

Aula 06

Paralelismo em CPU

Supercomputação



Prof. Lícia Sales Costa Lima

Insper

www.insper.edu.br

Recaptulando...

- Soluções de alto desempenho
- (1) Linguagem eficiente
- (2) Conhecimento do Hardware
- (3) Heurística Inteligente
- (4) Paralelismo

Hardware Importa!

Conhecer o hardware ajuda a tomar decisões para usar da melhor forma possível o recurso disponível





Figure 5-5. Loop Blocking Access Pattern

Busca heurística




Fonte: Wikipedia

Heurística Inteligente

- Definir a estratégia para trabalhar com a natureza do problema
- Pegar atalhos e ganhar tempo!
- Lembre-se, em HPC, tempo é o nosso recurso mais escasso!

Concorrência x Paralelismo




Paralelismo

- Consiste no uso de múltiplos processadores, simultaneamente, para resolver um problema
- Tem por objetivo o aumento do desempenho, i.e., a redução do tempo necessário para resolver um problema




Taxonomia de Flynn




Michael J. Flynn


- É uma forma de classificar computadores paralelos
- Proposta por Flynn, em 1972




Von Newmann



Pipeline




Array




Máquinas Paralelas
(SMP, clusters e NUMA)

Organizações dos processadores




Paralelismo de dados

A mesma operação é executada para todos os elementos de um conjunto de dados





Paralelismo de tarefas

Tarefas independentes são executadas em paralelo



Paralelismo






Discussão

- **Quanto mais paralelo melhor?**

Discussão



A photograph of a lightbulb sitting on a dark chalkboard. A silver pen lies horizontally at the top of the frame. Several white chalk marks, including a large circle and some lines, are visible on the board.

Discussão

- **Exemplo 1 – Supondo 8 cores**

```
vector<double> dados;  
vector<double> resultados;  
for (int i = 0; i < dados.size(); i++) {  
    resultados[i] = funcao_complexa(dados[i]);  
}
```

– Tempo total / 8



Discussão

- **Exemplo 2 – Supondo 8 cores**

```
vector<double> dados;  
vector<double> resultados;  
resultados[0] = 0;  
for (int i = 1; i < dados.size(); i++) {  
    resultados[i] = funcao_complexa(dados[i], resultados[i-1]);  
}
```

Complicou, Depende da iteração anterior </3



Discussão

- **Exemplo 3 – Supondo 8 cores**

```
vector<double> dados;  
vector<double> resultados1;  
vector<double> resultados2;  
resultados1[0] = resultados2[0] 0;  
for (int i = 1; i < dados.size(); i++) {  
    resultados1[i] = funcao_complexa(dados[i], resultados1[i-1]);  
    resultados2[i] = funcao_complexa2(dados[i], resultados2[i-1]);  
}
```

**Podemos calcular resultados1 e resultados2
paralelamente**

Paralelismo - Resumo

1. Paralelizar significa rodar código sem dependências simultaneamente
2. Paralelismo de dados: mesma tarefas, dados diferentes
3. Paralelismo de tarefas: dividimos uma tarefa em tarefas menores
4. Existem tarefas inerentemente sequenciais
5. Ganhos são limitados a partes do programa

OpenMP


Sintaxe, Principais
Conceitos



OpenMP

- Diretivas de compilação para paralelizar o código
- Fornece pragmas que permitem paralelizar código em ambientes multi-core
- Idealmente funciona com o mínimo de modificações no código sequencial.

OpenMP – Fork/Join



- can repeat, with differing thread counts

OpenMP - Sintaxe


```
// Arquivo interface da biblioteca OpenMP para C/C++
#include <omp.h>

// retorna o identificador da thread.
int omp_get_thread_num();

// indica o número de threads a executar na região paralela.
void omp_set_num_threads(int num_threads);

// retorna o número de threads que estão executando no momento.
int omp_get_num_threads();
```

```
#pragma omp parallel
#pragma omp for
for(i = 0; i < N; i++) a[i] = a[i] + b[i];
```



OpenMP - Sintaxe

Código sequencial

```
for(i = 0; i < N; i++)  
    a[i] = a[i] + b[i];
```

Região OpenMP parallel

```
#pragma omp parallel  
{  
    int id, i, Nthrds, istart, iend;  
    id = omp_get_thread_num();  
    Nthrds = omp_get_num_threads();  
    istart = id * N / Nthrds;  
    iend = (id+1) * N / Nthrds;  
    if(id == Nthrds-1) iend = N;  
    for(i = istart; i < iend; i++)  
        a[i] = a[i] + b[i];  
}
```

Região paralela OpenMP
com uma construção de
divisão de laço

```
#pragma omp parallel  
#pragma omp for  
for(i = 0; i < N; i++) a[i] = a[i] + b[i];
```

OpenMP - Scheduling

`#pragma omp for schedule(static)`



`#pragma omp for schedule(static,3)`



`#pragma omp for schedule(dynamic)`



`#pragma omp for schedule(dynamic,2)`



`#pragma omp for schedule(guided)`



`#pragma omp for schedule(guided,2)`



Pedindo Recursos ao SLURM

```
#!/bin/bash
#SBATCH --job-name=teste__openmp
#SBATCH --output=saida_%j.txt
#Sbatch --cpus-per-task=5 # 5 threads
#SBATCH --time=00:01:00
#SBATCH --partition=gpu
#SBATCH --mem=2G

# garante que o OpenMP use exatamente os recursos alocados pelo SLURM
export OMP_NUM_THREADS=${SLURM_CPUS_PER_TASK}

./seu_binario
```