


Survey on NUCA:

• Non-Uniform Cache Architecture

Marco A. Z. Alves


Philippe O.A. Navaux




Introdução

- Aumento no Nível de Integração: Chips 65, 45, 32nm
- ☺ Crescimento no poder de criação (super lei de Moore)
- ☹ Wire-Delay, Consumo de Potência (limites físicos)


Transistores por Microprocessador



Frequência do Microprocessador




MEMÓRIAS CACHE UNIFORMES




Memórias Cache Uniformes

- Estratégias de Mapeamento de Dados
 - Mapeamento direto (barato)
 - Associativo por Conjunto (médio)
 - Totalmente Associativo (caro)


(a) Diretamente mapeada



(b) Associativa por Conjunto




(c) Totalmente Associativa



Memórias Cache Uniformes

- Armazenamento de Dados


- Muitos Endereço Base
- Tag de identificação
- Bit Sujo (início do sistema)



Memórias Cache Uniformes

- Localizando um Bloco na Memória Cache

- Endereço é enviado
- Se sinalizar HIT
 - Dados disponíveis
- Se sinalizar MISS
 - Pesquisa em outro nível



Memórias Cache Uniformes

- Estrutura interna dos arrays da memória cache

- Array de Tags
- Array de Dados

- Decoder


- Recebe endereço
- Ativa os vetores

- Sense Amps

- Detecta os valores


- Comparators

- Mux ativa saída do conjunto




Memórias Cache Uniformes

- Organização dos sub-blocos
 - Layout H-Tree
 - Área total deve considerar blocos e interconexão
 - Tempo de acesso único
 - Problemas:
 - Latência
 - Largura de Banda
 - Área
 - Interconexão
 - Etc.



MEMÓRIAS CACHE NÃO-UNIFORMES




Memórias Cache Não-Uniformes


- Origem das NUCA
 - Tempo de acesso a grandes memórias cache não apropriadas
 - Problemas de atraso do fio entre outros problemas físicos
 - Isolamento dos blocos NUCA podem ser convenientes para futuras tecnologias de integração
- Funcionamento Básico
 - Blocos próximos ao processador vão ser acessados mais rapidamente

Memórias Cache Não-Uniformes


- Tipos básicos de NUCA com típicos tempos de acesso
 - A) Memória UCA
 - B) Memória UCA com níveis 2 e 3
 - C) NUCA estática com barramento
 - D) NUCA estática com NoC
 - E) NUCA dinâmica com NoC




(a) UCA




(b) ML-UCA



(c) S-NUCA-1




(d) S-NUCA-2



(e) D-NUCA


Memórias Cache Não-Uniformes

- Interconexão dos Blocos NUCA
 - Estrutura da S-NUCA I
 - Barramentos conectando os bancos



Memórias Cache Não-Uniformes


- Interconexão dos Blocos NUCA
 - Estrutura S-NUCA 2 e D-NUCA
 - Utiliza redes de interconexão intra-chip




Memórias Cache Não-Uniformes

- Políticas de Mapeamento de Blocos
 - A) Mapeamento Simples
 - B) Mapeamento balanceado
 - C) Mapeamento Compartilhado


(a) Simple Mapping



(b) Fair Mapping



(c) Shared Mapping




Memórias Cache Não-Uniformes

- Mapeamento Simples

- Colunas são conjuntos associativos
- Cada Linha é uma via do conjunto associativo
- ☹ Linhas podem não corresponder ao número de vias associativas
- ☹ Tempo de acesso as vias diferente dentro de um mesmo conjunto associativo


(a) Simple Mapping



Memórias Cache Não-Uniformes

- Mapeamento Balanceado
 - Tenta equalizar o tempo de acesso aos conjuntos associativos
 - 😊 Tempo de acesso equilibrado
 - ☹️ Sobrecusto de complexidade adicional
 - ☹️ Sobrecusto de roteamento


(h) Fair Mapping



Memórias Cache Não-Uniformes

- Mapeamento Compartilhado
 - Compartilha os bancos próximos ao processador
 - 😊 Provê rápido tempo de acesso a todos conjuntos
 - ☹️ Complexidade do mapeamento

(c) Shared Mapping




Memórias Cache Não-Uniformes

- Busca de Dados em NUCA

- Incremental Search

- 😊 Baixo consumo


- ☹ Baixo desempenho



- Multicast Search


- 😊 Alto Desempenho

- ☹ Alto Consumo




- Limited Multicast

- Dividido em sub-grupos de procura paralela




- Partitioned Multicast

- Dividido em sub-grupos paralelos




Memórias Cache Não-Uniformes

- Migração de Dados em Memórias NUCA dinâmicas
 - Tenta maximizar os acessos a bancos próximos, de menor latência
 - LRU – Bancos próximos com MRU (Dados Usados mais recentemente)
 - ☹️ Grandes movimentações de dados
 - Generational Promotion
 - Remove a Vítima ou Troca de Lugar com a Vítima



Memórias Cache Não-Uniformes

- Memórias NUCA em processadores Multi-Core
 - Como manter coerente ?
 - Como evitar conflitos ?
 - Como organizar ?
 - Como mapear ?



Considerações Finais

- Problemas físicos estão cada vez mais claros
- Utilização de many-core parece ser uma solução
- Dúvidas:
 - Como trocar informações ?
 - Como prover dados ?
 - Como programar ?
 - Como reduzir o consumo ?
 - Como manter crescimento do desempenho ?
- Soluções de suporte a todos os núcleos são necessárias
 - Redes de Interconexão Intra-Chip - NoC
 - Memórias Cache Não-Uniforme - NUCA

Memórias NUCA

Non-Uniform Cache Architecture

Marco Antonio Zanata Alves

marco.zanata@inf.ufrgs.br

Take care of all your memories.
For you cannot relive them.



Physical Area Analysis

Exp.	Organization	Total Logical Size	Slice Logical Size	Associativity	Line Size	Normalized Physical Area	Latency	Penalty	Normalized Cache Misses
1	1Core/L2	32MB	1MB	8 Ways S.A.	64 Bytes	100%	1.6 ns	4 Cycles	100%
1	2Cores/L2	16MB	1MB	8 Ways S.A.	64 Bytes	50%	1.6 ns	4 Cycles	112%
2	2Cores/L2	32MB	2MB	8 Ways S.A.	64 Bytes	78%	2.1 ns	5 Cycles	89%
3	2Cores/L2	16MB	1MB	16 Ways S.A.	64 Bytes	50%	2.6 ns	6 Cycles	108%
4	2Cores/L2	16MB	1MB	8 Ways S.A.	128 Bytes	73%	2.6 ns	6 Cycles	68%

- ☹ Increase on physical area size for same cache size.
- ☹ Increase on data access latency
- 😊 Balance between data access latency and reduction on cache misses (Efficient Cache)

Global Conclusions

- The traditional techniques as increase on cache size, associativity, and line size did not work:
 - Cache size cannot increase the performance.
 - High associativity cannot increase the performance.
- Any change in cache parameters increase the latency.
- Need a good trade-off between cache latency and cache misses.
- Future works:
 - Developing non-uniform cache architecture (NUCA) considering our results, in order to hide high latency problems.