

Online Mapping of MPI-2 Tasks to Processes and Threads

João Vicente F. Lima

Orientador: Prof. Dr. Nicolas Maillard

{joao.lima,nicolas}@inf.ufrgs.br

Universidade Federal do Rio Grande do Sul (UFRGS)

21 de agosto de 2009



Roteiro da apresentação

- 1 Introdução
- 2 Contexto
- 3 Estado da Arte
- 4 Proposta - libSpawn
- 5 Resultados
- 6 Conclusão

Roteiro da apresentação

- 1 Introdução
- 2 Contexto
- 3 Estado da Arte
- 4 Proposta - libSpawn
- 5 Resultados
- 6 Conclusão

Introdução

- Demanda crescente por desempenho ao longo dos anos
- No *hardware*:
 - ▶ arquiteturas vetoriais SIMD (*Single Instruction Multiple Data*)
 - ▶ sistemas MPPs (*Massively Parallel Processor*)
 - ▶ NOW (*Network of Workstations*)
 - ▶ *clusters* SMP (*Symmetric multiprocessor*)
 - ▶ Grades
- Mais recentemente:
 - ▶ *clusters* SMP *multi-core* (*many-core*)
 - ▶ *cluster of clusters*
- Mas, o desempenho não depende somente da arquitetura
- Um algoritmo paralelo também é decisivo

Roteiro da apresentação

1 Introdução

2 Contexto

3 Estado da Arte



4 Proposta - libSpawn

5 Resultados

6 Conclusão

Contexto



Algoritmos Paralelos Dinâmicos



- O algoritmo, por sua vez, pode apresentar irregularidades

Contexto



Algoritmos Paralelos Dinâmicos



- O algoritmo, por sua vez, pode apresentar irregularidades
- Possível solução: um **algoritmo dinâmico**
 - ▶ prever a carga de tarefas com técnicas de programação
- Exemplos de técnicas: *Mestre/Escravo*, *Divisão-e-Conquista*
 - ▶ *Mestre/Escravo* é centralizada, ideal para problemas pequenos
 - ▶ *Divisão-e-Conquista* não determina o número de tarefas

Contexto

Algoritmos Paralelos Dinâmicos



- O algoritmo, por sua vez, pode apresentar irregularidades
- Possível solução: um **algoritmo dinâmico**
 - ▶ prever a carga de tarefas com técnicas de programação
- Exemplos de técnicas: *Mestre/Escravo*, *Divisão-e-Conquista*
 - ▶ *Mestre/Escravo* é centralizada, ideal para problemas pequenos
 - ▶ *Divisão-e-Conquista* não determina o número de tarefas
- O desempenho (plataforma/algoritmo) depende da **granularidade**

Contexto

Granularidade

- Razão entre processamento e comunicação
- Considera aspectos mais práticos (de plataforma)
 - ▶ recursos disponíveis
 - ▶ carga dos recursos
 - ▶ localidade
 - ▶ custos em comunicação e criação de tarefas
- Implementar um controle não é trivial, porque deve-se:
 - ▶ **descrever tarefa** - abstrata, processo ou *thread*
 - ▶ **controlar localidade** - reduzir custos de comunicação
 - ▶ **considerar carga de trabalho** - distribuir entre recursos
 - ▶ **controlar recursos** - inserção/remoção em tempo de execução

Contexto


Granularidade

- Razão entre processamento e comunicação
- Considera aspectos mais práticos (de plataforma)
 - ▶ recursos disponíveis
 - ▶ carga dos recursos
 - ▶ localidade
 - ▶ custos em comunicação e criação de tarefas
- Implementar um controle não é trivial, porque deve-se:
 - ▶ **descrever tarefa** - abstrata, processo ou *thread*
 - ▶ **controlar localidade** - reduzir custos de comunicação
 - ▶ **considerar carga de trabalho** - distribuir entre recursos
 - ▶ **controlar recursos** - inserção/remoção em tempo de execução

Um ambiente de programação com suporte ao controle de granularidade simplifica a programação de algoritmos dinâmicos

Contexto

Granularidade



Roteiro da apresentação

1 Introdução

2 Contexto

3 Estado da Arte

4 Proposta - libSpawn

5 Resultados

6 Conclusão

Estado da Arte

Ambientes de Programação

- Memória Compartilhada: **Cilk**, **OpenMP** e **Intel®TBB**
 - ▶ **Cilk**: aplicações D&C para arquiteturas SMP
 - ▶ **OpenMP**: API com paralelismo de laços, dados e tarefas (3.0)
 - ▶ **Intel®TBB** : biblioteca C++ para arquiteturas *multi-core*
- Memória Distribuída: **Cilk-NOW**, **Satin**, **KAAPI**, **AMPI** e **MPI**
 - ▶ **Cilk-NOW**: versão distribuída do **Cilk**
 - ▶ **Satin**: aplicações D&C para grades em Java
 - ▶ **KAAPI**: aplicações *multi-thread* e distribuídas
 - ▶ **AMPI**: implementação MPI para balanceamento de carga
 - ▶ **MPI**: padrão em PAD na programação com troca de mensagens

Estado da Arte

Conclusão

- Conclusão sobre os ambientes:
 - ▶ suporte para plataformas específicas
 - ▶ interfaces extensas, pouco uso em PAD
 - ▶ sem dinamismo (**AMPI**)
- Em **MPI**:
 - ▶ a norma define **tarefas**, mas as implementações usam **processos pesados**
 - ▶ implementações sem controle de granularidade
 - ▶ depende do programador (`MPI_Comm_spawn`/`pthread_create`)

Roteiro da apresentação

- 1 Introdução
- 2 Contexto
- 3 Estado da Arte
- 4 Proposta - libSpawn**
- 5 Resultados
- 6 Conclusão

Investigar as vantagens no controle *online* de granularidade em programas MPI dinâmicos



- **libSpawn** - biblioteca C++ que implementa o controle
- O controle processo/*thread* é **online** e transparente
- Implementa a comunicação entre tarefas
 - ▶ MPI não identifica *threads*

Parâmetros

- **Cores da arquitetura** - *cores* disponíveis para execução
- **Carga de sistema** - avalia a carga de sistema em execução
- **Recursos de sistema** - limites de SO, como memória, descritores de arquivos, *threads*, ...




Proposta

Controle de Granularidade (1/6)




Proposta

Controle de Granularidade (2/6)




Proposta

Controle de Granularidade (3/6)




Proposta

Controle de Granularidade (4/6)




Proposta

Controle de Granularidade (5/6)



Proposta

Controle de Granularidade (6/6)



Proposta

Comunicação de Tarefas

- Soluciona impasses na comunicação com *threads*
- Classes especializadas de acordo com o tipo de tarefa (processo/*thread*)
- Suporta as funções de mensagens:
 - ▶ bloqueantes: `Send/Recv`
 - ▶ não bloqueantes: `Isend/Irecv`
- Mensagens são armazenadas no comunicador (`Comm`)
 - ▶ duas listas para mensagens `Send` e `Recv`
 - ▶ o comunicador controla as mensagens
- Comunicações em memória compartilhada

Proposta

Características de Granularidade

- **Descrição de tarefa**

- ▶ pode ser tanto um processo quanto uma *thread*

- **Localidade**

- ▶ aumenta quando cria novas *threads* localmente
- ▶ controla as comunicações entre tarefas

- **Carga de Trabalho**

- ▶ cada processo verifica a carga de sistema, para decidir entre processo/*thread*

- **Gerenciamento de recursos**

- ▶ depende da implementação MPI utilizada (MPICH2)
- ▶ recursos são os endereços contidos em *hostfile*

- **Criação de tarefas**

- ▶ reduz o custo com a criação de *threads*

Proposta

Limitações

- Um Spawn não gera tarefas híbridas (*threads* e processos)
- O Spawn não é coletivo (COMM_SELF)
- Variáveis globais podem ocasionar inconsistências
- Não suporta comunicações coletivas
- Sem gerenciamento de recursos
- A utilização de outras *threads* não foi testada

Roteiro da apresentação

- 1 Introdução
- 2 Contexto
- 3 Estado da Arte
- 4 Proposta - libSpawn
- 5 Resultados**
- 6 Conclusão

Resultados - Experimentos

- **Objetivo:** avaliar a proposta em relação a processos
- Quatro *benchmarks* sintéticos:
 - ▶ **Fibonacci**
 - ▶ **Mergesort**
 - ▶ N-Queens
 - ▶ Caixeiro Viajante (TSP)
- Plataforma: Grid'5000 (<http://www.grid5000.fr>)
 - ▶ convênio entre GPPD e INRIA como equipe associada
 - ▶ *sites* Toulouse, Sophia, Rennes
 - ▶ agregados com 2 CPUs Dual Core, 4 *cores* por nó
 - ▶ rede Gigabit Ethernet
 - ▶ 4GB de memória (Sophia), 8GB nas demais


Resultados - Gráficos Utilizados

- Dois gráficos são mostrados por experimento
 - ▶ facilitar a visualização devido à diferença de escala
- **Tempos libSpawn** : médias e simetria com *boxplot*
 - ▶ *quartile* inferior (Q1) - 25% menores que Q2
 - ▶ mediana (Q2)
 - ▶ *quartile* superior (Q3) - 25% maiores que Q2
 - ▶ *outliers* - resultados anômalos
 - ▶ linha inferior - $Q1 - 1,5 * IQR$
 - ▶ linha superior - $Q3 + 1,5 * IQR$
- **Tempos Processos X libSpawn**
 - ▶ médias da amostra
 - ▶ desvio padrão em linha vertical
- Tamanho das amostras: 20 execuções


Resultados - Fibonacci

- **Entrada:** 20
- **Recursos:** de 16 a 120 *cores*
- **Tarefas:** 13.529

Resultados - Fibonacci com libSpawn




Resultados - Fibonacci processos X libSpawn




Resultados - Mergesort

- **Entrada:** 2 milhões de números aleatórios (1)
- **Recursos:** de 8 a 120 *cores*
- **Tarefas:** 10.812

Resultados - Mergesort com libSpawn



Resultados - Mergesort processos X libSpawn



Resultados - Conclusão

- Os experimentos avaliam os custos, principalmente:
 - ▶ criação de tarefas
 - ▶ localidade
 - ▶ comunicação
- Ganhos significativos devido a:
 - ▶ redução em criação de tarefas (*threads*)
 - ▶ redução na comunicação
- Observações
 - ▶ ganhos menores no Mergesort devido ao formato MPMD
 - ▶ tempos anômalos devido à falta de escalonamento de tarefas
 - ▶ O pior tempo na libSpawn não é maior que o melhor caso com processos
- Em suma, o controle proporciona ganhos significativos

Roteiro da apresentação

- 1 Introdução
- 2 Contexto
- 3 Estado da Arte
- 4 Proposta - libSpawn
- 5 Resultados
- 6 Conclusão**

Conclusão

Conclusão

- O trabalho tratou de controlar a granularidade em MPI
- Esse controle se concretiza em uma biblioteca (libSpawn)
- Ganhos significativos com *benchmarks* sintéticos
- Redução na criação de tarefas e comunicação
- Tempos anômalos devido à falta de escalonamento (processo/*thread*)
- Trabalhos futuros:
 - ▶ escalonamento em dois níveis (*cores*/ nó)
 - ▶ novos experimentos com *benchmarks* dinâmicos
 - ▶ experimentos em diferentes plataformas (Grades, *cluster of clusters*)

Referências

- Forum, The MPI (1995). A Message-Passing Interface Standard. Technical Report CS-94-230, University of Tennessee, Knoxville, Tennessee.
- Forum, The MPI (1997). MPI-2: Extensions to the Message-Passing Interface. Technical Report CDA-9115428, University of Tennessee, Knoxville, Tennessee.
- Grama, A., Gupta, A., Karypis, G., and Kumar, V. (2003). *Introduction to Parallel Computing*. Addison-Wesley, 2th edition.
- Lima, J. V. F., Maillard, N. (2008). Controle de Granularidade com threads em Programas MPI Dinâmicos. *WSCAD'08 - Workshop em Sistemas Computacionais de Alto Desempenho*.
- Pezzi, G. P., Cera, M. C., Mathias, E. N., Maillard, N., and Navaux, P. O. A. (2006). Escalonamento Dinâmico de programas MPI-2 utilizando Divisão e Conquista. *WSCAD'06 - Workshop em Sistemas Computacionais de Alto Desempenho*, 7:71-78.
- Rünger, G. (2006). Parallel Programming Models for Irregular Algorithms. *Lecture Notes in Computational Science and Engineering - Parallel Algorithms and Cluster Computing*, 52:3-23.

Online Mapping of MPI-2 Tasks to Processes and Threads

João Vicente F. Lima

Orientador: Prof. Dr. Nicolas Maillard

{joao.lima,nicolas}@inf.ufrgs.br

Universidade Federal do Rio Grande do Sul (UFRGS)

21 de agosto de 2009



- **Descrição de tarefa**

- ▶ MPI é sempre um processo
- ▶ nos outros, a tarefa é abstrata e executa como *thread*

- **Localidade**

- ▶ Satin, KAAPI e AMPI aumentam a localidade
- ▶ MPI depende da implementação ou do programador (MPI_Comm_spawn/pthread_create)

- **Carga de trabalho**

- ▶ somente OpenMP e MPI dependem da implementação

- **Gerenciamento de recursos**


- ▶ o MPI não especifica, mas permite inclusão por cliente/servidor

- **Criação de tarefas**

- ▶ AMPI não suporta


Extra - Proposta

Controle de Granularidade



Extra - Proposta

Comunicação de Tarefas



Extra - Proposta

Comunicação de Tarefas

- **Comm** - armazena as listas de mensagens
- **Request** - pedido de comunicação
- **RequestTask** - métodos de comunicação entre *threads*
- **RequestProcess** - métodos de comunicação entre processos
- **RequestTaskContainer** - representa uma mensagem
- **MsgEnvelope** - descreve a identificação da mensagem

Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem bloqueante em Send

MPI2::Comm.Send(...)

```
1: void Send(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   request.Wait();  
8: }
```

Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem bloqueante em Send

MPI2::Comm.Send(...)

```
1: void Send(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   request.Wait();  
8: }
```

Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem bloqueante em Send

MPI2::Comm.Send(...)

```
1: void Send(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   request.Wait();  
8: }
```

Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem bloqueante em Send

MPI2::Comm.Send(...)

```
1: void Send(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   request.Wait();  
8: }
```

Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem bloqueante em Send

MPI2::Comm.Send(...)

```
1: void Send(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   request.Wait();  
8: }
```


Extra - Proposta

Comunicação de Tarefas

- Envio de mensagem não bloqueante em Isend


MPI2::Comm.Isend(...)

```
1: void Isend(...) {  
2:   Request *request;  
3:   if (isCommThreads())  
4:     request = new RequestTask(...);  
5:   else  
6:     request = new RequestProcess(...);  
7:   return *request;  
8: }
```


Extra - N-Queens

- **Entrada:** tabuleiro de 10 X 10
- **Recursos:** de 4 a 120 *cores*
- **Tarefas:** 34.814

Extra - N-Queens com libSpawn




Extra - N-Queens processos X libSpawn




Extra - TSP

- **Entrada:** 10 cidades
- **Recursos:** de 12 a 120 *cores*
- **Tarefas:** 31

Extra - TSP com libSpawn



Extra - TSP processos X libSpawn



Online Mapping of MPI-2 Tasks to Processes and Threads

João Vicente F. Lima

Orientador: Prof. Dr. Nicolas Maillard

{joao.lima,nicolas}@inf.ufrgs.br

Universidade Federal do Rio Grande do Sul (UFRGS)

21 de agosto de 2009

