

WSPPD'09

Em Direção a um Escalonador por Roubo de Tarefas na Criação de Tarefas por Divisão & Conquista com MPI-2

Stéfano **Mór**
Nicolas **Maillard**

sdkmor@inf.ufrgs.br
nicolas@inf.ufrgs.br


Sumário

- (1) Motivação
- (2) Roubo de Tarefas Aleatorizado
- (3) Adaptando para Memória Distribuída
- (4) Conclusões

Motivação

cluster

- memória **distribuída**
- troca de mensagens
- barramento rápido
- MPI
- visão lógica "all-to-all"
- conectividade física varia



Motivação

desafio: aproveitar ao máximo o hardware paralelo

foco atual: melhorar o escalonamento de processos MPI

Motivação

escalonamento MPI


MPI 1 :: estático :: tarefa=processo



Motivação

escalonamento MPI

MPI 2 :: estático & dinâmico :: processo = tarefa :: **“Task Spawning”**
Estado da Arte



Motivação

processor-aware: programador decide em qual processador alocar nova tarefa; **número de processadores** passados como **parâmetro**.


processor-oblivious: tarefa é alocada pelo middleware; **não importa** ao programador o **número de processadores**.

Contribuição

idéia central: usar o escalonamento por roubo de tarefas (projetado para memória compartilhada) em um cenário de memória distribuída com MPI

limitação: escalonamento eficiente para computação totalmente estrita (próximo slide)
e.g., Divisão & Conquista (nosso foco)

Roubo de Tarefas Aleatorizado




Roubo de Tarefas Aleatorizado

4 situações

uma *deque* por processador :: em cada processador

thread α faz spawn
da thread β



$\alpha \rightarrow \text{spawn}(\beta)$

α é empilhada e β
ganha o processador



β




Roubo de Tarefas Aleatorizado


4 situações

uma *deque* por processador :: em cada processador

thread α está executando e
thread β é habilitada



β vai para o fundo
da *deque*




Roubo de Tarefas Aleatorizado


4 situações

uma *deque* por processador :: em cada processador

thread α está executando e morre.



se há thread β no fundo da *deque*, ela passa a executar.




Roubo de Tarefas Aleatorizado


4 situações

uma *deque* por processador :: em cada processador

thread α está executando e morre.



se não há thread no fundo da *deque*, ela rouba tarefas do topo de outra *deque*.



Adaptando para Memória Distribuída

roubo de tarefas


problemas com memória distribuída

- 4 problemas cruciais
 - problema do spawn (+/-)
 - problema da sincronização (✓)
 - problema de acesso concorrente à memória(✓)
 - problema de checkpointing(✓)

Adaptando para Memória Distribuída

roubo de tarefas

problema do spawn



Adaptando para Memória Distribuída

roubo de tarefas

problema da sincronização

- roubo de tarefas deve ser assíncrono em relação à vítima
 - nova thread que atende roubos
 - memória compartilhada com a thread que faz o processamento em si
 - não precisa parar de processar
 - apenas em máquinas SMT

Adaptando para Memória Distribuída

roubo de tarefas


problema de acesso concorrente à memória

- thread de processamento e thread de atendimento devem ter acesso mutuamente exclusivo sobre a *deque*
 - o mesmo vale para tentativas de roubo sobre a mesma *deque*
 - implementação do protocolo THE
 - criação de uma nova thread de atendimento para cada roubo
 - somente funciona com máquina SMT arbitrária

Adaptando para Memória Distribuída

roubo de tarefas

problema do checkpointing



Conclusões

2 perguntas

questões em aberto

- existe equivalência entre o DAG de memória compartilhada e o DAG de memória distribuída?
 - *send/receive* bloqueante afeta a eficiência do RSWA?
- é possível implementar o RSWA de maneira eficiente em uma topologia do tipo anel (MPD)?

EOF

Agradecimentos ao CNPq

Obrigado!

Dúvidas?

SEMAC'09

Em Direção a um Escalonador por Roubo de Tarefas na Criação de Tarefas por Divisão & Conquista com MPI-2

Stéfano **Mór**
Nicolas **Maillard**

sdkmor@inf.ufrgs.br
nicolas@inf.ufrgs.br