SSC-0742
PROGRAMAÇÃO CONCORRENTE

Aula 04 – Técnicas de Desenvolvimento de Programas Paralelos – Parte 1

Prof. Jó Ueyama

Créditos

Os slides integrantes deste material foram construídos a partir dos conteúdos relacionados às referências bibliográficas descritas neste documento

Visão Geral da Aula de Hoje

1. Conceitos Básicos
2. Técnicas de Decomposição
3. Comunicação
4. Sincronização
5. Dependência de Dados
6. Balanceamento de Carga
7. Exercício e Leitura Recomendada

CONCEITOS BÁSICOS

Conceitos Básicos

- Paralelização Automática X Manual
  - Desenhar e desenvolver programas paralelos tem sido um processo essencialmente manual
  - O programador em geral é o responsável tanto pela identificação quanto pela implementação efetiva do paralelismo

Conceitos Básicos

- Paralelização Automática X Manual
  - Muitas vezes desenvolver código paralelo de forma manual consome tempo e é um processo mais complexo e suscetível a erros. Por outro lado, pode-se obter melhores *spedups* em comparação à paralelização automática de código
  - Várias ferramentas estão disponíveis para ajudar um programador converter programas seriais em programas paralelos
    - *O tipo mais comum de ferramenta para realizar esta tarefa são pré-processadores ou compiladores de paralelelização*

Conceitos Básicos

- Paralelização Automática X Manual
  - Um compilador paralelizador pode ser:
    - **Totalmente automática**
      - O compilador analisa o código fonte e identifica oportunidades de paralelismo
      - A atividade envolve identificar inibidores de paralelismo e uma ponderação se o uso de paralelismo poderia ser eficiente para melhorar o desempenho
      - Loops (do, for) são os alvos mais frequentes para a atividade de paralelização automática

Conceitos Básicos

- Paralelização Automática X Manual
  - **Direcionado ao Programador**
    - Diretivas de compilação ou flags do compilador. O programador informa explicitamente ao compilador como paralelizar o código. Pode também ser utilizado com algum grau de paralelização automática

Conceitos Básicos

- Paralelização Automática X Manual
  - Alguns pontos importantes em relação à paralelização automática:
    - Erros podem ocorrer
    - O desempenho pode ser ruim
    - Menos flexível que a paralelização manual
    - Limitado a um subconjunto de código (principalmente loops)
    - Não pode paralelizar o código se a análise sugere que não há inibidores ou o código é complexo
  - Neste curso, serão abordadas técnica para o desenvolvimento manual de programas paralelos.

Conceitos Básicos

- **Problema x Programa**
  - Primeiro passo para desenvolver um programa paralelo
    - ENTENDER O PROBLEMA
  - Se a ideia é a paralelização de um programa serial, o primeiro passo é entendê-lo
  - NÃO PERCA TEMPO
    - Antes de desenvolver uma solução paralela para o problema, determine primeiro se o problema apresenta potencial para exploração de paralelismo

Conceitos Básicos

- Exemplo do que pode ser paralelizado:
  - Resolução de sistemas lineares
- Exemplo do que não pode ser paralelizado
  - Série de Fibonacci (1,1,2,3,5,8,13,21)
    - F(n) = F(n-1) + F(n-2)
    - O cálculo da sequência implica em cálculos dependentes ao invés de independentes
    - O cálculo de F(n) utiliza cálculo de F(n-1) e F(n-2); Os três termos não podem ser calculados independentemente

Conceitos Básicos

- **Problema x Programa**
  - **Identificar os pontos críticos de um programa**
    - Saiba onde a maioria do trabalho está sendo feito
    - Muitos programas científicos consomem a maior parte do tempo de processamento em poucos locais
    - Ferramentas de desempenho podem auxiliar nesse sentido
    - Concentre-se no paralelismo dos pontos críticos e ignore as seções do programa que fazem pouco uso da CPU

Conceitos Básicos

- **Problema x Programa**
  - **Identificar gargalos no programa**
    - Há áreas de um programa que são desproporcionalmente mais lentas. Ex: E/S é algo que degrada o desempenho de um programa
    - Possibilidade de reestruturar o programa ou utilizar um algoritmo diferente para reduzir ou eliminar áreas com processamento mais demorado

Conceitos Básicos

- **Problema x Programa**
  - **Identificar inibidores de paralelismo**
    - Dependência de dados (como mostrado na sequência de Fibonacci)
  - Investigar outros algoritmos quando possível. Esta pode ser a consideração mais importante ao projetar uma aplicação paralela

TÉCNICAS DE DECOMPOSIÇÃO

Técnicas de Decomposição

- Primeiro passo
- Quebre o programa em blocos de trabalho que possam ser distribuídos em várias tarefas

Decomposição/Particionamento

Técnicas de Decomposição

- Dois modos básicos de particionamento de um trabalho computacional em tarefas paralelas:
  - **Decomposição de domínio e Decomposição funcional**

Técnicas de Decomposição

- **Decomposição de Domínio**
  - O dado associado ao problema é decomposto.
    - Cada tarefa paralela trabalha sobre uma porção dos dados

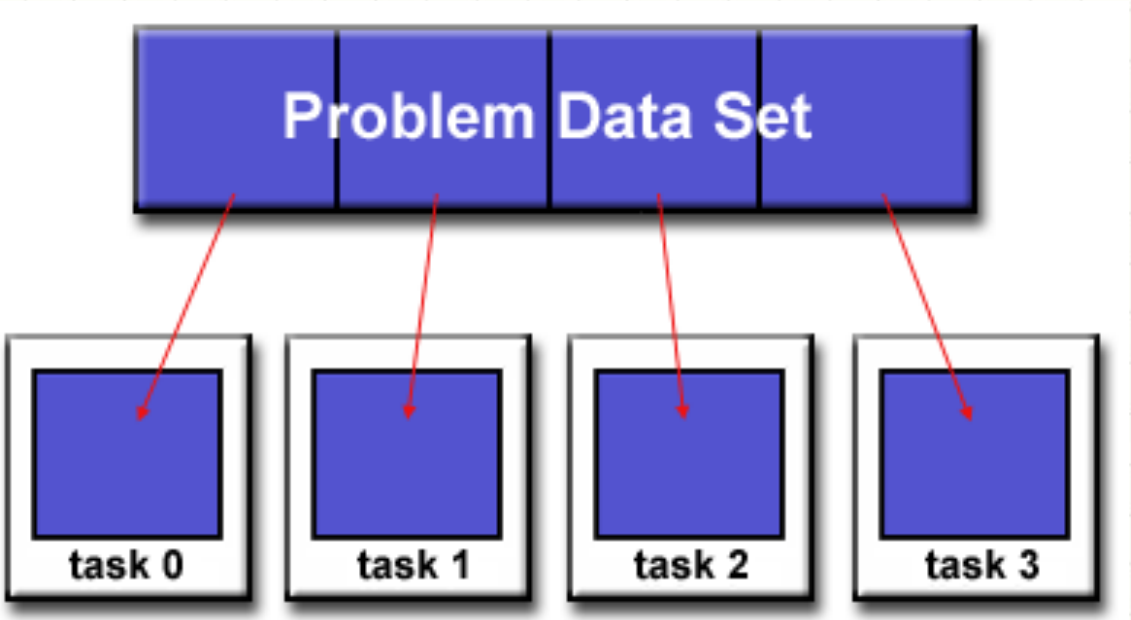

Técnicas de Decomposição

- **Decomposição de Domínio**
  - Dois modos diferentes para particionar dados

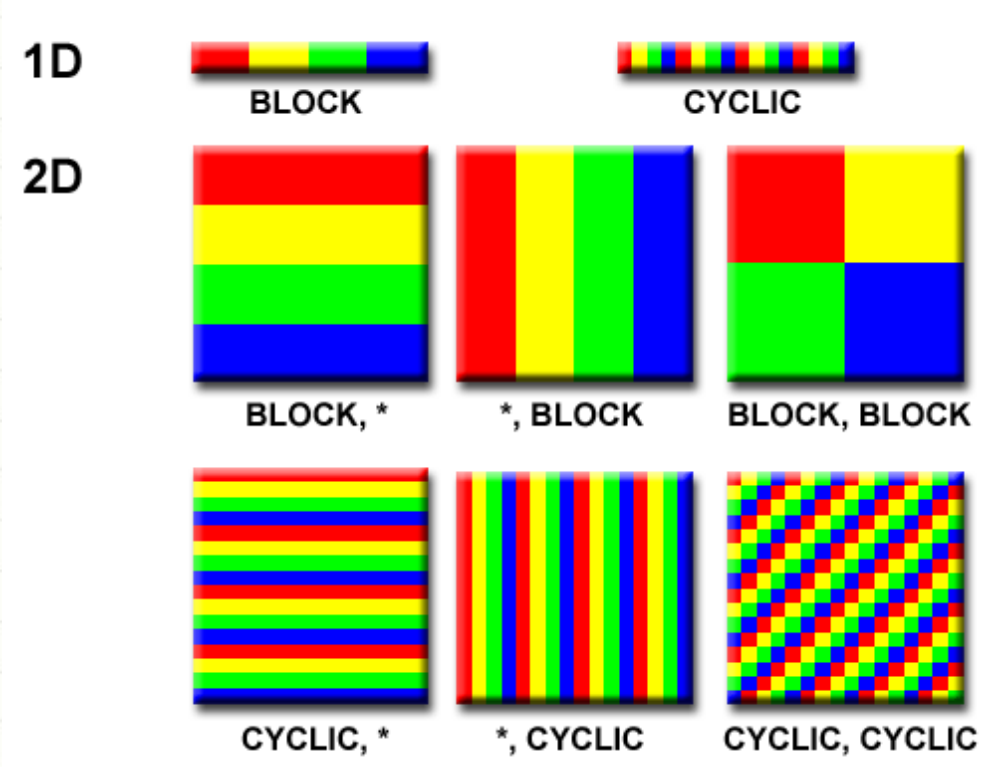

Técnicas de Decomposição

- **Decomposição Funcional**
  - Nesta abordagem o foco recai sobre o algoritmo executado e não sobre o conjunto de dados
  - O problema é decomposto de acordo com o trabalho que deve ser feito
    - Cada tarefa executa parte do trabalho global

Técnicas de Decomposição

- **Decomposição Funcional**

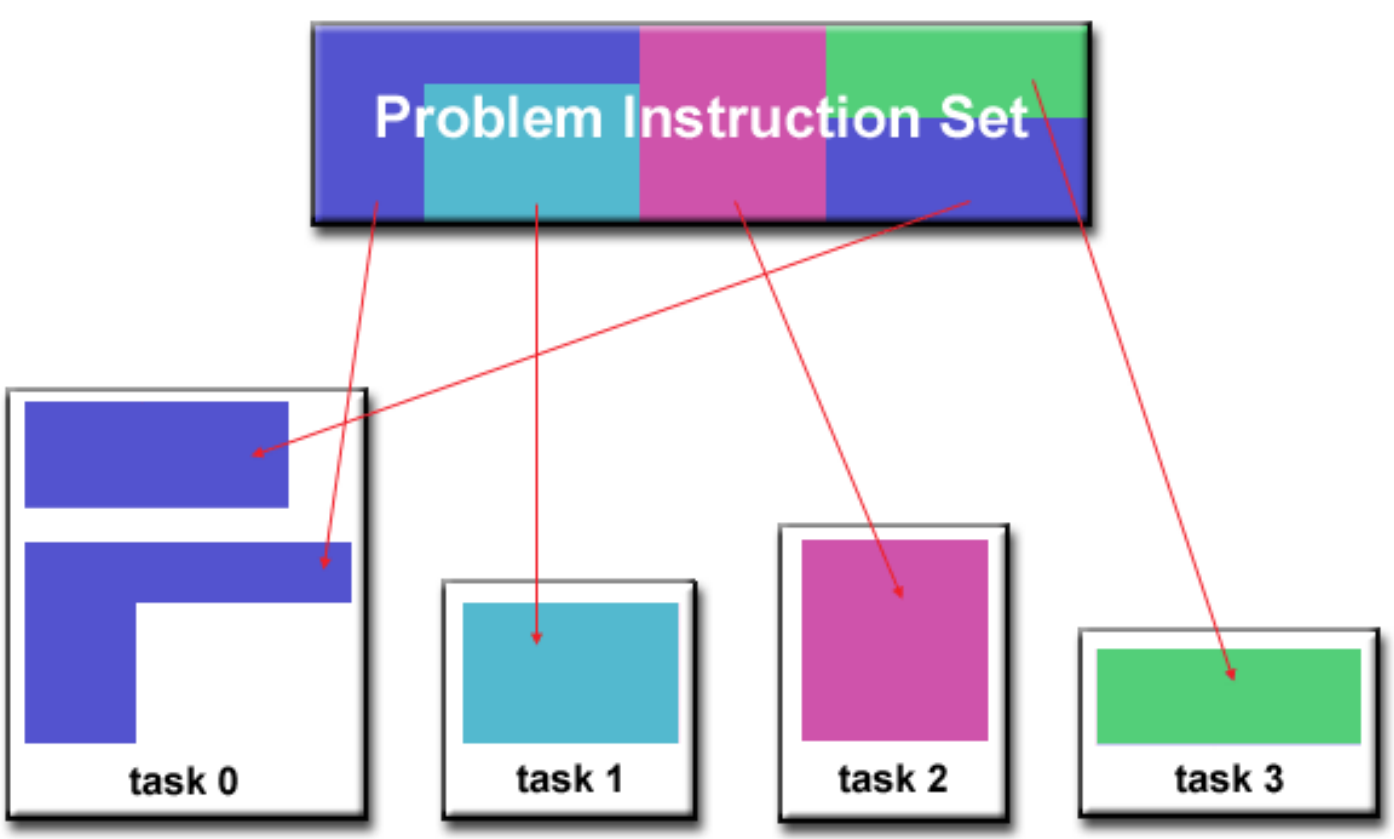

Técnicas de Decomposição

- **Decomposição Funcional**
  - Funciona bem para problemas que podem ser divididos em diferentes tarefas. Exemplo:
    - Modelagem de um ecossistema
    - Processamento de Sinais
    - Modelagem Climática

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Modelagem de um Ecossistema**

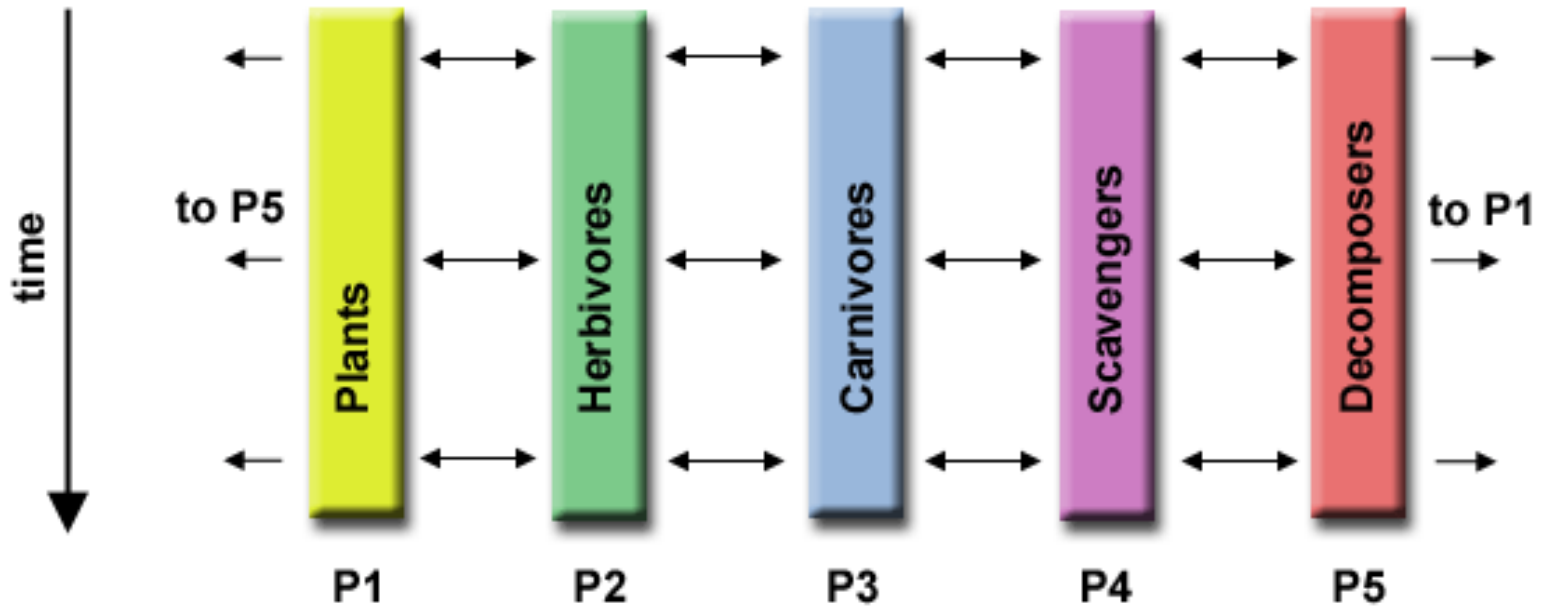

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Modelagem de um Ecossistema**
    - Cada programa calcula a população de um determinado grupo. O crescimento de cada grupo depende de seus vizinhos. Conforme o tempo avança, cada processo calcula seu estado atual e em seguida troca informações com as populações vizinhas. Todas as tarefas prosseguem para calcular o estado da próxima etapa.

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Processamento de Sinais**

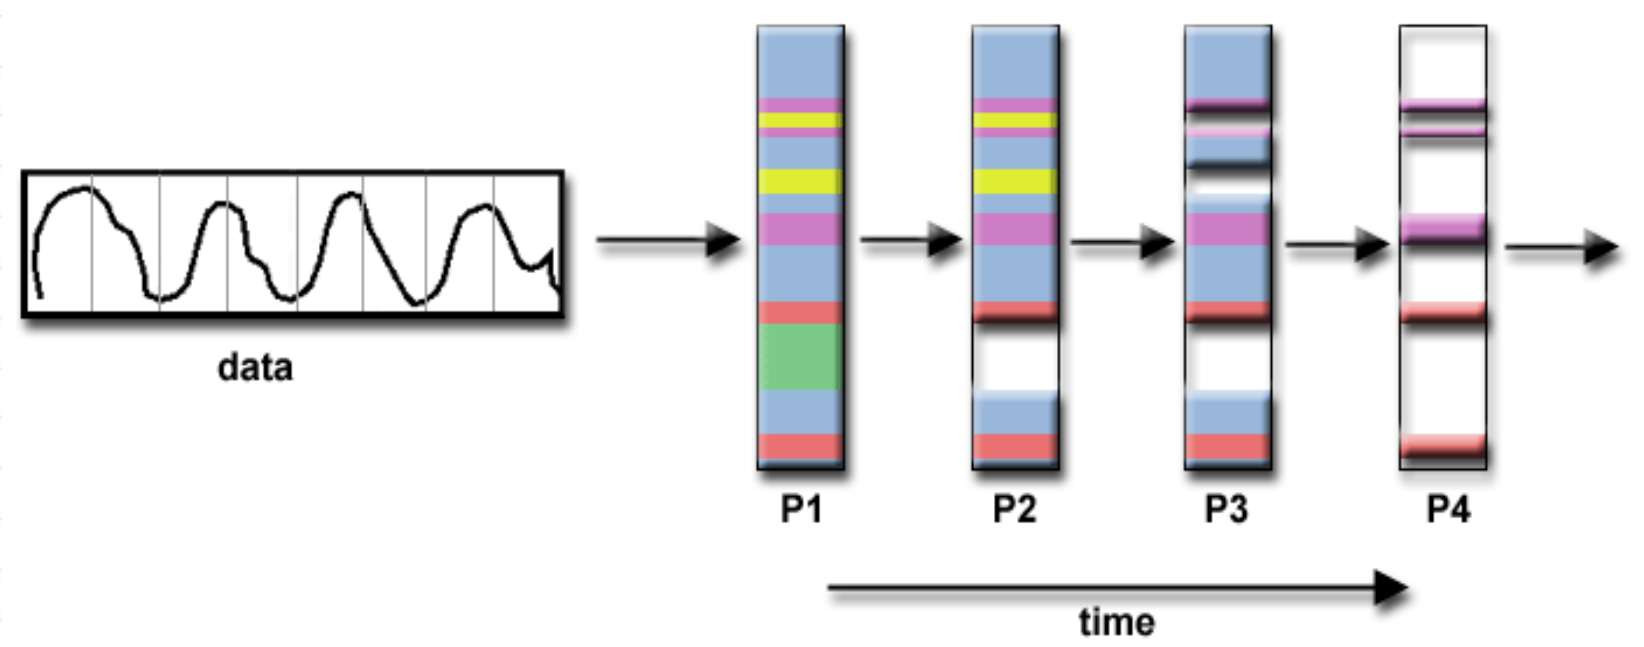

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Processamento de Sinais**
    - Um conjunto de sinais de áudio é passado através de quatros filtros computacionais distintos. Cada filtro é um processo separado. O primeiro segmento de dados deve passar pelo primeiro filtro antes de avançar para o segundo. Quando isso ocorre, o segundo segmento de dados passa pelo primeiro filtro. Nesse instante o quarto segmento está no primeiro filtro. Todas a tarefas estão ocupadas, funcionando como um *pipeline*.

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Modelagem Climática**

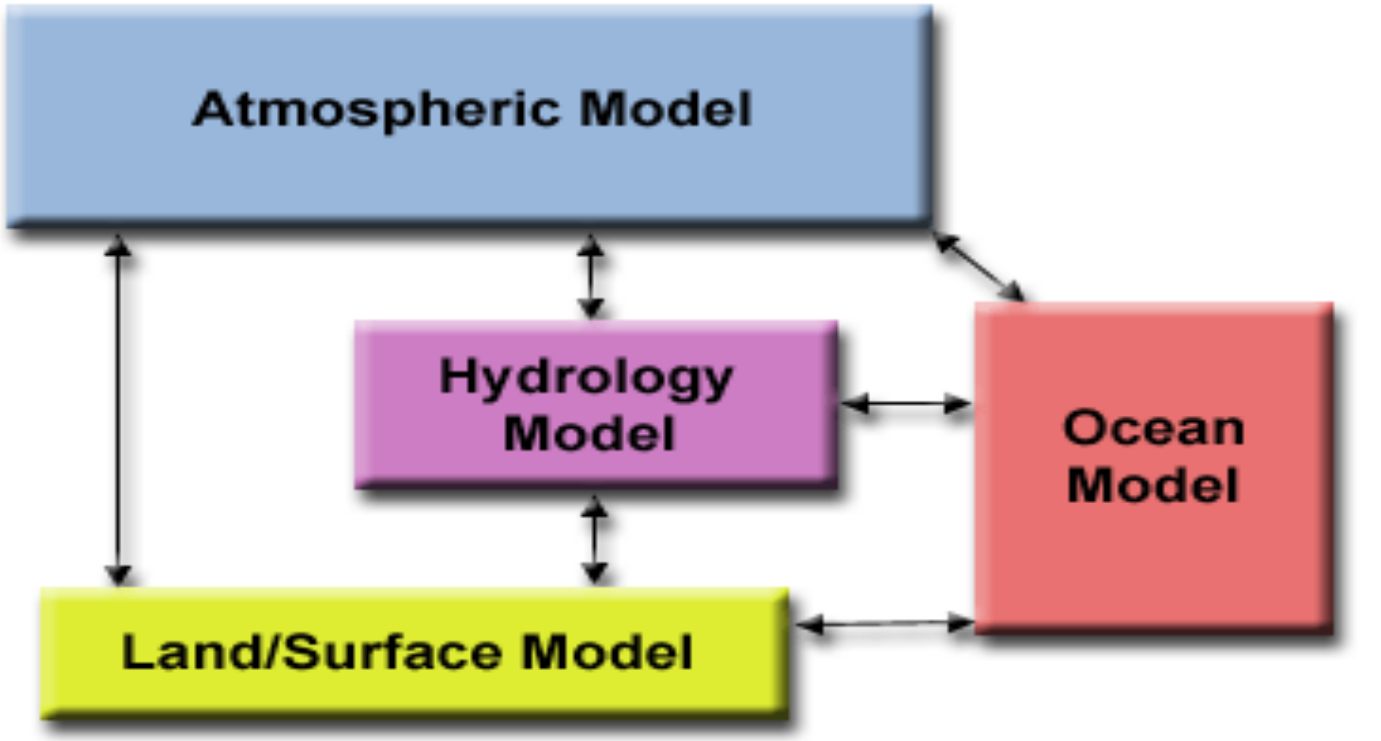

Técnicas de Decomposição

- **Decomposição Funcional**
  - **Modelagem Climática**
    - Cada componente do modelo pode ser processado por uma tarefa separada
    - As setas representam o intercâmbio de dados entre os componentes durante a computação
    - O modelo da atmosfera gera dados de velocidade do vento que são utilizados pelo modelo oceânico
    - O modelo oceânico gera dados de temperatura da superfície do mar que são usado pelo modelo de atmosfera, e assim por diante

COMUNICAÇÕES

Comunicações

- A necessidade de comunicação depende do problema
- **Necessidade de Comunicação**
  - Alguns tipos de problemas podem ser decompostos e executados em paralelo sem a necessidade das tarefas terem que compartilhar dados. Exemplo:
    - Operação de processamento de imagem onde cada pixel de uma imagem preto e branco precisa ser invertida. Os dados da imagem podem ser facilmente distribuídos para várias tarefas que então agem de forma independente uma da outra para realizar sua parte no trabalho.
  - Esse tipo de problema é chamado de embaraçosamente paralelo. Muito pouca comunicação inter-tarefa é necessária

Comunicações

- **Comunicação Necessária**
  - A maioria das aplicações paralelas não são tão simples e precisam que as tarefas possam compartilhar dados umas com as outras.
    Exemplo:
    - Problema de difusão de calor em 3D requer que uma tarefa conheça as temperaturas calculadas pelas tarefas que tem dados vizinhos
    - As alterações nos dados vizinhos apresenta efeito direto sobre os dados dessa tarefa

Comunicações

- Fatores que precisam ser considerados
  - Há um número de fatores a considerar quando se elabora um programa com comunicações inter-tarefas. São eles:
    - Custo da comunicação
    - Latência X Largura de Banda
    - Visibilidade das Comunicações
    - Comunicação Síncrona X Comunicação Assíncrona
    - Escopo das comunicações
    - Eficiência das comunicações

Comunicações

- **Custo da Comunicação**
  - A comunicação entre tarefas implica em sobrecarga
  - Ciclos de CPU e outros recursos que poderiam ser utilizados para o cálculo são utilizados para estruturar e transmitir dados
  - Comunicações frequentemente necessitam de algum tipo de sincronização entre as tarefas, o que faz com que tarefas fiquem esperando ao invés de fazer trabalho útil
  - O tráfego pode saturar a capacidade da rede de comunicação, sinalizando para problemas de desempenho

Comunicações

- **Latência x Largura de Banda**
  - Latência é o tempo que leva para enviar uma mensagem de um ponto **A** um ponto **B** e em geral é expressa em microssegundos
  - Largura de Banda é quantidade de dados que podem ser transmitidos por unidade de tempo, em geral expressa em Megabits/segundo ou Gigabits/Segundo.
  - Enviar muitas mensagens pequenas pode causar sobrecarga de comunicação.
    - Vale a pena empacotar pequenas mensagens em uma mensagem maior, para tornar mais efetivo o uso da banda de comunicação.

Comunicações

- **Visibilidade de Comunicações**
  - Com o ***Modelo de Passagem de Mensagens***, as comunicações são explícitas e em geral bastante visíveis e sobre o controle do programador
  - Com o ***Modelo Paralelo de Dados*** as comunicações frequentemente ocorrem transparentemente ao programador, particularmente em arquiteturas de memória distribuída
  - O programador pode não saber exatamente quando e como as comunicações inter-tarefas estão sendo realizadas

Comunicações

- Comunicação Síncrona x Assíncrona
  - ***Comunicação Síncrona*** requer algum tipo de *handshaking* entre as tarefas que estão compartilhando dados. Isso pode ser explicitamente estruturado no código pelo programador, ou pode ocorrer em baixo nível sem o conhecimento do programador
  - São bloqueantes, uma vez que outros trabalhos devem esperar até que o processo de sincronização esteja terminado

Comunicações

- Comunicação Síncrona x Assíncrona
  - ***Comunicação Assíncrona***
    - Permite que as tarefas transmitam dados de forma independente. Exemplo: Uma tarefa pode se preparar para enviar uma mensagem para a tarefa 2, e em seguida começar a fazer outras atividades. Quando a tarefa 2 vai receber os dados, não importa.
    - São não-bloqueantes, pois outros trabalhos podem ser realizados enquanto acontecem as comunicações.

Comunicações

- **Escopo das Comunicações**
  - É fundamental saber quais tarefas precisam se comunicar umas com as outras durante a concepção de um código paralelo. Há dois escopos, os quais podem ser implementados de forma síncrona ou assíncrona
    - **Ponto-a-Ponto**: Envolve duas tarefas. Uma é a emissora e outra a receptora de dados
    - **Coletivo**: Envolve o compartilhamento de dados entre mais de duas tarefas, que são especificadas como sendo membros de um grupo comum, ou coletivo.
      - ***Algumas variações:***

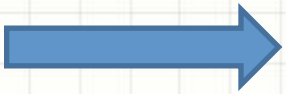

Comunicações

- **Escopo das Comunicações**

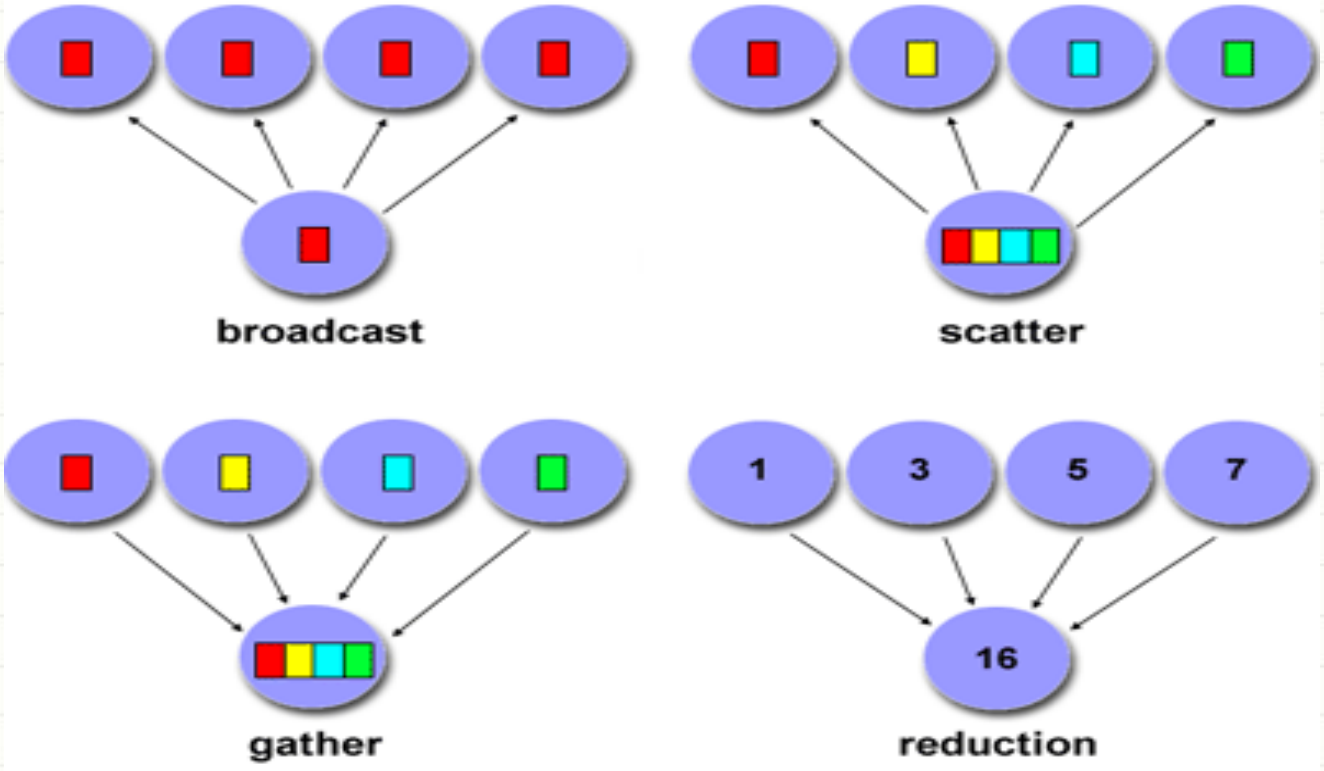

Comunicações

- **Eficiência das Comunicações**
  - Muitas vez o programador terá uma escolha no que diz respeito aos fatores que afetam o desempenho das comunicações. Exemplos:
  - **Que implementação de determinado modelo deve ser usado?**
    - Utilizar o Modelo de Passagem de Mensagens. Como exemplo, uma implementação MPI pode ser mais rápida em uma determinada plataforma de hardware do que em outra
  - **Que tipo de operações de comunicação deve ser utilizado?**
    - As operações de comunicação assíncronas podem melhorar o desempenho geral do programa
  - **Rede**
    - Algumas plataformas podem oferecer mais de uma rede de comunicação. Qual é a melhor?

Comunicações

- **Sobrecarga e Complexidade**

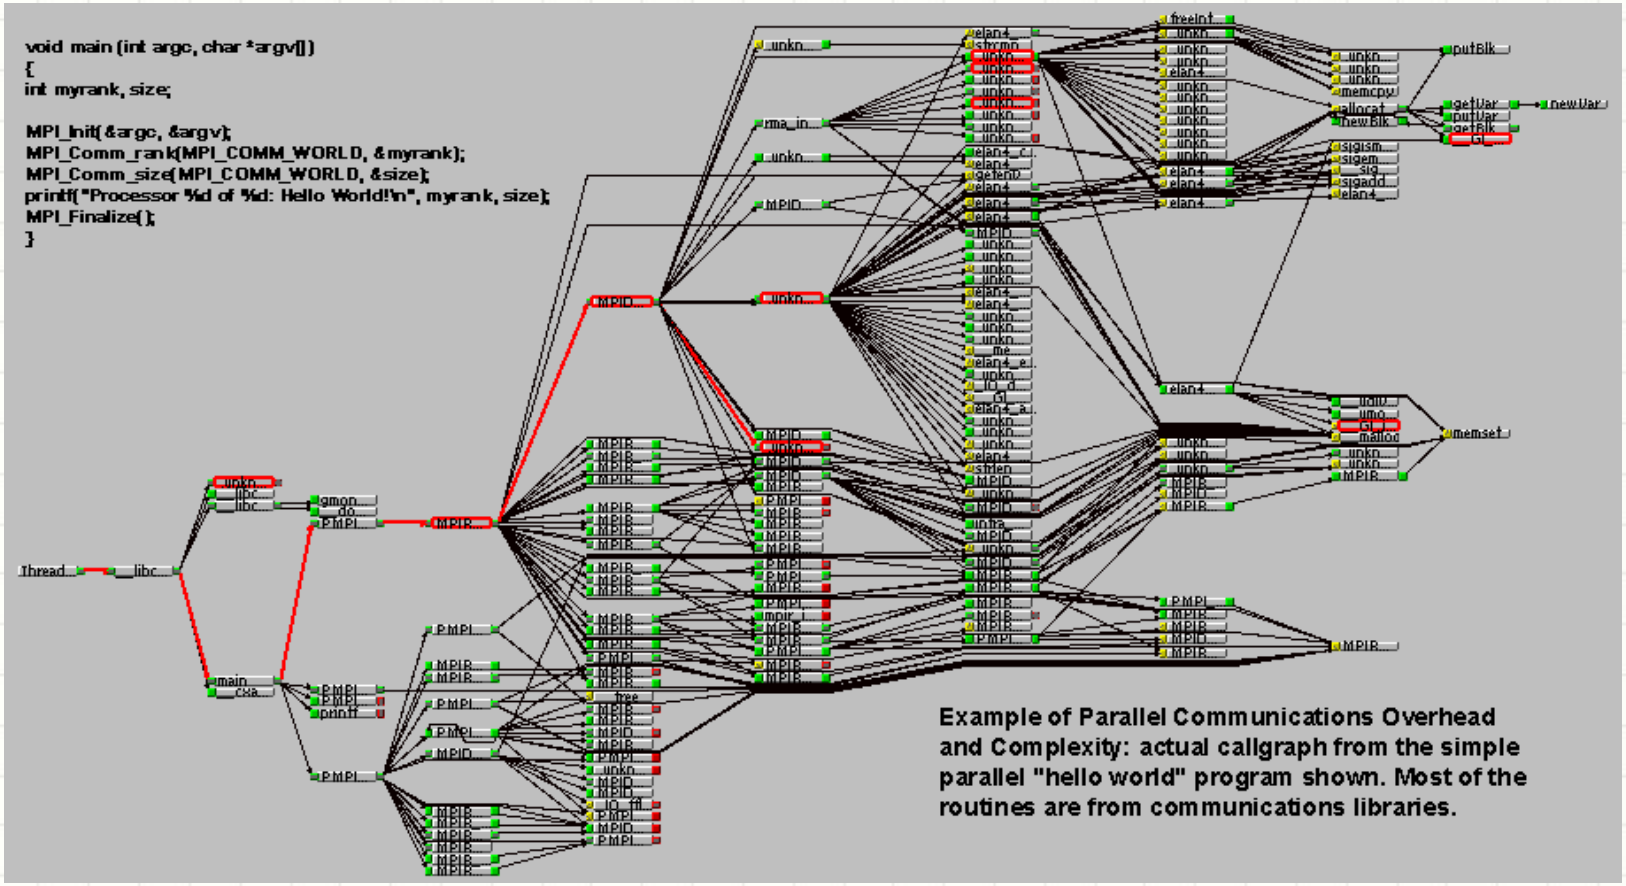

EXERCÍCIO E LEITURA RECOMENDADA

Exercício

- Acessar o Moodle

Leitura Recomendada

- Introduction to Parallel Computing, Ananth Grama, Anshul Gupta, George Karypis, Vipin Kumar - 2ª ed., Addison Wesley
- Introduction to Parallel Computing
  - https://computing.llnl.gov/tutorials/parallel_comp/

Dúvidas

Próxima Aula...

- Ferramentas de Apoio ao Desenvolvimento de Aplicações Concorrentes