Performance de uma CPU

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

	Instruction Count	CPI	Clock Rate
Programa	X		
Compilador	X	(X)	
Conjunto de Instruções	X	X	
Organização	X	X	
Tecnologia			X

Métricas de Marketing

$$\text{MIPS} = \text{IC} / \text{CPU time} * 10^6 = \text{Clock Rate} / \text{CPI} * 10^6$$

- Máquinas com diferentes conjuntos de instruções ?
- Programas com instruções diferentes ?
 - Frequência dinâmica das instruções
- Sem correlação com performance

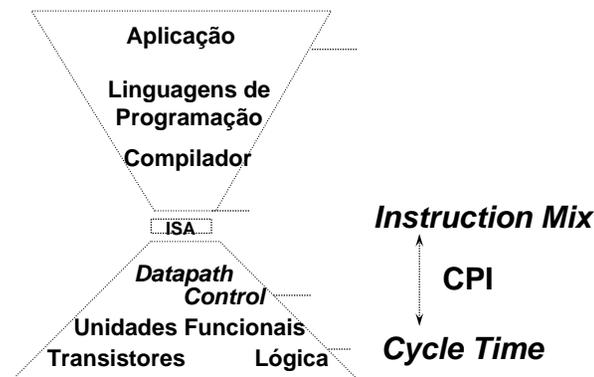
$$\text{MFLOP/s} = \text{Operações FP} / \text{CPU time} * 10^6$$

- Dependente de máquina
- Tempo da máquina pode estar sendo gasto em outro lugar

Normalizado:

add, sub, compare, mult	1
div, sqrt	4
exp, sin, . . .	8

Compromissos da Organização da CPU



Ciclos por Instrução

Cycles per Instruction

“Média do número de ciclos por instrução”

$$\begin{aligned} \text{CPI} &= \frac{(\text{CPU Time} \times \text{Clock Freq})}{\text{Instruction Count}} \\ &= \frac{\text{Cycles}}{\text{Instruction Count}} \end{aligned}$$

$$\text{CPU Time} = \text{Cycle Time} \times \sum_{i=1}^n \text{CPI}_i \times \text{IC}_i$$

“Frequência de instruções”

$$\text{CPI} = \sum_{i=1}^n \text{CPI}_i \times F_i \quad \text{onde} \quad F_i = \frac{\text{IC}_i}{\text{Instruction Count}}$$

Exemplo de Cálculo de CPI

Máquina Base (Reg / Reg)

Operação	Freq	Ciclos	CPI _i	(% Time)
ALU	50%	1	.5	(33%)
Load	20%	2	.4	(27%)
Store	10%	2	.2	(13%)
Branch	20%	2	.4	(27%)
CPI			1.5	

Mix Típico

Exemplo

Analisar o impacto de acrescentarem-se operações Registrador / Memória na máquina anterior, sabendo-se que:

- Um operando em memória
- Um operando em registrador
- Leva 2 ciclos para completar
- Branch passa a levar 3 ciclos para completar.

Qual a fração dos Loads tem que ser eliminada para que a modificação seja vantajosa?

Solução

$$ExTime = Instr\ Cnt \times CPI \times Clock$$

Op	Freq	Ciclos	CPI _i	Freq	Ciclos	CPI _i
ALU	0.50	1	0.5	0.5 - x	1	0.5 - x
Load	0.20	2	0.4	0.2 - x	2	0.4 - 2x
Store	0.10	2	0.2	0.1	2	0.2
Branch	0.20	2	0.4	0.2	3	0.6
Reg/Mem				x	2	2x
	1.00		1.5	1 - x		(1.7 - x)/(1 - x)

$$Instr\ Cnt_{Old} \times CPI_{Old} \times Clock_{Old} = Instr\ Cnt_{New} \times CPI_{New} \times Clock_{New}$$

$$1.00 \times 1.5 = (1 - x) \times \frac{(1.7 - x)}{(1 - x)}$$

$$1.5 = 1.7 - x$$

$$0.2 = x$$

TODOS os loads devem ser eliminados para esta versão ser vantajosa!

Programas para Avaliação da Performance de Processadores

- (Toy) Benchmarks
 - Programas de 10-100 linhas
 - e.g.: sieve, puzzle, quicksort
- Benchmarks sintéticos
 - Tentativa de se ter na média a mesma frequência de instruções de programas reais
 - e.g., Whetstone, dhrystone
- Kernels
 - Partes críticas de programas reais
 - e.g., *Livermore loops*
- Programas reais
 - e.g., gcc, spice

Truques utilizados para se ganhar o *Jogo dos Benchmarks*

- Configurações diferentes das máquinas utilizadas para rodar o mesmo programa;
- Compilador otimizado para o benchmark;
- Utilizar benchmark escrito para melhorar performance de uma única máquina;
- Sincronizar jobs intensivos em CPU/IO;
- Utilização de benchmarks pequenos;
- Benchmarks “compilados à mão” para otimizar performance;

Erros Comuns em *Benchmarking*

- Variações das demandas de dispositivos ignorados
- Nível de carga do sistema controlado de maneira inadequada
- Efeitos de cache ignorados
- Tamanho de *buffers* inapropriados
- Ignorar a imprecisão devido à amostragem

Erros Comuns em *Benchmarking*

- Ignorar *overhead* dos monitores;
- Medições sem validação;
- Não manter mesmas condições iniciais;
- Não medir performance transiente (*cold start*);
- Coleta de muitos dados com pouca análise;

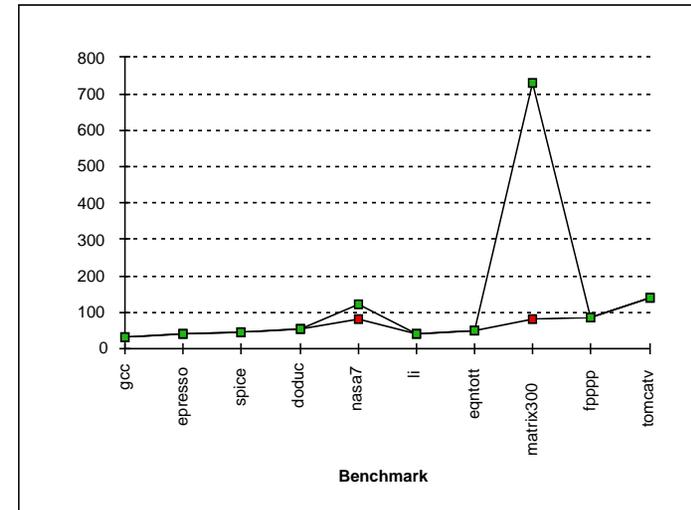
SPEC: *System Performance Evaluation Cooperative*

- Primeiro *Round* 1989
 - 10 programas
- Segundo *Round* 1992
 - SpecInt92 (6 programas inteiros) e SpecFP92 (14 programas de ponto flutuantes)
 - Sem limite para flags de compiladores
- Terceiro *Round* 1995
 - Limite de um único flag para todos os programas
 - Novo conjunto de programas

SPEC Primeiro Round

- Um programa: 99% do tempo em única linha de código
- Fácil para compilador (não testa a máquina)

SPEC Primeiro Round



Como agrupar dados de medições de Performance

1. Tempo total de Execução

a. Tempo → Média Aritmética

$$\sum_{i=1}^n \frac{T_i}{n}$$

b. Taxa (rate) → Média Harmônica

$$\frac{n}{\sum_{i=1}^n \frac{1}{R_i}}$$

– Rastream o tempo de execução

Como agrupar dados de medições de Performance

2. Tempo de Execução Ponderado

a. Tempo → Média Aritmética Ponderada

$$\sum_{i=1}^n \frac{T_i}{n}$$

b. Taxa (rate) → Média Harmônica Ponderada

$$\frac{n}{\sum_{i=1}^n \frac{1}{R_i}}$$

– Rastream o tempo de execução

Como agrupar dados de medições de Performance

3. Tempo de Execução Normalizado

a. Média Geométrica

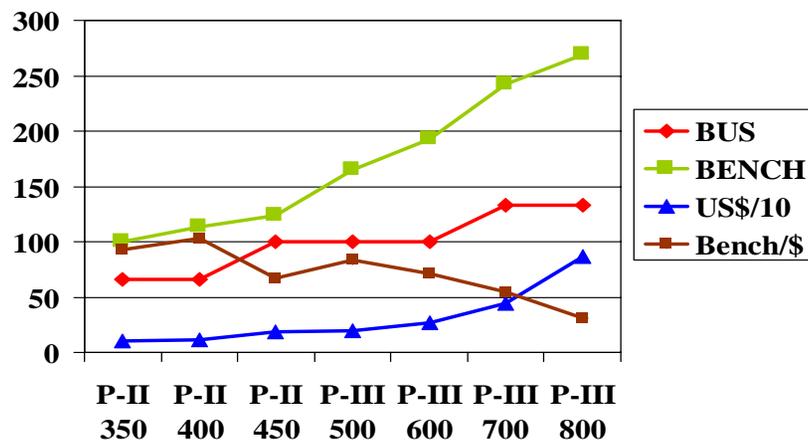
$$\sqrt[n]{\prod_{i=1}^n \text{Execution time ratio}_i}$$

- Não há, necessariamente, correspondência com o tempo de execução

Avaliação de Performance

- Venda é uma função da performance relativo à competição. Logo, espere investimentos altos em melhoria da performance do produto dado pela melhoria da performance dos *benchmarks*
- Bons produtos aparecem quando:
 - Bons *benchmarks*
 - Boas maneiras de sumarizar a performance
- Se o *benchmark* ou sumário são inadequados, então melhor o produto para melhorar vendas sempre ganha de outras opções
Ex. Tempo é a única medida real de performance!
- E quanto ao custo?

Avaliação de Benchmarks / Preços de CPUs



<http://www.cpuscorecard.com>