

Arquitectura de Computadores II



3º Ano

Multiprocessadores

João Luís Ferreira Sobral
Departamento do Informática
Universidade do Minho



Maio 2003

Multiprocessadores

- Utilização de vários processadores numa arquitectura
=> aumento do desempenho
- N processadores => ganho de N vezes?
 - capacidade de processamento superior a qualquer sistema uniprocessador
- Escaláveis: o desempenho do sistema pode ser melhorado adicionando mais unidades de processamento.
- Populares em servidores de ficheiros e de bases de dados
- Utilizados para executar uma só aplicação (p. ex. simulação do tempo) ou para suportar a carga de vários utilizadores (p. ex. servidores Web)
- Classificação dos sistemas (Taxonomia de Flynn)
 - Classificação de acordo com o número de fluxos de instruções e de dados processados (Exemplo para MIPS)

1. **SISD - Single Instruction Single Data** – Um só fluxo de instruções e de dados (processadores convencionais)

IF	ID	EX	MEM	WB
----	----	----	-----	----

2. **SIMD - Single Instruction Multiple Data** – Um só fluxo de instruções processa vários fluxos de dados

		EX	MEM	WB
IF	ID	EX	MEM	WB
		EX	MEM	WB

3. **MIMD - Multiple Instruction Multiple Data** – Vários fluxos de instruções processam vários fluxos de dados

IF	ID	EX	MEM	WB
----	----	----	-----	----

IF	ID	EX	MEM	WB
----	----	----	-----	----

IF	ID	EX	MEM	WB
----	----	----	-----	----

Multiprocessadores

● MIMD

- Tem prevalecido por ser mais flexível e poder ser desenvolvido com base em processadores comerciais
- O hardware pode suportar um modelo de **memória partilhada** ou de **memória distribuída**

● MIMD com Memória partilhada centralizada:

- um só espaço de endereçamento partilhado por todos os processadores
- primitivas para sincronizar os acesso às zonas de memória partilhada
- velocidade de acesso à memória pode ser uniforme (UMA)

● MIMD com Memória distribuída:

- cada processador possui o seu espaço de endereçamento
- existem primitivas para o envio de informação entre processadores

● Sistemas híbridos de memória partilhada e distribuída

- velocidade de acesso à memória não uniforme (NUMA) variando em função do endereço acedido.

● Vantagens de memória distribuída:

- A largura de banda de acesso à memória escala mais facilmente
- A latência dos acessos à memória local é menor

● Desvantagens de memória distribuída:

- A comunicação entre máquina é mais complexa e a latência de comunicação entre máquinas é superior

● É possível simular por SW um sistema de memória partilhada numa sistema de memória distribuída (*Virtual Shared Memory*)

Multiprocessadores

- Programação mais complexa que a dos sistemas uniprocessador:

- condicionada à obtenção de bons ganhos
=> forte envolvimento do programador
- complexidade de aplicações sequenciais + divisão da aplicação em tarefas paralelas + identificação das interacções entre tarefas.
- ganho condicionado pela fracção sequencial da aplicação

Se s for a fracção sequencial do algoritmo, então $1/s$ é o ganho máximo que pode ser obtido com essa aplicação:

Exemplo:

Se 10% ($s=0,1$) da aplicação for sequencial qual o ganho máximo que pode ser obtido?

$$ganho_p = \frac{1}{\frac{0,9}{p} + 0,1} \xrightarrow{p \rightarrow \infty} 10$$

Se for utilizado um número *infinito* de processadores o ganho é 10 x! (8,5x c/ 50 processadores, 9,2x c/ 100 processadores)

- impacto negativo no desempenho da aplicação da latência dos acessos a memória remota

Exemplo:

acesso a uma memória remota = 2000 ns
 $T_{cc} = 10$ ns
acessos remotos = 0,5%
CPI sem acessos remotos = 1

Qual o CPI se forem considerados os acessos remotos?

$CPI = CPI_{Base} + \% \text{ acessos remotos} \times \text{custo de cada acesso}$

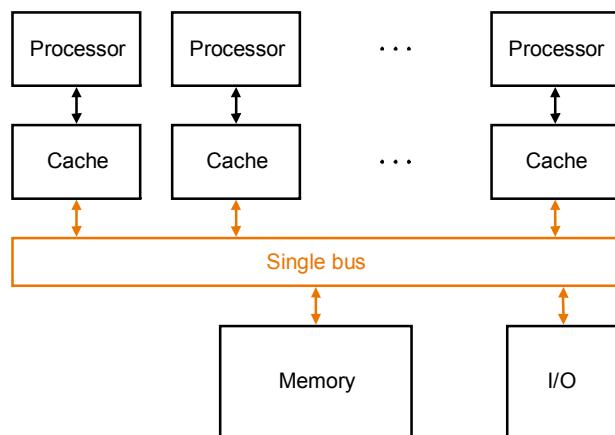
$$CPI = 1,0 + 0,05 \times 2000/10 = 2,0$$

Uma máquina apenas com acessos locais é 2x mais rápida!

Multiprocessadores

- Conectados por um único barramento
(arquitecturas com memória partilhada centralizada):

- Vários processadores partilham um barramento de acesso à memória
- As *caches* de cada processador contribuem para reduzir o tráfego no barramento e a latência dos acessos à memória
- um valor pode estar replicado em vários sítios => são necessários mecanismos para assegurar a coesão entre as *caches* dos vários processadores e a memória
- A largura de banda de acesso à memória é partilhada pelos vários processadores => limitação à escalabilidade deste tipo de arquitectura



- Exemplos (1997):

Nome	Nº máx. de CPU	CPU	Freq. Relógio	Memória Máxima	Débito de comunicação
Compaq Proliant 5000	4	Pentium Pro	200 MHz	2,0 GB	540 MB/s
Digital AlphaServer 8400	12	Alpha 21164	440 MHz	28,6 GB	2150 MB/s
HP 9000 k460	4	PA-8000	180 MHz	4,0 GB	960 MB/s
IBM RS/6000 R40	8	PowerPC 604	112 MHz	2,0 GB	1800 MB/s
SGI Power Challenge	36	MIPS R10000	195 MHz	16,3 GB	1200 MB/s
SUN Enterprise 6000	30	UltraSPARC 1	167 MHz	30,7 GB	2600 MB/s

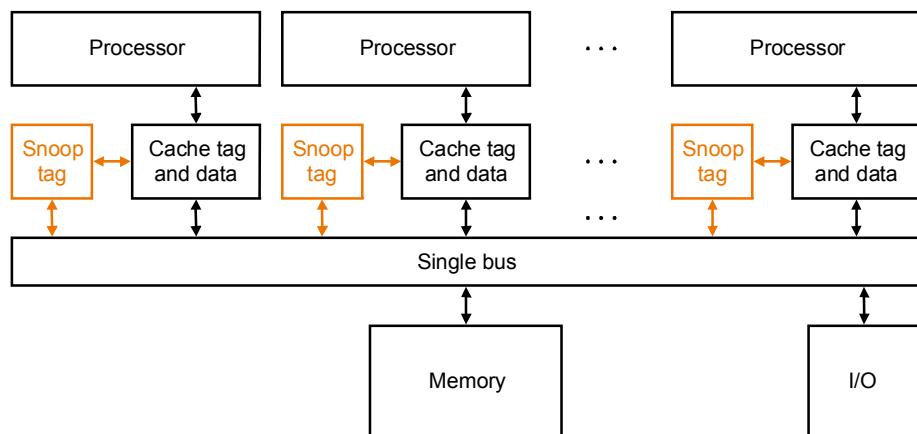
- Exemplos (2002 – Boards para Intel/AMD):

Nome	Nº CPU	CPU	Freq. Rel.	Mem. Max	BW Memória	Outros
Tyan Thunder K7X	2	AMD Athlon MPX	1,73 GHz	4,0 GB	2100 MB/s	2 x 64 bit PCI Dual Ultra 160 SCSI
Tyan Thunder i860	2	Intel Pentium 4 Xeon	2,20 GHz	4,0 GB	3200 MB/s	2 x 64 bit PCI Dual Ultra 160 SCSI
Tyan Thunder i7500	2	Intel Pentium 4 Xeon	2,20 GHz	12,0 GB	3200 MB/s	2 x 64 bit PCI-X Dual Ultra 160 SCSI

Multiprocessadores

• Coesão de *caches*

- O facto de os processadores poderem utilizar protocolos de *cache writeback*, pode originar valores inconsistentes entre a *cache* e a memória principal partilhada com outros processadores.
- Os protocolos que asseguram a coesão entre os valores das *caches* dos vários processadores e da memória central são designados por **protocolos de coesão de *caches***
- **Coesão baseada em *Snooping*** – cada bloco da *cache* contém informação indicando se é partilhado. O processador monitoriza a actividade de barramento verificando se esta envolve um bloco local:
 - ***Write-invalidate***: Quando um processador escreve um valor na *cache* todas as outras cópias são tornadas inválidas através de um sinal do barramento.
 - ***Write-update***: Quando um processador escreve um valor na *cache* todas as outras cópias são também actualizadas.

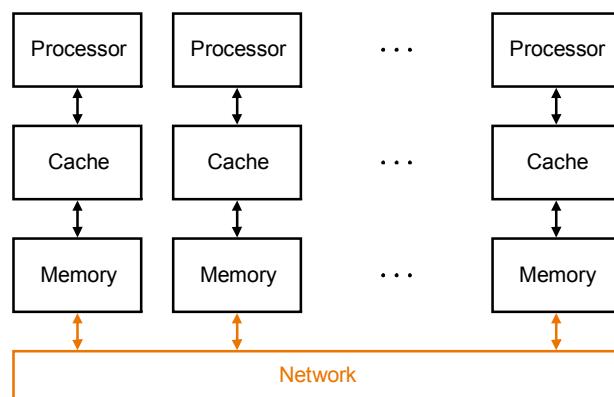


- *write-invalidate* tende a gerar menos tráfego no barramento, uma vez várias escritas numa mesma linha da *cache* não geram tráfego.
- *write-update* tende a reduzir a latência nos acessos, porque as cópias estão sempre actualizadas
- A generalidade dos sistemas comerciais utiliza o esquema *write-invalidate*.
- As linhas de *cache* de elevada dimensão dão origem ao problema da falsa partilha:
 - variáveis utilizadas por processadores diferentes e colocadas num mesmo bloco => o bloco é invalidado pelos dois processadores

Multiprocessadores

• Conectados por uma rede de interligação

- Os sistemas interligados por um barramento tendem a limitar o número de processadores que efectivamente podem ser ligados
- A alternativa reside na utilização de uma rede dedicada à interligação dos vários processadores, possuindo cada processador a sua memória dedicada



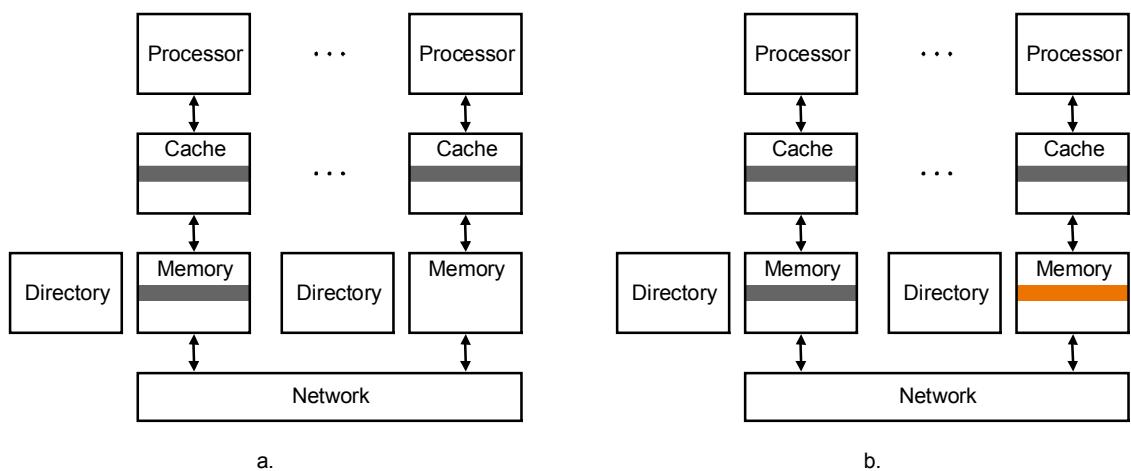
- Exemplos (1997):

Nome	Nº máx. de CPUs	CPU	Freq. Rel.	Memória Máxima	Largura de Banda de comunicação	Tipo de Nodos	Topologia
Cray Research T3E	2048	Alpha 21164	450 MHz	524 GB	1200 MB/s	4-way	3-D torus
HP/Convex Exemplar X-class	64	PA-8000	180 MHz	65 GB	980 MB/s	2-way	8-way crossbar + anel
Sequent NUMA Q	32	Pentium Pro	200 MHz	131 GB	1024 MB/s	4-way	anel
SGI Origin 2000	128	MIPS R10000	195 MHZ	131 GB	800 MB/s	2-way	6-cube
Sun Enterprise 10000	64	Ultra SPARC 1	250 MHz	65 GB	1699 MB/s	4-way	16-way crossbar

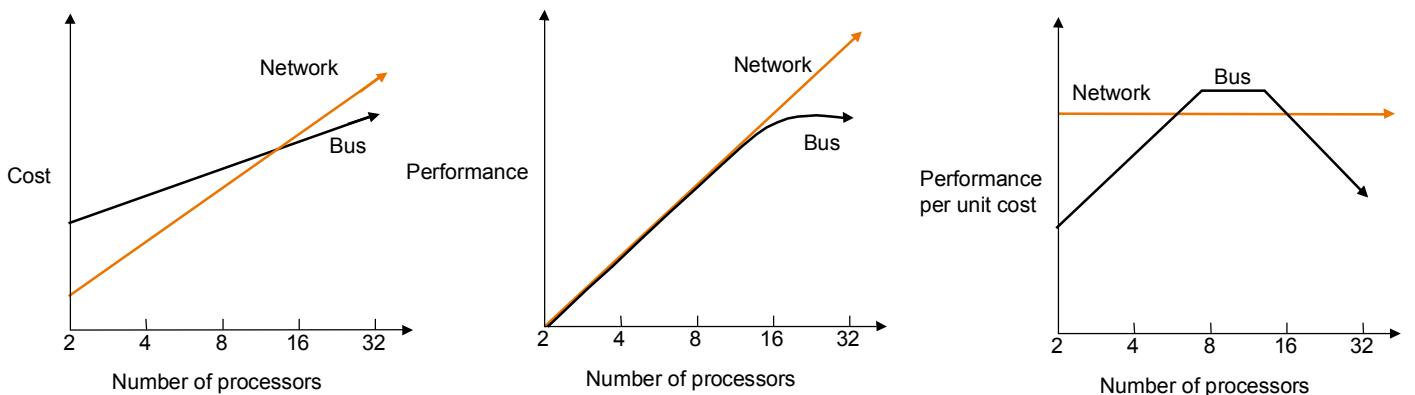
Multiprocessadores

• Conectados por uma rede de interligação Implementação de um endereçamento partilhado

- A implementação mais simples é não fornecer HW para suporte a coesão de *cache* => a cache não é utilizada em acessos remotos
- **Serviço de directoria** que mantém a informação sobre a partilha de cada bloco local de memória:
 - A directoria é distribuída pelos processadores
 - Cada entrada indica os processadores que contêm uma cópia do bloco de memória
 - A invalidação dos blocos em *caches* é efectuada através de mensagens, com base em informação na directoria



• Comparação entre os sistemas conectados por um barramento e os sistemas conectados por uma rede de interligação



Multiprocessadores

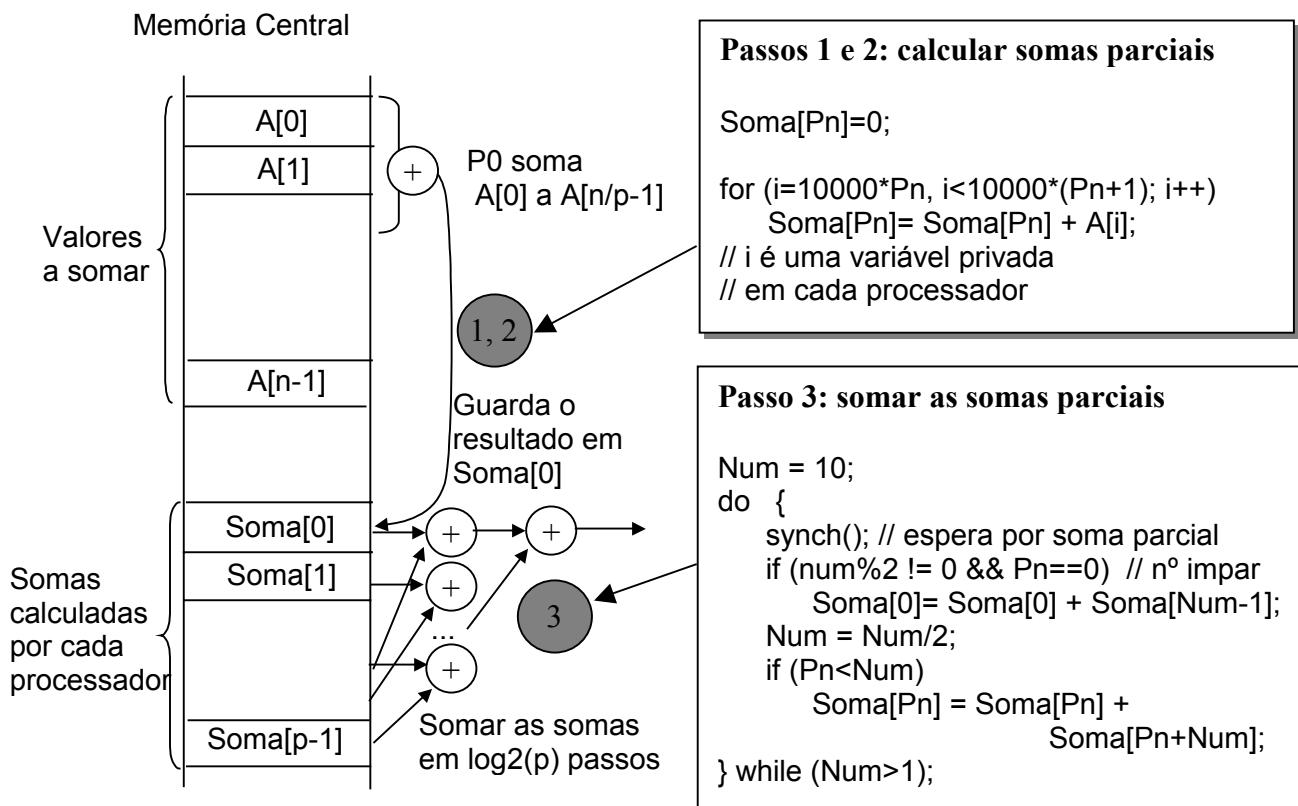
• Programação de sistemas multiprocessadores com memória partilhada

- Os processadores comunicam através da memória, efectuando *load* e *store*
- As primitivas de sincronização asseguram que os acessos a regiões críticas são efectuados com exclusividade

• Somar uma lista de números

1. Dividir os elementos da lista pelos processadores disponíveis
2. Efectuar a soma parcial em cada processador
3. Efectuar a soma das várias somas parciais

• Exemplo: somar 100000 números com 10 processadores:

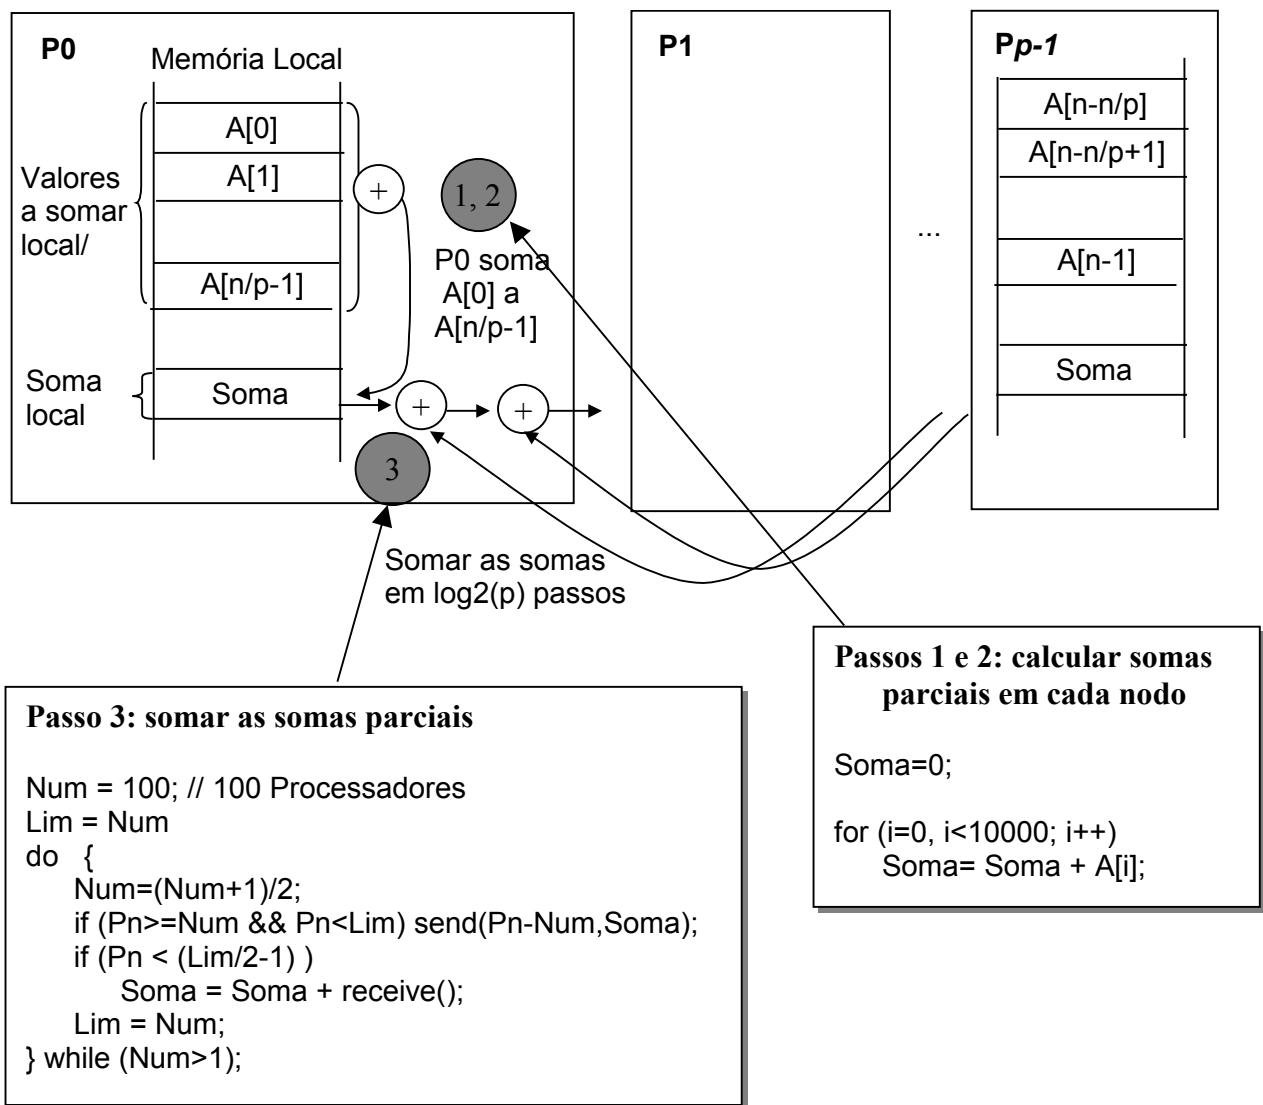


Multiprocessadores

- Programação de sistemas multiprocessadores com memória distribuída

- Os processadores comunicam através da memória de passagem de mensagens (send, receive)

- Exemplo: somar 100000 números com 100 processadores:



- A principal diferença reside no passo 3, porque as somas parciais se encontram distribuídas por vários processadores, sendo necessário enviar mensagens entre processadores com a soma parcial
- Adicionalmente, é necessário uma fase antes dos passos 1,2 para distribuir os valores a somar pelas memórias de cada nodo

Multiprocessadores

• Clusters de máquinas

- Constituídos pode HW “normal”, interligados por uma rede de alta velocidade
- Cada nodo de processamento pode ser uma máquina de memória partilhada com vários processadores
- Cada nodo possui uma cópia do SO
- Alta disponibilidade: quando falha uma máquina basta substituí-la por outra
- Custos de administração na ordem do número de máquinas
- Exemplos (1997)

Nome	Número máximo de processadores	Processador	Freq. Relógio	Memória Máxima	Largura de Banda de comunicação	Nodos	Máximo de nodos
HP 9000 EPS21	64	PA-8000	180 MHz	65 GB	532 MB/s	4-way	16
IBM RS/6000 HACMP R 40	16	PowerPC 604	112 MHz	4 GB	12 MB/s	8-way	2
IBM RS/6000 SP2	512	Power2 SC	135 MHz	1000 GB	150 MB/s	16-way	32
Sun Enterprise Cluster 6000 HA	60	Ultra SPARC 1	167 MHz	61 GB	100 MB/s	30-way	2
Tandem NonStop Himalaya S70000	4096	MIPS R10000	195 MHz	1000 GB	40 MB/s	16 way	256

- Exemplo (Cluster investigação da Universidade do Minho - 1999)

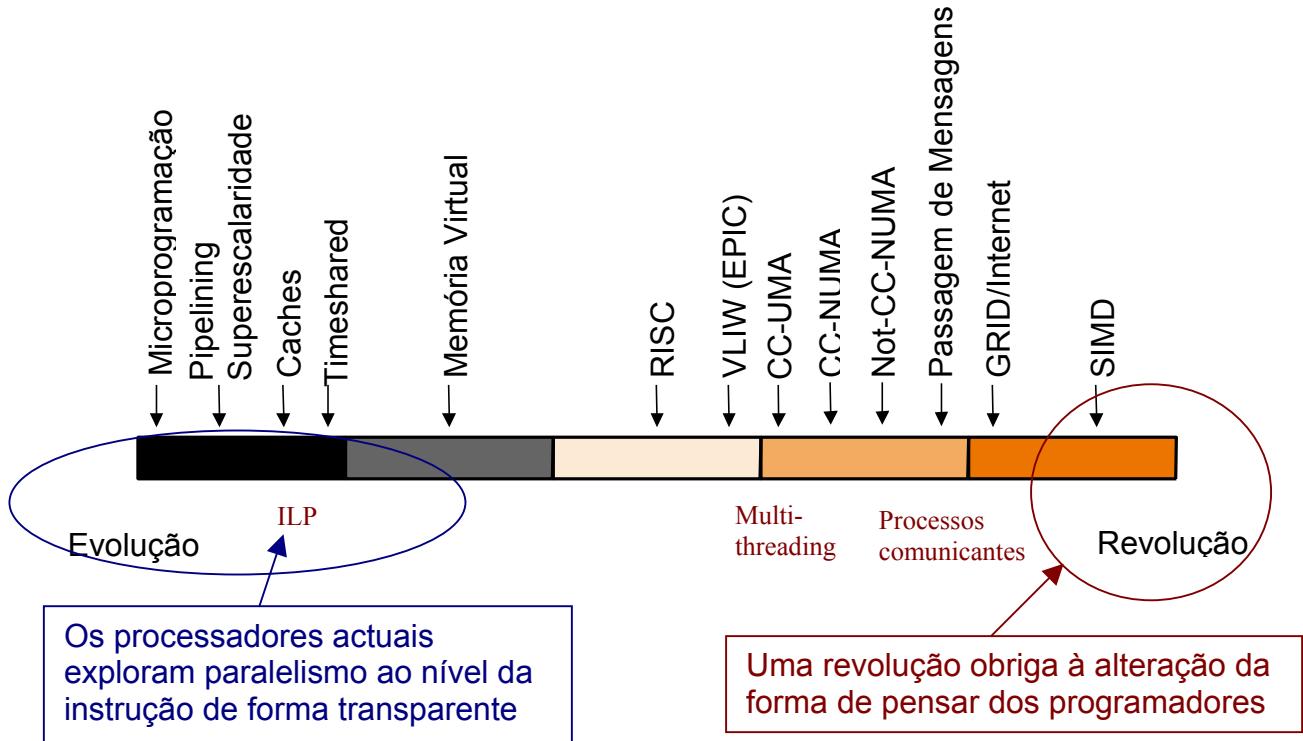
Nº máx. CPU	Processador	Freq. Relógio	Memória Máxima	Largura de Banda de comunicação	Nodos	Máximo de nodos
16	Pentium III	400 MHz	6,1 GB	150 MB/s (1,2 Gbit/s)	2-way	8

Futuro da Arquitectura de Computadores

- TOP 500 (os mais potentes computadores do mundo www.top500.org)

Rank	Manufacturer Computer/Procs	R _{max} R _{peak}	Installation Site Country/Year	Computer Family Computer Type
1	NEC Earth-Simulator/ 5120	35860.00 40960.00	Earth Simulator Center Japan/2002	NEC Vector SX6
2	Hewlett-Packard ASCI Q - AlphaServer SC ES45/1.25 GHz/ 4096	7727.00 10240.00	Los Alamos National Laboratory USA/2002	Compaq AlphaServer Al.Se.-Cluster
3	Hewlett-Packard ASCI Q - AlphaServer SC ES45/1.25 GHz/ 4096	7727.00 10240.00	Los Alamos National Laboratory USA/2002	Compaq AlphaServer Al.Se.-Cluster
4	IBM ASCI White, SP Power3 375 MHz/ 8192	7226.00 12288.00	Lawrence Livermore National Laboratory USA/2000	IBM SP SP Power3 375 MHz high node
5	Linux NetworX MCR Linux Cluster Xeon 2.4 GHz - Quadrics/ 2304	5694.00 11060.00	Lawrence Livermore National Laboratory USA/2002	NOW - Intel NOW Cluster - Intel
...
7	Hewlett-Packard AlphaServer SC ES45/1 GHz/ 2560	3980.00 5120.00	Commissariat à l'Energie Atomique France/2001	Compaq AlphaServer Al.Se.-Cluster
...
161	IBM SP Power3 375 MHz/ 380	393.00 570.00	EDINFOR Portugal/2002	IBM SP SP Power3 375 MHz

- Evolução versus revolução



Bibliografia

Matéria	Bibliografia
Introdução aos multiprocessadores	COD2e 9.1 e 9.2
Multiprocessadores conectados por um barramento	COD2e 9.3
Multiprocessadores conectados por uma rede e Clusters	COD2e 9.4, 9.5, 9.7, 9.8, 9.9 e 9.10

COD2e *Computer Organization and Design: the hardware/software interface*, D. Patterson and J. Hennessy, Morgan Kaufmann, 2^a edição, 1998.

CA3e *Computer Architecture: A Quantitative Approach*, J. Hennessy and D. Patterson, Morgan Kaufmann, 3^a edição, 2002.