LNCC
www.lncc.br
Laboratório Nacional de Computação Científica

Introdução E/S Paralela no SDUMONT
MPIIO - Tuning

Escola Supercomputador SDUMONT
Programa de Verão 2021

André Ramos Carneiro (andrerc@lncc.br)
Bruno Alves Fagundes (brunoaf@lncc.br)

MPIIO - Tuning

Roteiro:

- MPI-IO
- ROMIO
- OMPIO

MPIIO

- Desenvolvido em 1994 no Laboratório Watson da IBM
- Fornecer suporte de Operações de E/S paralelas ao MPI
- 1996: Adotado pela NASA e incorporado pelo Forum do MPI no MPI-2.
- 1997: Publicação do MPI 2 com o MPI-IO já definido dentro.
- Chamadas de função do MPI-IO -> chamadas MPI.
- Escrever arquivos MPI -> enviar mensagens MPI.
- Ler arquivos MPI -> receber mensagens MPI.
- Versatilidade e flexibilidade dos tipos de dados MPI
- Define as visões de arquivo MPI (MPI file views).

MPIIO - ROMIO

- Implementação do MPI-IO portável
- Utilizada por qualquer implementação MPI
- Já faz parte do código da maioria das implementações
- Duas técnicas de otimização de desempenho

1) “Data Sieving”

  Focado em operações independentes com dados não contíguos

  Lê grandes blocos contíguos de dados e depois extrai as áreas de interesse

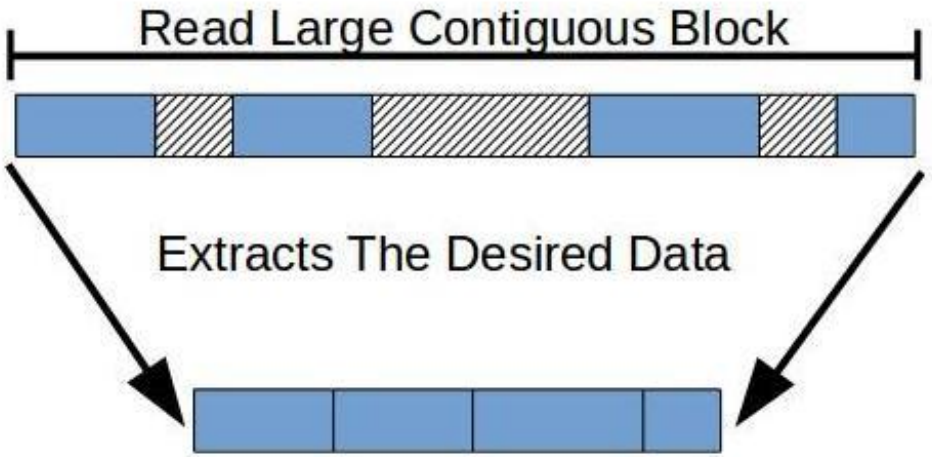

MPIIO - ROMIO

2) “Collective buffering” ou “Two phase I/O”

- Focado em operações coletivas
- Conjunto de processos (agregadores)
- Leem os dados do disco e distribuem para os demais processos
- Coletam os dados de todos os processos e os escrevem no disco

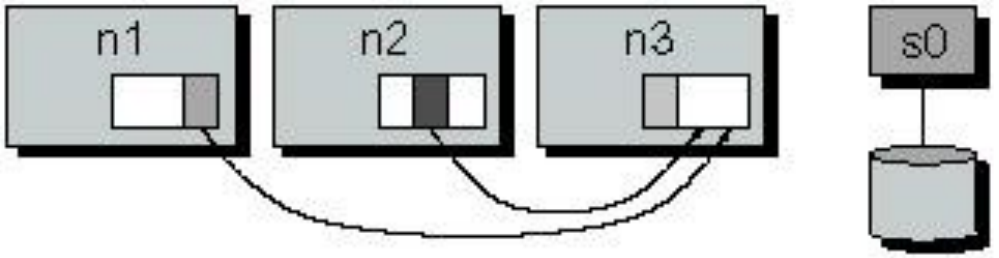

In step one, data is transferred to aggregators.

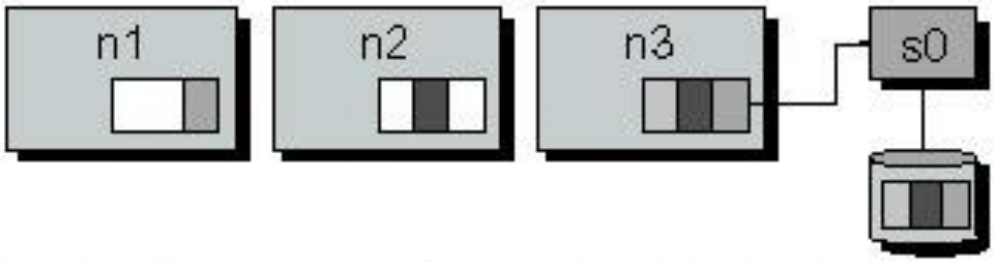

In step two, aggregators write data to storage.

MPIIO – ROMIO - Hints

- Data Sieving
  - `ind_rd_buffer_size (BYTES)`
    - Tamanho do buffer intermediário ao realizar operação de leitura
  - `ind_wr_buffer_size (BYTES)`
    - Tamanho do buffer intermediário ao realizar operação de escrita
  - `romio_ds_read [enable, disable, **automatic**]`
    - Determina realizar o data sieving para operações de leitura
  - `romio_ds_write [enable, disable, **automatic**]`
    - Determina realizar o data sieving para operações de escrita

MPIIO – ROMIO - Hints

- Collective Buffering
  - `cb_buffer_size (BYTES)`
    - Tamanho do buffer intermediário
  - `cb_nodes (Num nós/processos)`
    - Número máximo de agregadores (Hosts únicos)
  - `romio_cb_read [enable, disable, automatic]`
    - Controla quando o buffering coletivo é aplicado às operações de leitura coletiva
  - `romio_cb_write [enable, disable, automatic]`
    - Controla quando o buffering coletivo é aplicado às operações de escrita coletiva
  - `cb_config_list` Pode ser utilizado para um controle mais refinado
    - *:2 → Cada host utilizará 2 processos para realizar E/S
    - sdumontXXXX:24,*:0 → O nó especificado utilizará 24 processos para serem agregadores. Os demais nós não serão utilizados.

MPIIO – ROMIO - Hints

- Lustre
  - `romio_lustre_co_ratio [Int]` **C**`liente/`**O**`ST`
    - Número máximo de cliente de E/S por OST. É configurado por padrão como CO = 1
  - `romio_lustre_coll_threshold (BYTES)` – limite para realizar E/S Col.
    - Tamanho limite da requisição para realizar as operações coletivas. Acima do valor definido, não são realizadas. Configurado com o valor 0 significa sempre realizar as operações coletivas.
  - `romio_lustre_cb_ds_threshold: (BYTES)` - limite para realizar Sieving.
    - Otimiza as operações de E/S coletivas com uma versão do “data sieving”. Se a requisição de E/S for menor do que o valor desse hint, o “data sieving” não será utilizado.
  - `romio_lustre_ds_in_coll: [enable, disable]`
    - Habilitar/Desabilitar o Data Sieving nas chamadas coletivas
  - * Para que essas Hnits estejam disponíveis, é necessário que o ROMIO tenha sido compilado com suporte ao Filesystem Lustre

MPIIO – ROMIO - Hints

- Configurar
  - Um arquivo texto contendo:

```
hint_1 valor
hint_2 valor
etc....
```

  - Configurar a variável de ambiente `ROMIO_HINTS`, apontando para o arquivo:
    - `export ROMIO_HINTS=/scratch/PROJETO/USUARIO/arquivo_de_hints`

- Executar a aplicação através do mpiexec/mpirun/srun

- Exibir as Hints utilizadas pelo ROMIO
  - `export ROMIO_PRINT_HINTS=1`

MPIIO – ROMIO - Ativar

- Intel MPI - PSXE 2016, 2017 e 2018
  - `export I_MPI_EXTRA_FILESYSTEM=on`
  - `export I_MPI_EXTRA_FILESYSTEM_LIST=lustre`
- Intel MPI - PSXE 2019
  - `export I_MPI_EXTRA_FILE_SYSTEM=on`
- OpenMPI - Ativado através do **MCA** (Modular Component Architecture)
  - 2.X | 3.X: `export OMPI_MCA_io=romio314`
  - 4.X: `export OMPI_MCA_io=romio321`

MPIIO – OMPIO

- Implementação desenvolvida pelo Open-MPI.org
- Introduzida a partir da versão 1.7 (default a partir da versão 2.0)
- Suporte ao Lustre a partir da versão 2.0

- Objetivos
  - Aumenta a modularidade da biblioteca de E/S Paralela
  - Permite aos frameworks utilizar diferentes algoritmos de decisão
  - Melhora a integração das funções de E/S paralelas

- Sub-frameworks:
  - **fs framework**: Gerenciamento de todas as operações com arquivos
  - **fbtl framework**: Operações individuais de E/S blocking e non-blocking
  - **fcoll framework**: Operações coletivas de E/S blocking e non-blocking
  - **sharedfp framework**: Operações de arquivos compartilhados

MPIIO – OMPIO – Parâmetros

- `io_ompio_cycle_buffer_size (BYTES)`
  - Tamanho dos dados utilizados por chamadas de I/O individuais.
- `io_ompio_bytes_per_agg (BYTES)` **(32MB)**
  - Tamanho do buffer temporário para operações coletivas de I/O nos processos agregadores.
- `io_ompio_num_aggregators (INT)`
  - Número de processos agregadores utilizados nas operações coletivas de I/O.
- `io_ompio_grouping_option: [1-7]`
  - Algoritmo utilizado para decidir automáticamente o número de agregadores utilizados. 1: Data volume based | 2: maximizing group size uniformity | 3: maximimze data contiguity | 4: hybrid optimization | 5: simple (default) | 6: skip refinement step | 7: simple + grouping based on default file view
- `fs_lustre_stripe_size (BYTES)`
  - Define o tamanho do stripe size de um arquivo no filesystem lustre
- `fs_lustre_stripe_width (INT)`
  - Define o stripe count de um arquivo no filesystem lustre

MPIIO – OMPIO – Parâmetros

- Lista completa de todos os parâmetros:
  - `ompi_info --level 9 --param io ompio`
  - `ompi_info --level 9 --param fcoll all`
  - `ompi_info --level 9 --param fs all`
  - `ompi_info --level 9 --param fbtl all`
  - `ompi_info --level 9 --param sharedfp all`

MPIIO – OMPIO – Parâmetros

- Para utilizar:
  - `export OMPI_MCA_io=ompio`
  - `export OMPI_MCA_io_ompio_bytes_per_agg=536870912`
  - `export OMPI_MCA_io_ompio_num_aggregators=5`
  - `export OMPI_MCA_fs_lustre_stripe_width=5`
  - `export OMPI_MCA_fs_lustre_stripe_size=5242880`

Dúvidas?