



Computer simulations create the future

# 第2回 AICS公開ソフト講習会

## K MapReduce

丸山 直也  
松田 元彦  
滝澤 真一郎

理化学研究所 計算科学研究機構  
プログラム構成モデル研究チーム



# Agenda

---

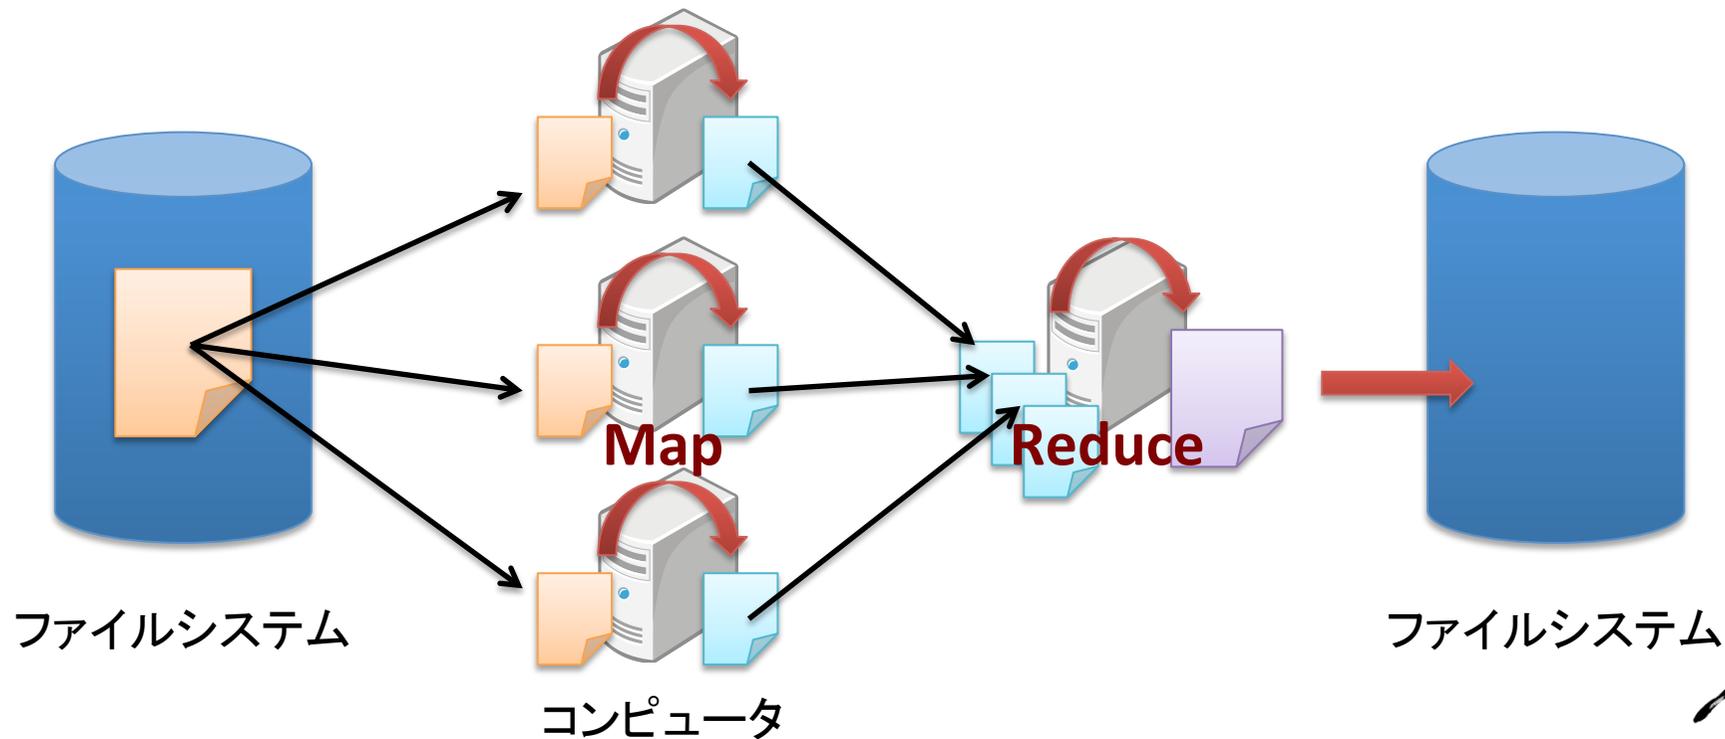
- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

# MapReduceとは

- 多数のコンピュータ上で、大規模なデータを分散処理することを目的に導入されたプログラミングモデル
  - 2004年にGoogleが発表した論文を期に広まる
    - Jeffrey Dean and Sanjay Ghemawat, MapReduce: Simplified Data Processing on Large Clusters, OSDI'04.
- 学術利用だけでなく、企業利用事例も多数ある
  - ログ(アクセスログ、購入記録等)解析
  - ソーシャルグラフ解析
  - ゲノム、顕微鏡等の観測データ解析

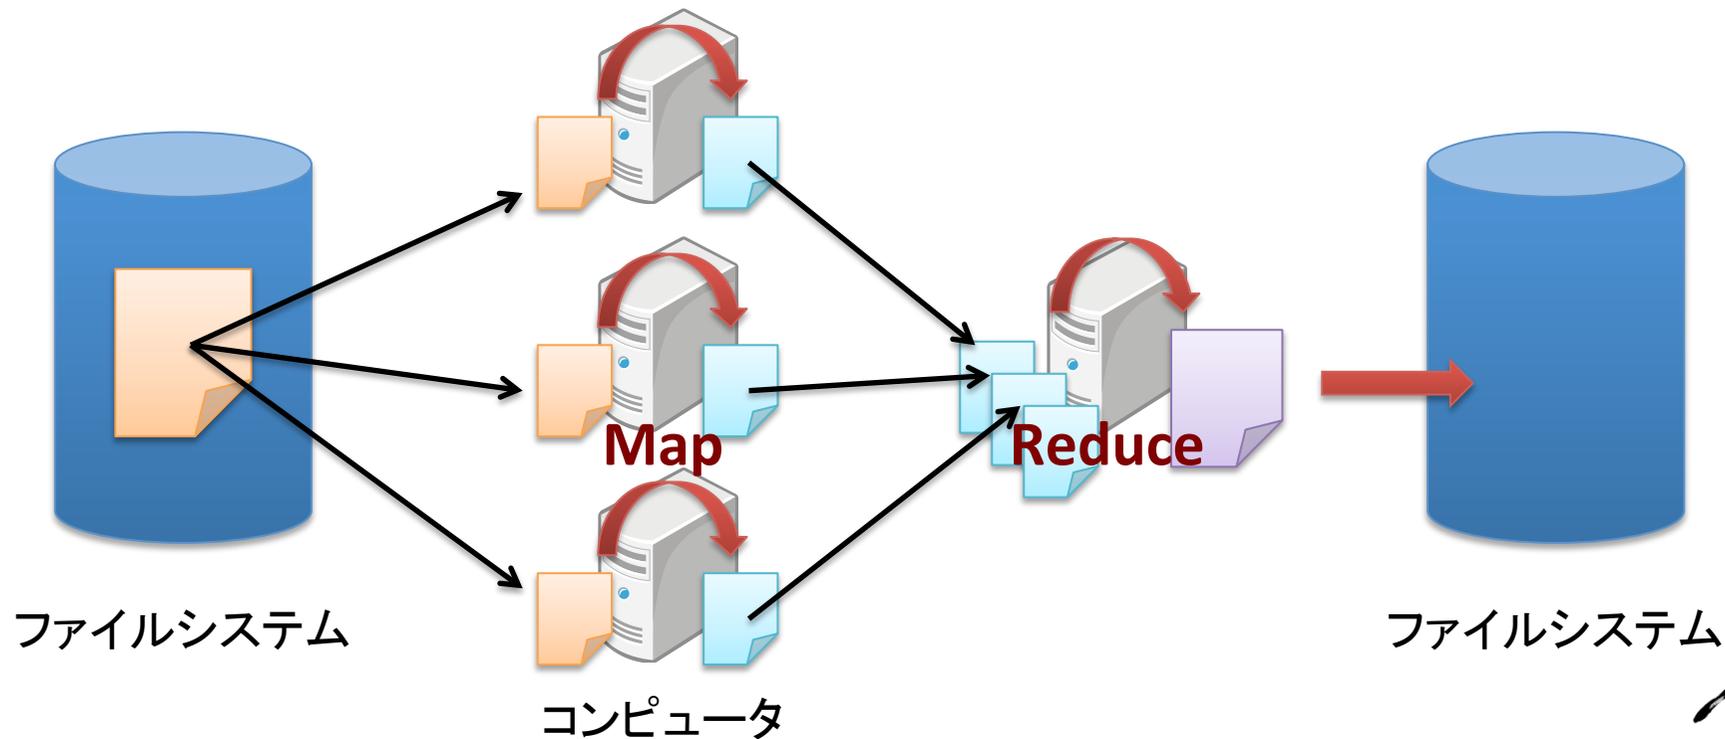
# MapReduce動作概要 (1/2)

- データを分割して、多数のコンピュータで並列処理し、結果をまとめる
  - 個々の処理は「互いに独立」が前提



# MapReduce動作概要 (2/2)

- データの分割・コンピュータへの分散、並列実行はMapReduce処理系が対応
  - 利用者はMap、Reduceで行う処理を逐次処理として実装するだけで良い => 並列化は処理系が担当



# MapReduceの利点

- Map用プログラム、Reduce用プログラムの2つの逐次処理プログラムを実装するだけで良い
  - データの分割、コンピュータへの分散、Map/Reduce処理の並列実行はMapReduce処理系が担当
  - ▶ 計算ロジックだけに集中してプログラム実装できる
- ただ、従わなければならない制約もあります

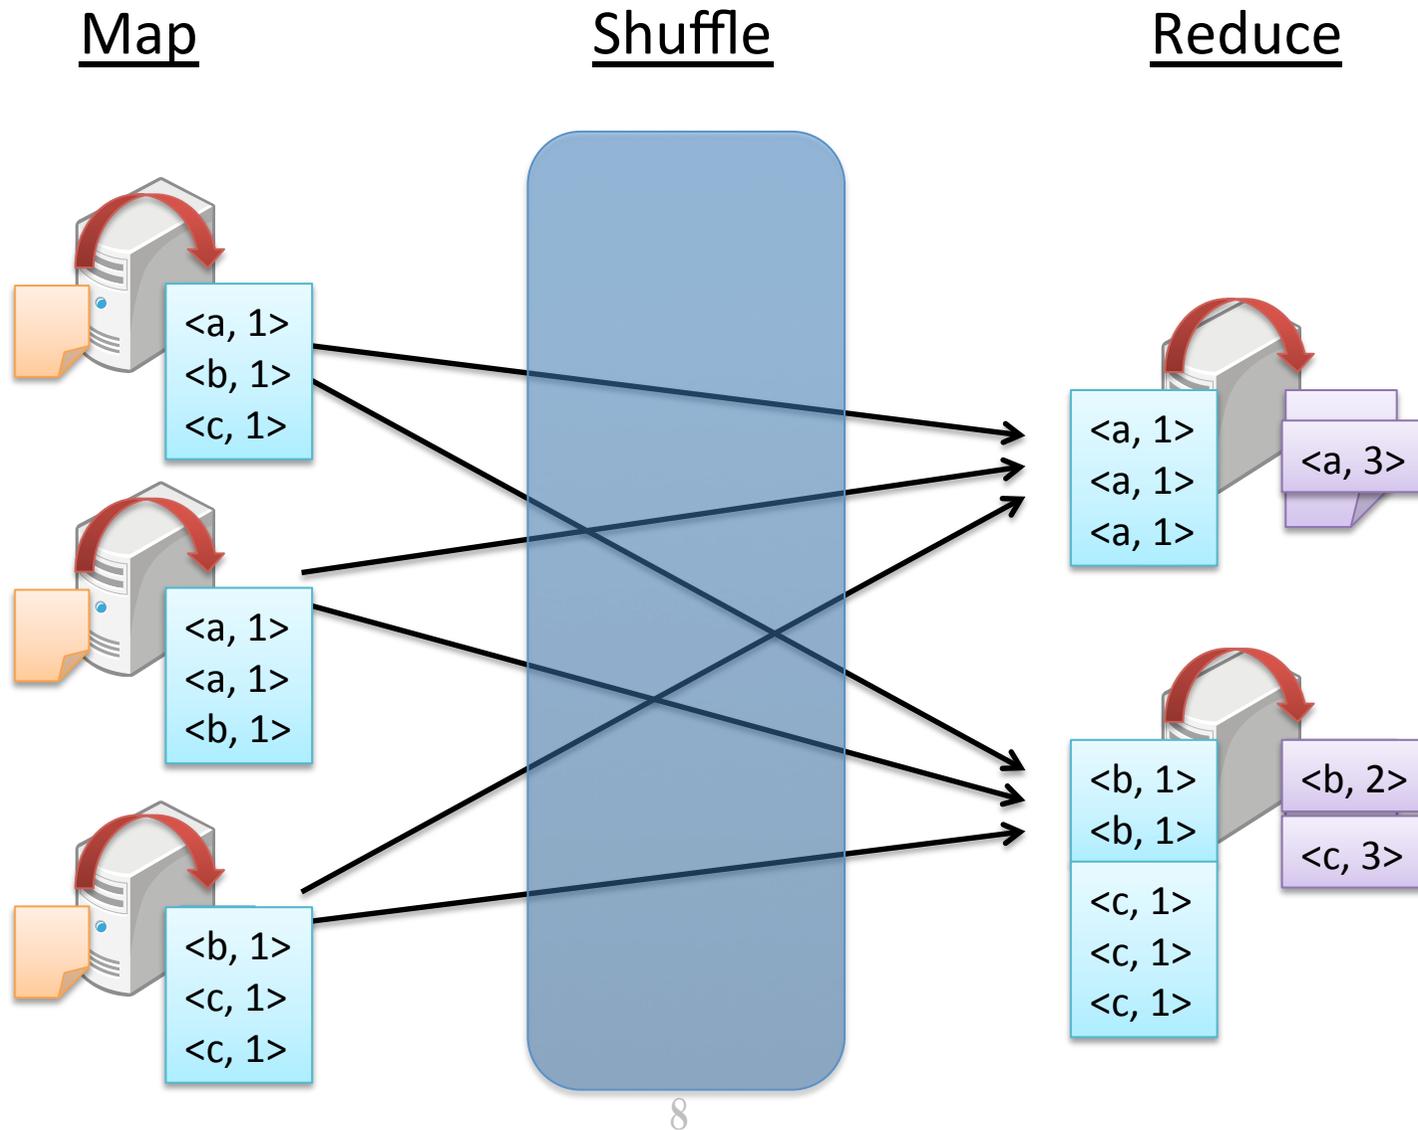
# プログラム実装上の制約

- Map用プログラム
  - 異なるデータに対して、同じ処理が行われる
    - 入力毎に異なる計算をしたければ、入力のコンテキストに応じて処理を分岐しなければならない
  - Key-Value (KV)を出力する処理として実装
- Reduce用プログラム
  - 異なるデータに対して、同じ処理が行われる
  - KVを入力・出力とする
    - Map用プログラムが出力したKVがKey毎にまとめられて入力される
    - 同じKeyを持つ複数のValueを結合する処理として実装

Key-Value  
ハッシュのような  
キーと値のペア

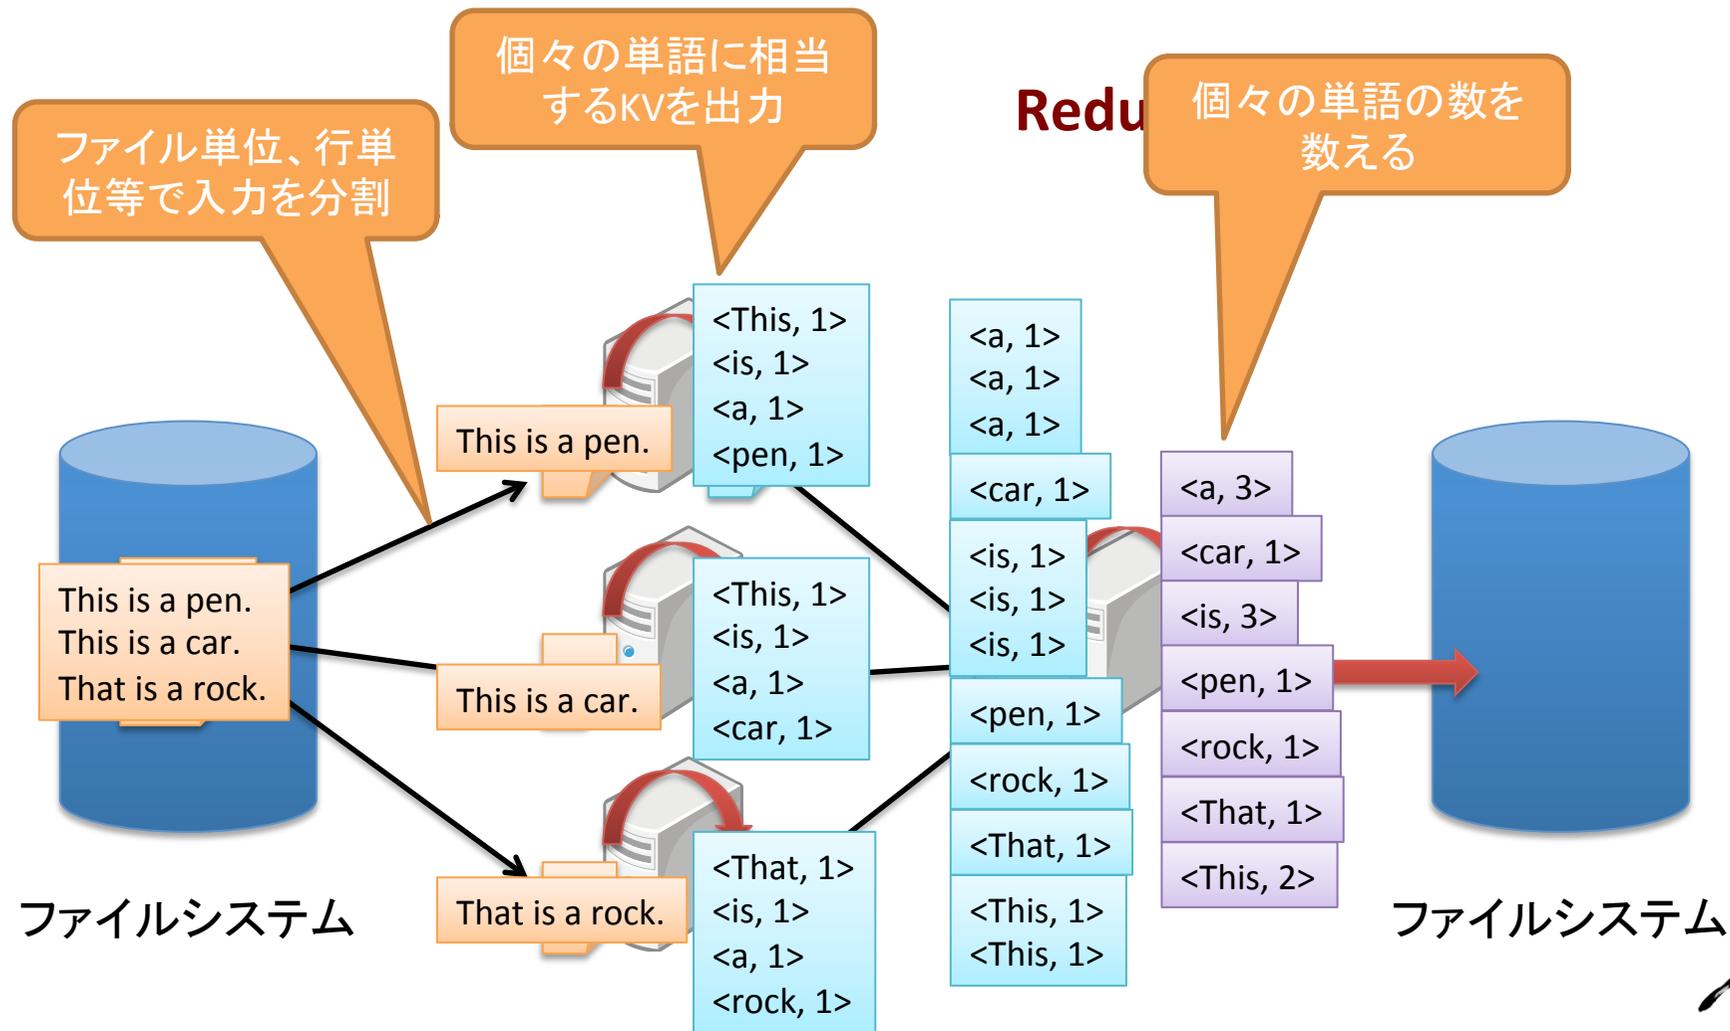
<a, 1>, <b, 2>  
など

# MapReduce動作詳細

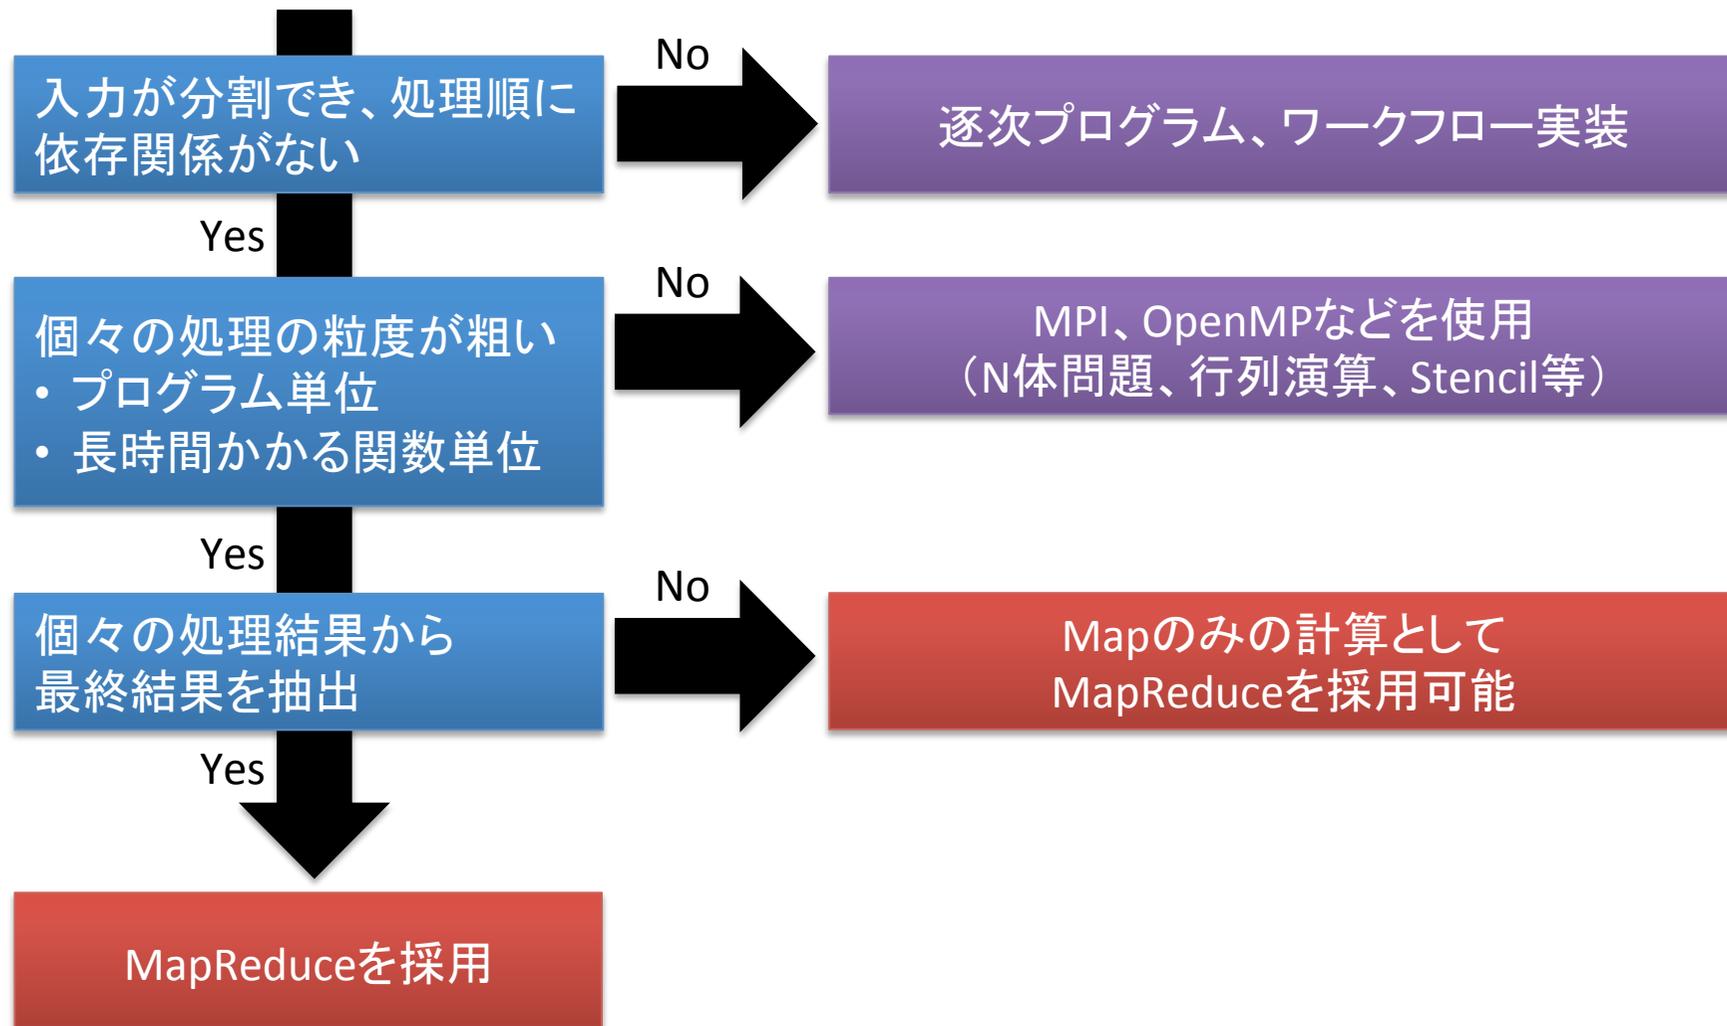


# MapReduceプログラム例: Word Count

- テキストファイル中出现する単語の数を数える



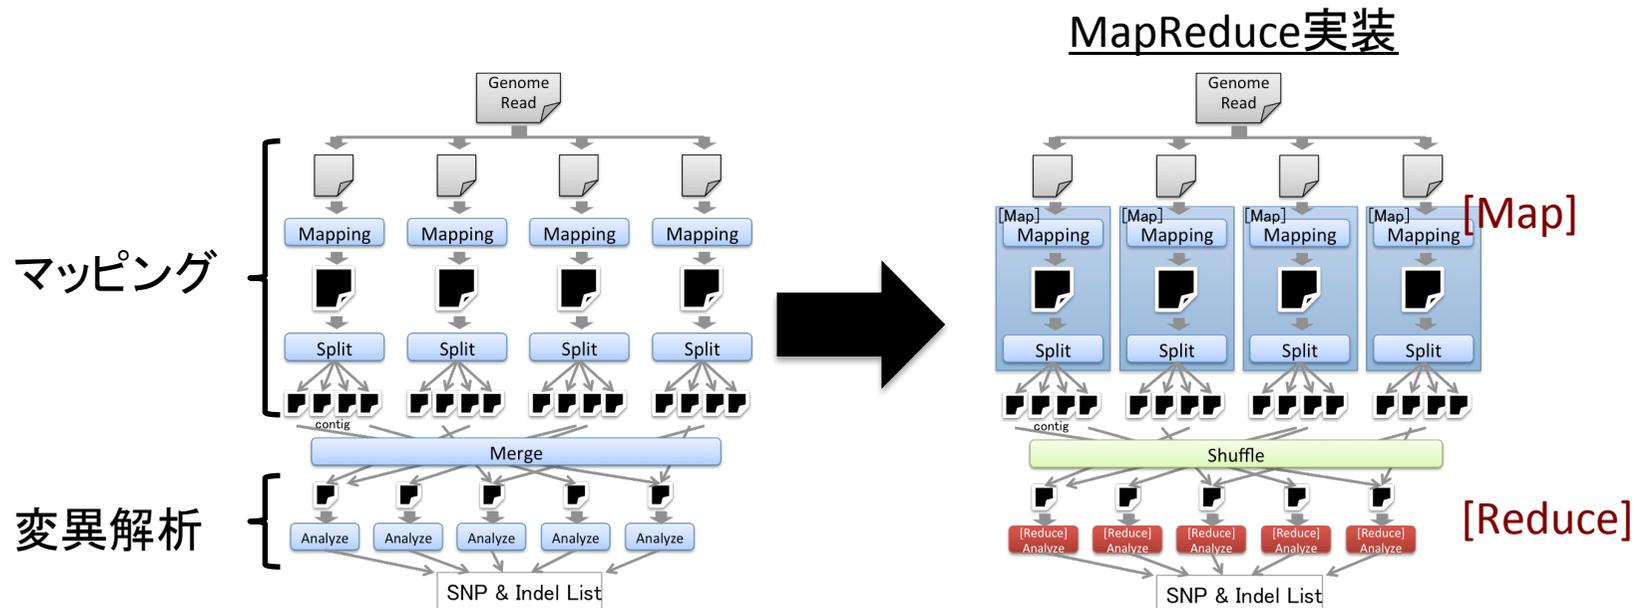
# MapReduceモデルが有用な計算パターン



# 計算科学アプリケーションへの適用事例 (1/4)

- ゲノム解析ワークフローをMapReduceモデルで構築
  - 大規模データ処理を並列実行
  - シーケンサー出力のゲノムデータを分割してマッピング処理、塩基配列パターン毎に変異解析

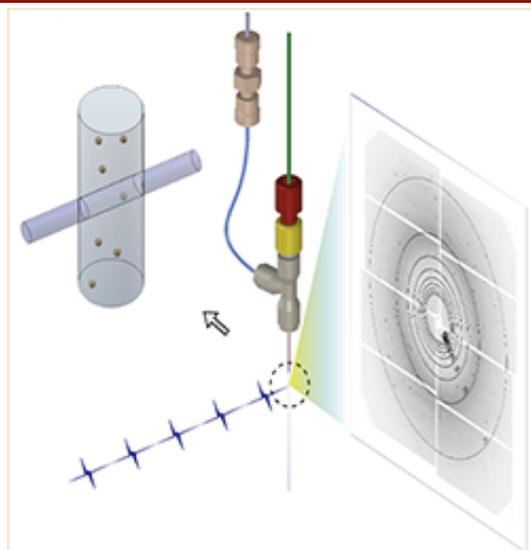
➡ 典型的なMapReduceパターンで表現可能



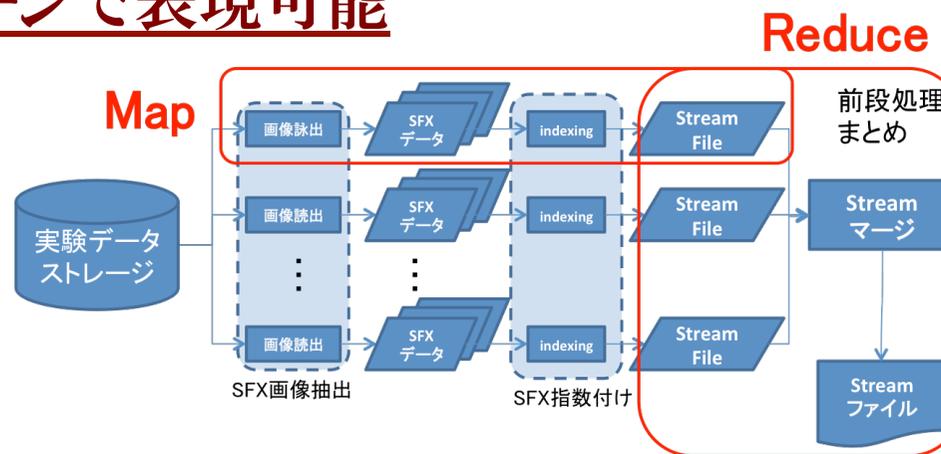
# 計算科学アプリケーションへの適用事例 (2/4)

- X線自由電子レーザー施設SACLAの利用実験データ解析
  - Serial Femtosecond Crystallography (SFX)実験では、タンパク質微小結晶からの回折パターンを大量に取得し、立体構造を解析
    - 100万枚/日規模の回折パターンを解析
  - SFX用の既存ツールを用いて、個々の回折パターンから特徴量を抽出し、結果を結合

## ➡ 典型的なMapReduceパターンで表現可能



SACLA利用によるSFX実験の模式図

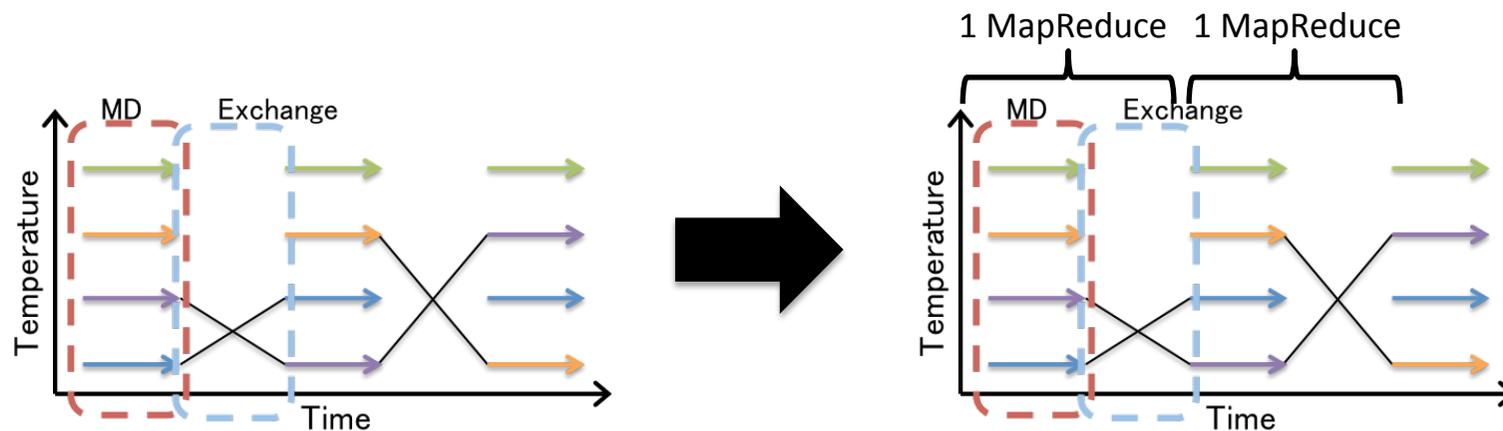


回折パターン1枚1枚にSFXツールを実行し、インデクシングを行う (Map)。解析結果をストリームファイルとして結合する (Reduce)。

構造解析  
後段処理へ

# 計算科学アプリケーションへの適用事例 (3/4)

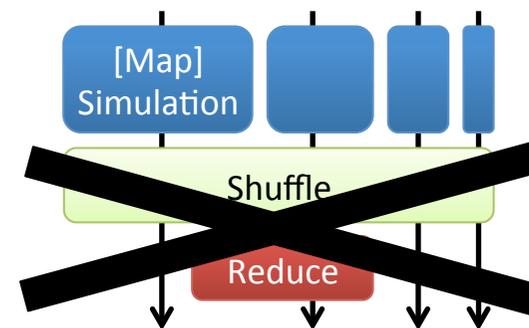
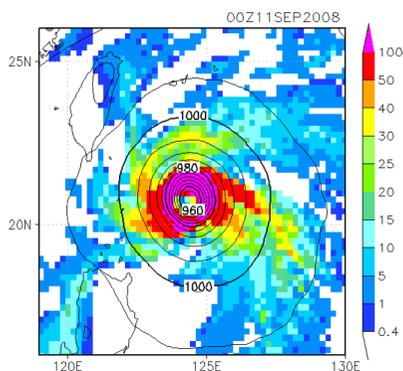
- アンサンブル計算をMapReduceモデルで構築
    - 異なるパラメータのシミュレーションを複数行い、結果を統計処理
    - 例)レプリカ交換分子動力学法
      - エネルギーの異なる複数のタンパク質のレプリカについてMD計算
      - MD計算の結果を基に実行パラメータを交換し、MDを繰り返し実行
- ➡ 繰り返し処理を行うMapReduceパターンで表現可能



# 計算科学アプリケーションへの適用事例 (4/4)

- 異なるパラメータで多数のシミュレーションを要求する計算科学アプリケーション
  - データ同化を用いた気象予報: 10~10,000ケース
  - 自動車交通流等の社会シミュレーション: 10~10,000ケース
- 京コンピュータでは同時受付ジョブ数に制限(15ジョブ)
  - 制限を超えたジョブを投入するためには、利用者がジョブ実行を監視・管理する必要がある

➡ Map実行のみのMapReduceとして、複数ケースを1ジョブ実行



Shuffle, Reduceの無い、MapReduceとして実行

# MapReduceを京で効率よく実行するための要件

- マルチノード・マルチコア環境での高いスケーラビリティ
  - 82,944ノード・663,552コアの有効活用
  - 大量のKVの高速な通信
- 大容量ファイルの効率的な処理
  - 分散ファイルシステムに保存されているファイルへの、多数のノードからの同時アクセスに対応
- プログラムをまとめて実行する機能
  - 京ではジョブ投入数に制限

KMRはこれらを満たすように設計・実装されています

HadoopやMR-MPIなどの既存のMapReduce処理系は、性能面、スケーラビリティにおいて不十分

# Agenda

---

- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

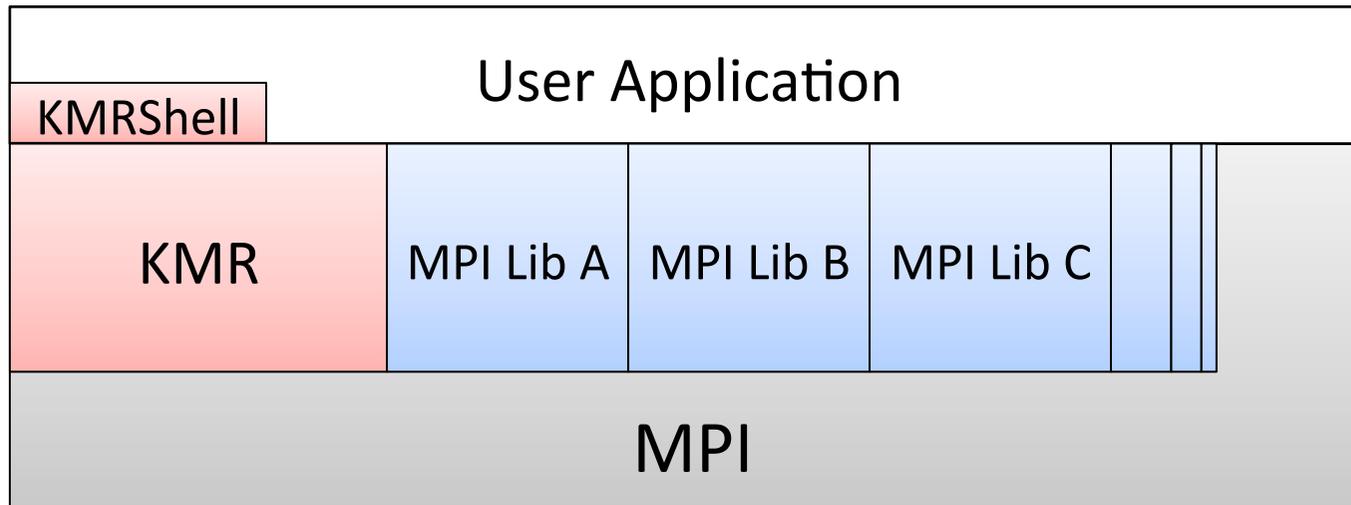
# K MapReduce (KMR)

- 大規模並列システム上で、スケーラブルに動作するMapReduce処理系実現を目的に開発された処理系
- 開発チーム: AICS プログラム構成モデル研究チーム
  - 丸山直也 (プロジェクトリーダー)
  - 松田元彦
  - 滝澤真一郎
- 動作環境
  - 京コンピュータ、富士通FX10
  - Linux/Solaris + gcc/Intel Compiler + OpenMPI
    - コンパイラはc99準拠のこと
    - MPI以外の依存ライブラリはなし

# KMR情報源

- プロジェクトホームページ
  - <http://mt.aics.riken.jp/kmr/>
- 論文
  - Motohiko Matsuda, Naoya Maruyama and Shinichiro Takizawa: K MapReduce: A Scalable Tool for Data-Processing and Search/Ensemble Applications on Large-Scale Supercomputers, IEEE Cluster 2013 Conference (2013).
    - KMRの実装と性能評価
  - 滝澤真一郎, 松田元彦, 丸山直也: MapReduceによる計算科学アプリケーションのワークフロー実行支援, 情報処理学会 HPCS2014 (2014).
    - KMRによる計算科学アプリケーションの実装と評価

# KMRの実装位置づけ



- MPIの1ライブラリとしてC言語にて実装
- MPIや他のMPIライブラリと組み合わせたプログラムの実装が可能
- コマンドとしての利用も可能 (KMRShell)

# KMRの特徴

- ノード間・ノード内にて並列実行するハイブリッド並列
  - ノード内: OpenMP
  - ノード間: MPI
- オンメモリ処理
  - ファイルを介さないので高速、一方で耐故障性には劣る
- 京コンピュータのネットワーク・ストレージ構成を意識した性能最適化
  - KVデータサイズに応じたShuffle通信手法の切り替え
  - 通信とIOを組み合わせた、高速な集団ファイル読み込み
- 対応言語
  - ライブラリ使用時: C/C++, Fortran
  - コマンド使用時: ノードがサポートする任意の言語

# KMRのメリット

- MapReduceモデルを用いた、大規模並列システムでの容易な並列プログラミングモデル
  - 逐次処理のみの実装で、大規模並列実行可能
- 並列プログラミングを簡易化
  - Master-Workerタイプ計算の実行
  - パラメータ設定の簡易な集団通信
- 京コンピュータ利用時の複雑さを隠蔽
  - ネットワークアーキテクチャを考慮し、メッセージサイズに応じて集団通信アルゴリズムを自動切替
  - ストレージアーキテクチャを考慮し、IOノードへの負荷を削減するファイル読み込みを実施
  - MPI\_Comm\_spawnの動的プロセス終了の待ち時間調整

# KMRのメリット - 計算

- マルチノード・マルチコアを用いた自動並列
  - KMRではKVを自動的にコア単位で複数ノードに割り振り、Map/Reduce処理を並列実行

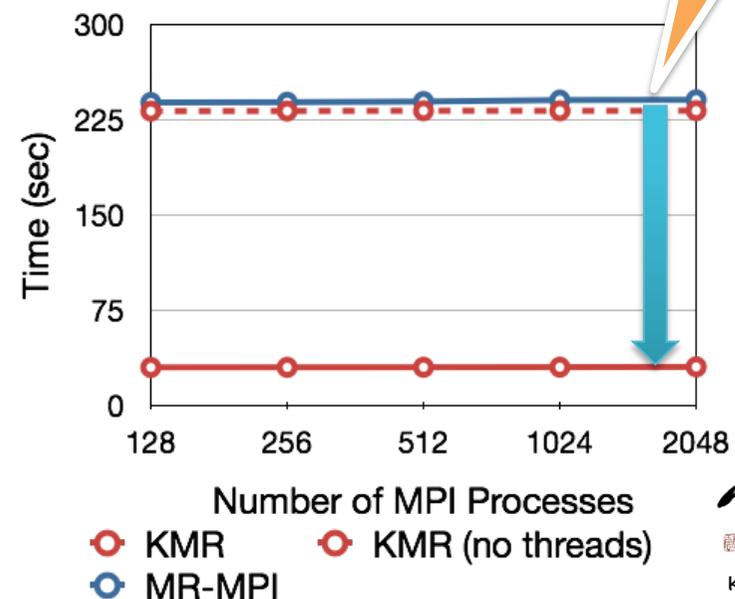
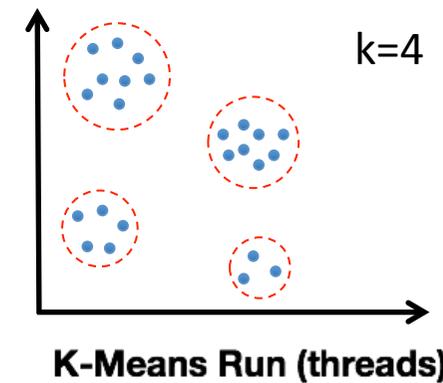
- 例) k-meansクラスタリング
  - データをk個のグループに分割
  - MR-MPIでは、ノード間並列は行わすが、コア間並列は行わない
    - MR-MPI: MPI実装されたMapReduce

## 実行環境

- 京コンピュータ (8CPU/Node)
- 1 MPI Proc/Node

## 実行設定

- Points: 100,000/Proc
- Clusters: 10,000
- 4次元座標
- 繰り返し回数: 10



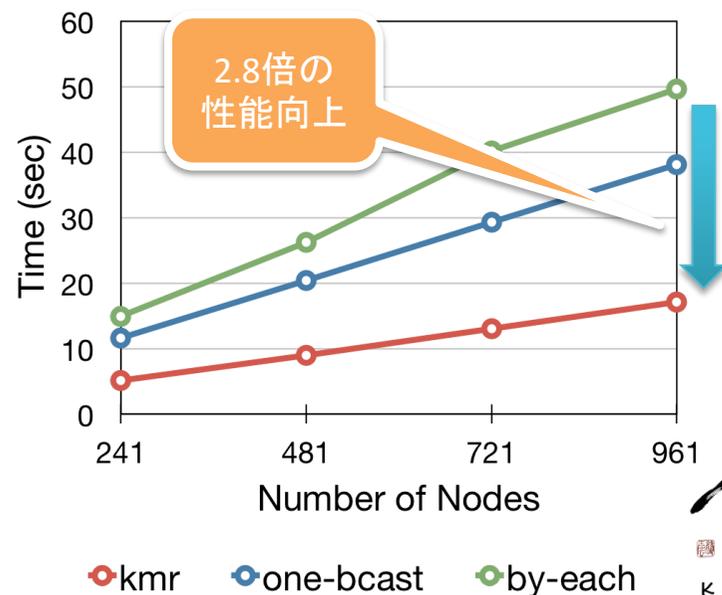
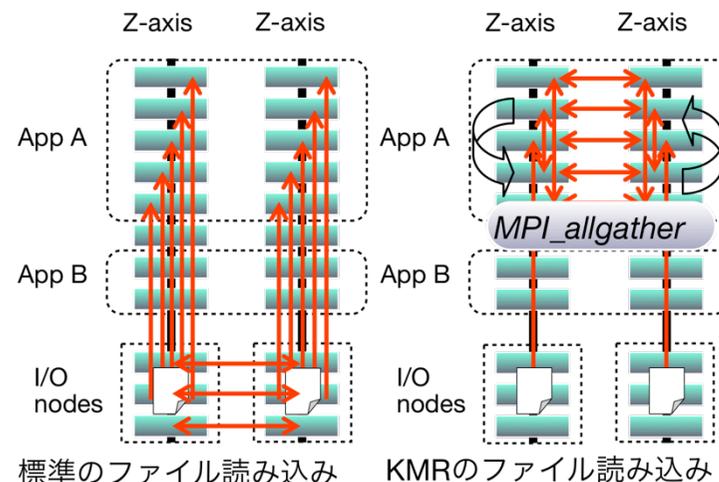
# KMRのメリット – ファイルアクセス

- IOアクセス競合を避け、ファイル読み込み性能を向上

- 計算ノードを、グループ単位でIO数を制限することによりIOノードへのアクセスを削減
- 計算ノード間で集団通信によるファイルの共有

- 1GBゲノムファイル読み込み

- 京の各ノードから、同一ゲノムファイルを読み込む
- by-each:すべてのノードが個別に読み込む
- one-bcast:1ノードが読み込み、他ノードにbcast転送



# 導入方法

- ソースコードダウンロード
  - ホームページから **KMR-1.1 Release (2013-09-20)** をダウンロード

- 展開

```
$ tar xzf kmr-1.1.tar.gz  
$ cd kmr-1.1
```

- configure

```
$ ./configure
```

- 必要に応じてインストールパスを指定

```
$ ./configure --prefix=$HOME/lib/kmr-1.1
```

- make & install

```
$ make  
$ make install
```

# 京での利用

- /opt/aics/kmrにインストール済み
- ディレクトリ構成

```
/opt/aics/kmr
├── K-1.2.0-14
│   └── kmr-1.1
└── K-1.2.0-15
    └── kmr-1.1
```

- KMR更新時、または言語環境更新時にその時々バージョンにあったKMRをインストール

# Agenda

---

- MapReduceプログラミングモデル
- **K MapReduce (KMR)**
  - 概要・特徴・導入方法
  - **利用方法**
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

# 利用方法

- KMRShellによる簡易MapReduce実行
  - 1回のMapReduce計算を実行
  - 計算ノードがサポートする任意の言語で実装された逐次プログラムを実行可能
- KMRライブラリを用いたプログラミング
  - MapReduceモデルに従った任意のワークフローを実装可能
  - KMRの全機能を利用可能
  - C/C++, Fortranにてプログラムを実装

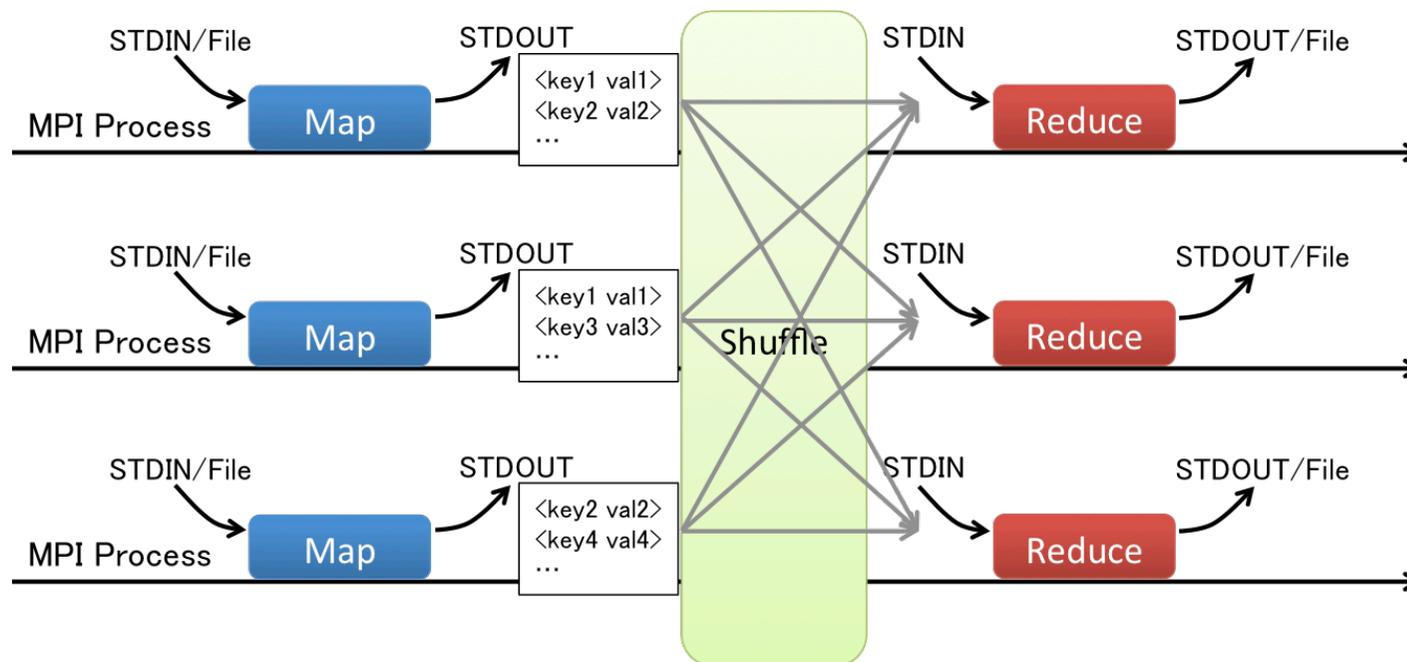
# Agenda

---

- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

# KMRShell (1/2)

- 1回のMapReduce計算を実行
- Mapper (Map用プログラム)、Reducer (Reduce用プログラム)は任意の言語で実装可能
- 動作の流れ



# KMRShell (2/2)

- 実行コマンド

```
$ mpirun -np 12 ./kmrshell -m mapper.sh ¥  
-r reducer.sh ./data
```

- 各パラメータの意味

-np 12	使用するMPIプロセス数。 Mapper/Reducerの実行数に相当。
./kmrshell	KMRShellプログラム本体。 KMR_INST/lib/kmrshellにインストールされている。
-m mapper.sh	Mapperプログラム
-r reducer.sh	Reducerプログラム
./data	Mapperの入力ファイル、またはディレクトリ。 全MPIプロセスに同じパスが渡されるため、プロセス 毎に入力ファイルを変えたい場合には、異なる内容の ファイルを同一パスにおくこと。 (マシンローカルストレージの利用を前提)

# Mapper/Reducer実装上の制約

- Mapper
  - [任意] 標準入力から入力データを読み込む
    - 別途ファイルから読み込んでも可
  - [必須] 標準出力に結果となるKVを出力
    - KeyとValueはスペース区切り
- Reducer
  - [必須] 標準入力から入力KVを読み込む
    - ShuffleされたMapper出力のKVが渡される
  - [任意] 標準出力/ファイルに結果を書き出す

# Word Count実装 (1/3)

- 設計

- Mapper

- 標準入力からテキストを受け取り、スペースで分割
    - 単語毎に”WORD 1”をKVとして標準出力に出力

- Reducer

- 単語毎に”WORD 1”をKVとして標準入力から読み込む
    - 単語毎に数を合計

- サンプルプログラムの場所

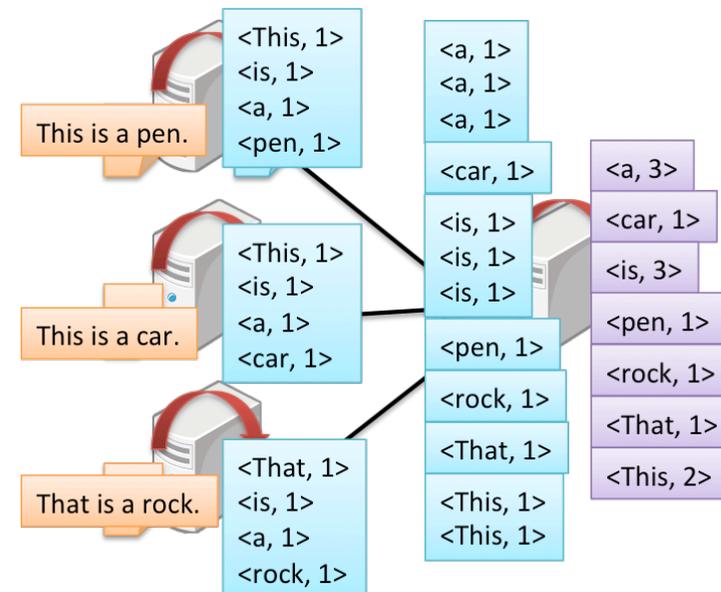
- Mapper

- KMR\_SRC/shell/wc.map.pl

- Reducer

- KMR\_SRC/shell/wc.reduce.pl

- Perlで実装



# Word Count実装 (2/3)

- Mapperの実装 – wc.map.pl

```
#!/usr/bin/perl  
use strict;
```

```
while(<STDIN>) {  
    chomp $_;  
    my @w = split(" ", $_);  
    foreach my $wd (@w) {  
        print $wd, " 1\n";  
    }  
}
```

標準入力からテキストを読み込む

テキストをスペースで分割

KV “WORD 1”を標準出力に出力

実行権限をつけて保存

# Word Count実装 (3/3)

- Reducerの実装 - wc.reduce.pl

```
#!/usr/bin/perl  
use strict;
```

```
my $counter;
```

```
while(<>) {  
    chomp $_;  
    my ($key, $value) = split " ";  
    $counter->{$key} += $value;  
}
```

標準入力からKVを読み込む

ハッシュ(counter)にKeyとして単語、  
値としてその数(常に1)を加える

単語とその数を出力

```
for (sort { $counter->{$a} <=> $counter->{$b} } keys %$counter) {  
    print $_, " ", $counter->{$_}, "\n";  
}
```

実行権限をつけて保存

# Word Countの実行： インタラクティブ実行

## 1. ワーキングディレクトリに実行ファイル群をコピー

```
$ cp KMR_INST/lib/kmrshell .  
$ cp KMR_INST/lib/kmrshuffler .
```

## 2. Mapper, Reducer, 入力ファイルの用意

```
$ vi wc.map.pl  
$ vi wc.reduce.pl  
$ cp KMR_SRC/LICENSE ./inputfile (KMRのライセンスファイル)
```

## 3. ディレクトリ内容

```
$ ls .  
inputfile kmrshell kmrshuffler wc.map.pl wc.reduce.pl
```

## 4. 実行 - 4並列

```
$ mpirun -np 4 ./kmrshell -m ./wc.map.pl ¥  
-r ./wc.reduce.pl ./inputfile
```

# Word Countの実行：京でランクディレクトリを使用して実行

## 1. Mapper, Reducerの用意

```
$ vi wc.map.pl  
$ vi wc.reduce.pl
```

## 2. 入力ファイルを分割

```
$ KMR_INST/bin/kmrfsplit.py -f -n 4 -d data KMR_SRC/LICENSE  
$ ls data  
part0 part1 part2 part3
```

## 3. ジョブスクリプト作成

```
$ KMR_INST/bin/kmrgenscript.py -e 4 -d data ¥  
-m wc.map.pl -r wc.reduce.pl -w job.sh  
$ ls  
data job.sh wc.map.pl wc.reduce.pl
```

## 4. 実行 - 4並列

```
$ pjsub job.sh
```

# Word Countの実行：京でランクディレクトリを使用して実行

## • 生成されるジョブスクリプト

```
#!/bin/bash -x
#
#PJM --rsc-list "node=4"
#PJM --rsc-list "elapse=00:10:00"
#PJM --rsc-list "proc-core=unlimited"
#PJM --stg-transfiles "all"
#PJM --mpi "use-rankdir"
#PJM --stgin "rank=* /KMR_INST/lib/kmrshell %r:./"
#PJM --stgin "rank=* wc.map.pl %r:./"
#PJM --stgin "rank=* /KMR_INST/lib/kmrshuffler %r:./"
#PJM --stgin "rank=* wc.reduce.pl %r:./"
#PJM --stgin "rank=* data/part%01r %r:./input"
#PJM --stgout "rank=* %r:./output.%r ./output.%01r"
#PJM --stgout "./core* ./"
#PJM -S

. /work/system/Env_base

mpiexec -n 4 -of-proc output ./kmrshell -m ./wc.map.pl -r ./wc.reduce.pl ./input
```

# KMRShellヘルパープログラム

- `kmrfsplit.py`
    - テキストファイルを指定した数に分割
    - デフォルトの区切り文字は「改行」
  - `kmrgenscript.py`
    - 京コンピュータ用のジョブスクリプトを生成
  - `kmrwrapper.py`
    - `kmrfsplit.py` と `kmrgenscript.py` を立て続けに実行
- 
- 全てKMRインストールディレクトリ下のbin/に存在
  - 使い方の詳細は各コマンドのManpage、または「-h」をつけて実行

# KMRShell コツと注意点 (1/3)

- ファイル内容ではなく、ファイル名をMapperに渡したい
  - kmrshellの最後のパラメータとして与えられるファイルからは、その内容がMapperに渡されます。別途Mapperの引数としてファイル名を指定する必要があります。

```
$ mpirun -np 4 ./kmrshell -m “./wc.map.pl inputfile” ¥  
-r ./wc.reduce.pl ./dummy
```

- Mapperを、コマンドライン引数から入力ファイル名を取得するよう実装
- kmrshellの入力(./dummy)は空ファイル・ディレクトリ

# KMRShell コツと注意点 (2/3)

- Mapperだけを実行したい
  - 結果をReduceする必要なく、異なるパラメータで複数の計算を実行したい場合など、Reducer実行が不要な場合があります。その時には空のReducerを指定してください。

```
$ mpirun -np 4 ./kmrshell -m ./wc.map.pl -r ./dummy.sh ¥  
./inputfile
```

- dummy.shは実行権限がついた、空のシェルスクリプト

```
$ cat dummy.sh  
#!/bin/sh
```

複数の計算を1つのジョブとしてまとめて実行したいときに有効

# KMRShell コツと注意点 (3/3)

- Mapper/Reducerの計算量を考慮して並列度 (-np) を指定する
  - Mapper/Reducer共に同じ並列度で動作します
  - 入力ファイル (Mapperへの入力) がたくさんあるが、出力するKeyの数が少ない場合、高い並列度を指定すると、Reduce時に資源の無駄が生じ得ます (逆もしかり)
    - 例) 入力ファイルは1,000個、Map結果の出力Keyは10個  
=> 並列度1,000で実行すると、Reduceにて990の無駄
- Reduce結果はソートされない
  - HadoopではReduce結果はソートされて出力されるが、KMRではソートしません
- MPIで動作しているので、1プロセスで障害が起こると、全体の実行が中断する

# Agenda

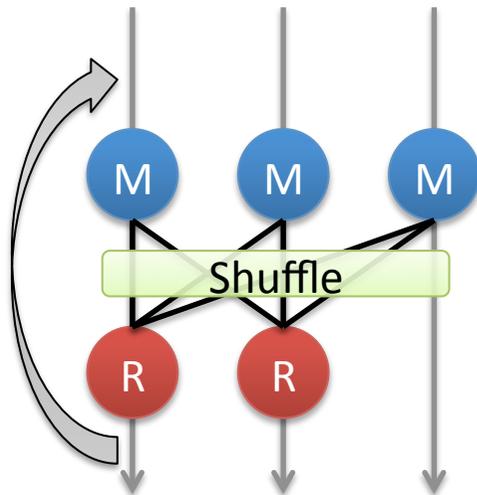
---

- MapReduceプログラミングモデル
- **K MapReduce (KMR)**
  - 概要・特徴・導入方法
  - **利用方法**
    - KMRShellによる簡易MapReduce実行
    - **KMRライブラリを用いたプログラミング**
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

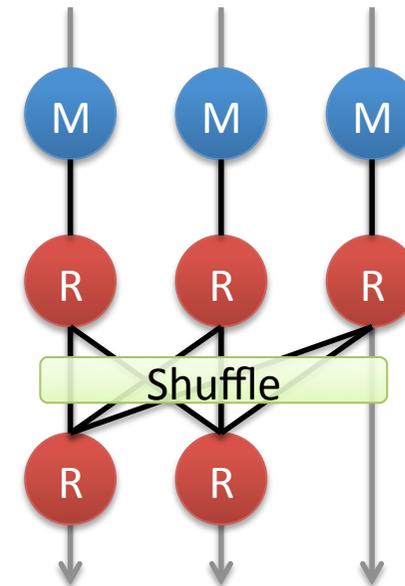
# KMRライブラリ

- MapReduceプログラミングモデルに従った任意のワークフローを実装可能
  - MapReduceの繰り返し実行
  - Combiner (Shuffle前にReduce) 実行

Iterative MapReduce



Combiner



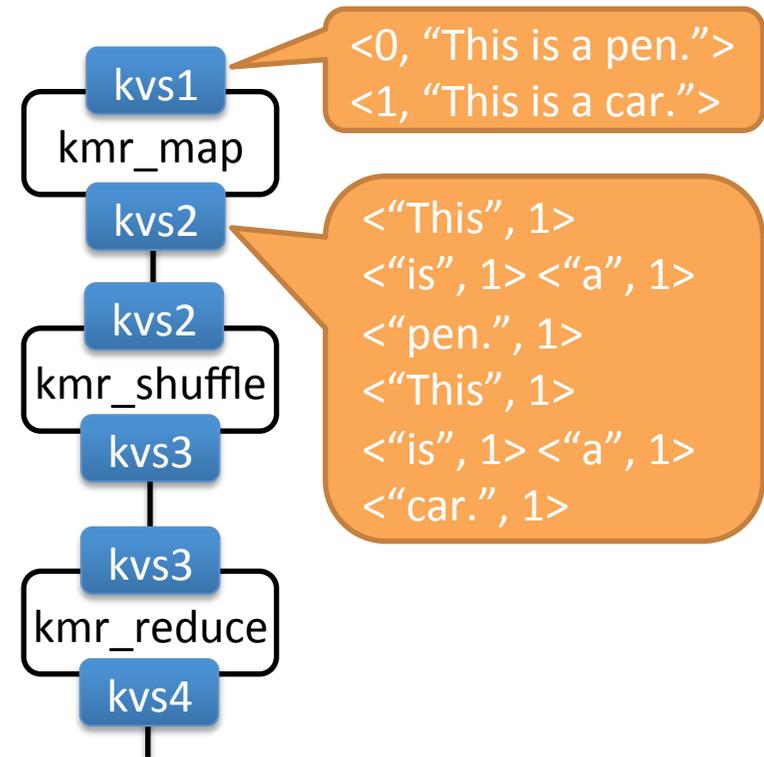
- C/C++, Fortranにてプログラムを実装

# 実装するもの

- Mapper関数
  - Map処理として実行される関数
  - 入力：1つのKV、またはファイル、メモリ上の変数
  - 出力：1つ以上のKV
- Reducer関数
  - Reduce処理として実行される関数
  - 入力：同じKeyを持つ、複数のKV
  - 出力：1つ以上のKV
- ドライバ関数 (main関数)
  - KMR実行の初期化、終了処理
  - KMR関数群を呼び出し、MapReduce計算処理を実装

# KMRの処理の流れ

- **Key-Value Store (KVS)とは**
  - 0個以上のKVを保持するメモリ上のデータ構造
  - KVSを単位にMapper、Reducerを実行
    - 1つのKVSを入力とし、個々のKVにMapper/Reducer実行し、結果を出力KVSに書き込む



- KMRライブラリを用いたプログラミングは、KVSの変化の流れを記述すること
  - ドライバ関数に記述

# ドライバ関数の実装

- 一連のMapReduce処理を行うプログラム

```
#include <mpi.h>
#include "kmr.h"

int main(int argc, char **argv) {
    MPI_Init(&argc, &argv);
    kmr_init();
    KMR *mr = kmr_create_context(MPI_COMM_WORLD, MPI_INFO_NULL, 0);

    KMR_KVS *kvs0 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs1 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs2 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs3 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    kmr_map(kvs0, kvs1, 0, kmr_noopt, mapfn);
    kmr_shuffle(kvs1, kvs2, kmr_noopt);
    kmr_reduce(kvs2, kvs3, 0, kmr_noopt, redfn);

    kmr_free_context(mr);
    kmr_fin();
    MPI_Finalize();
    return 0;
}
```

# ドライバ関数の実装

- 一連のMapReduce処理を行うプログラム

```
#include <mpi.h>
#include "kmr.h"

int main(int argc, char **argv) {
    MPI_Init(&argc, &argv);
    kmr_init();
    KMR *mr = kmr_create_context(MPI_COMM_WORLD, MPI_INFO_NULL, 0);

    KMR_KVS *kvs0 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs1 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs2 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs3 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    kmr_map(kvs0, kvs1, 0, kmr_noopt, mapfn);
    kmr_shuffle(kvs1, kvs2, kmr_noopt);
    kmr_reduce(kvs2, kvs3, 0, kmr_noopt, redfn);

    kmr_free_context(mr);
    kmr_fin();
    MPI_Finalize();
    return 0;
}
```

MPIの1ライブラリなので、MPIのヘッダファイル読み込み、MPI初期化・終了処理を実装

# ドライバ関数の実装

- 一連のMapReduce処理を行うプログラム

```
#include <mpi.h>
#include "kmr.h"

int main(int argc, char **argv) {
    MPI_Init(&argc, &argv);
    kmr_init();
    KMR *mr = kmr_create_context(MPI_COMM_WORLD, MPI_INFO_NULL, 0);

    KMR_KVS *kvs0 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs1 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs2 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs3 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    kmr_map(kvs0, kvs1, 0, kmr_noopt, mapfn);
    kmr_shuffle(kvs1, kvs2, kmr_noopt);
    kmr_reduce(kvs2, kvs3, 0, kmr_noopt, redfn);

    kmr_free_context(mr);
    kmr_fin();
    MPI_Finalize();
    return 0;
}
```

KMRの初期化・終了処理

# ドライバ関数の実装

- 一連のMapReduce処理を行うプログラム

```
#include <mpi.h>
#include "kmr.h"

int main(int argc, char **argv) {
    MPI_Init(&argc, &argv);
    kmr_init();
    KMR *mr = kmr_create_context(MPI_COMM_WORLD, MPI_INFO_NULL, 0);

    KMR_KVS *kvs0 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs1 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs2 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    KMR_KVS *kvs3 = kmr_create_kvs(mr, KMR_KV_OPAQUE, KMR_KV_OPAQUE);
    kmr_map(kvs0, kvs1, 0, kmr_noopt, mapfn);
    kmr_shuffle(kvs1, kvs2, kmr_noopt);
    kmr_reduce(kvs2, kvs3, 0, kmr_noopt, redfn);

    kmr_free_context(mr);
    kmr_fin();
    MPI_Finalize();
    return 0;
}
```

KVSの作成とMapReduce処理

# KVSの作成

- 空のKVS (KMR\_KVS型)を作成

```
KMR_KVS *kmr_create_kvs(KMR *mr, enum kmr_kv_field k,  
                        enum kmr_kv_field v);
```

- 第2引数でKeyの型、第3引数でValueの型を指定

KMR_KV_INTEGER	整数型 (int)
KMR_KV_FLOAT8	浮動小数点型 (double)
KMR_KV_OPAQUE	バイト列

- KVSを解放

```
int kmr_free_kvs(KMR_KVS *kvs);
```

- KMR関数 (kmr\_map, kmr\_reduce等) の入力となったKVSは自動で解放される

# Mapper実行関数の利用

- 入力KVS中の個々のKVに対して(利用者定義)Mapper関数を実行

```
int kmr_map(KMR_KVS *kvi, KMR_KVS *kvo, void *arg,  
           struct kmr_option opt, kmr_mapfn_t m);
```

KMR_KVS *kvi	入力KVS
KMR_KVS *kvo	出力KVS
void *arg	KVS以外の入出力データがあれば、 この変数にポインタとして指定 例)入力ファイル名
struct kmr_option opt	関数実行時のオプション 通常は「kmr_noopt」で可
kmr_mapfn_t m	利用者定義のMapper関数へのポインタ

- 関数終了後、入力KVSは解放される

# Mapper関数の実装

- Mapper関数型

```
int (*kmr_mapfn_t)(const struct kmr_kv_box kv,  
                  const KMR_KVS *kvi, KMR_KVS *kvo,  
                  void *arg, const long index);
```

struct kmr_kv_box kv	Mapperの処理対象KV
KMR_KVS *kvi	入力KVS(参照のみ)
KMR_KVS *kvo	出力KVS
void *arg	Mapper実行関数の第3引数として渡されたポインタ
long index	KVS中のKVのインデックス

– 個々のKVへの処理を定義する

# Mapper関数の実装 - 例

- k-means法 (KMR\_SRC/ex/kmeans-kmr.c)

- ある点1つが、どこの集合に属す

ポインタpにはk-means実行条件を保存

```
int calc_cluster(const struct kmr_kv_box kv,
                const KMR_KVS *kvi, KMR_KVS *kvo, long i) {
    int i;
    kmeans_t *kmeans = (kmeans_t *)p;
    int dim = kmeans->dim;
    int *means = kmeans->means;
    int n_means = kmeans->n_means;
    int *point = (int *)kv.v.p;
    int min_idx = 0;
    unsigned int min_dist = calc_sq_dist(point, &means[0], dim);

    for (i = 1; i < n_means; i++) {
        unsigned int dist = calc_sq_dist(point, &means[i], dim);
        if (dist < min_dist) {
            min_idx = i;
            min_dist = dist;
        }
    }

    struct kmr_kv_box nkvs = { .klen = sizeof(long),
                              .klen = sizeof(long),
                              .vlen = dim * sizeof(int),
                              .k.i = min_idx,
                              .v.p = (void *)point };

    kmr_add_kv(kvo, nkvs);
    return MPI_SUCCESS;
}
```

Valueに点の座標が保存されている

対象の点と、全ての集合との距離を計算し、最小の集合を選択

Keyに集合のID、Valueに点の座標、となるKVを生成し、出力KVSに追加

# 他の代表的なMapper実行関数

- ファイル等からKVを作成し、KVSに保存

```
int kmr_map_once(KMR_KVS *kvo, void *arg,
                struct kmr_option opt, _Bool rank_zero_only,
                kmr_mapfn_t m)
```

- Mapper関数(m)にて、ポインタ(\*arg)を参照してKVを作成
- Mapper関数(m)は1度しか実行されないため、1度の実行で必要なKVを全て作成すること
- MPIプログラムを実行し、その出力ファイルを元に作成したKVを出力KVSに保存

```
int kmr_map_via_spawn(KMR_KVS *kvi, KMR_KVS *kvo, void *arg,
                    MPI_Info info, struct kmr_spawn_option opt,
                    kmr_mapfn_t mapfn);
```

- 入力KVS(kvi)中のKVのValueにMPIプログラムを指定
- Mapper関数(mapfn)では、MPIプログラムの出力ファイルを読み込み、その内容に応じたKVを作成するよう実装

# Reducer実行関数の利用

- 入力KVS中の個々のKVに対して(利用者定義)Reducer関数を実行

```
int kmr_reduce(KMR_KVS *kvi, KMR_KVS *kvo, void *arg,
               struct kmr_option opt, kmr_redfn_t r);
```

KMR_KVS *kvi	入力KVS
KMR_KVS *kvo	出力KVS
void *arg	KVS以外の入出力データがあれば、 この変数にポインタとして指定 例)入力ファイル名
struct kmr_option opt	関数実行時のオプション 通常は「kmr_noopt」で可
kmr_redfn_t r	利用者定義のReducer関数へのポインタ

- 関数終了後、入力KVSは解放される

# Reducer関数の実装

- Reducer関数型

```
int (*kmr_redfn_t)(const struct kmr_kv_box kv[], const long n,  
                  const KMR_KVS *kvi, KMR_KVS *kvo,  
                  void *arg);
```

struct kmr_kv_box kv[]	Reducerの処理対象KV 全てのKVのKeyは等しい
long n	KVの数
KMR_KVS *kvi	入力KVS(参照のみ)
KMR_KVS *kvo	出力KVS
void *arg	Reducer実行関数の第3引数として 渡されたポインタ

– Keyの等しい、複数のKVへの処理を定義する

# Reducer関数の実装 - 例

- k-means法 (KMR\_SRC/ex/kmeans-kmr.c)
  - 集合の中心座標の更新

```
int update_cluster(const struct kmr_kv_box kv[], const struct kmr_kv_box *kvo,
                  const KMR_KVS *kvi, KMR_KVS *kvo) {
    int i, j;
    int cid = (int)kv[0].k.i;
    kmeans_t *kmeans = (kmeans_t *)p;
    int dim = kmeans->dim;
    int average[dim];

    for (i = 0; i < dim; i++)
        average[i] = 0;
    for (i = 0; i < n; i++) {
        int *point = (int *)kv[i].v.p;
        for (j = 0; j < dim; j++) {
            average[j] += point[j];
        }
    }
    for (i = 0; i < dim; i++)
        average[i] /= n;

    struct kmr_kv_box nkvs = {
        .klen = sizeof(long),
        .vlen = dim * sizeof(int),
        .k.i = cid,
        .v.p = (void *)average };

    kmr_add_kv(kvo, nkvs);
    return MPI_SUCCESS;
}
```

Keyは集合のID、Valueはその集合に属す点の座標

ポインタpにはk-means実行条件を保存

集合に含まれる全点の座標から、集合の中心座標を計算

Keyに集合のID、Valueに集合の中心座標、となるKVを生成し、出力KVSに追加

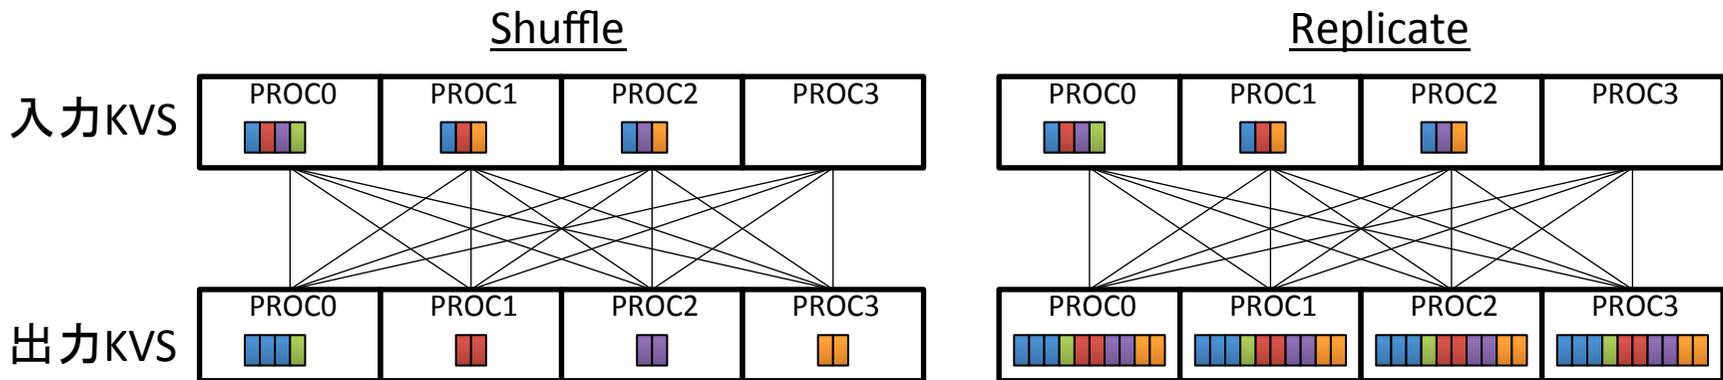
# 通信関数の利用

- ShuffleとReplicate

```
int kmr_shuffle(KMR_KVS *kvi, KMR_KVS *kvo, struct kmr_option opt);  
int kmr_replicate(KMR_KVS *kvi, KMR_KVS *kvo, struct kmr_option opt);
```

KMR_KVS *kvi	入力KVS
KMR_KVS *kvo	出力KVS
struct kmr_option opt	関数実行時のオプション 通常は「kmr_noopt」で可

- ReplicateはMapReduce実行結果のKVSを全プロセスで共有する時に有用



# 他の有用な関数

- KVSの中身をソート

```
int kmr_sort(KMR_KVS *kvi, KMR_KVS *kvo, struct kmr_option opt);
```

- 入力KVS(kvi)内のKVをKey順にソートし、出力KVS(kvo)に保存
- kmr\_reduceは結果をソートしないため、ソートした結果を必要とする場合には、Reduce後、この関数を実行

- マルチノード高速ファイル読み込み

```
int kmr_read_file_by_segments(KMR *mr, char *file, int color, void **buffer, off_t *size);
```

- ファイル(file)を読み込み、内容をメモリ(buffer)上に展開

# コンパイルと実行

- MPIコンパイラでコンパイル

- ヘッダファイル検索ディレクトリの指定、ライブラリとリンク

- 京、FX10

```
$ mpifccpx -Kopenmp,fast -I KMR_INST/include ¥  
SOURCE_CODE.c KMR_INST/lib/libkmr.a
```

- Linux/Solaris + gcc + OpenMPI

```
$ mpicc -O3 -I KMR_INST/include SOURCE_CODE.c ¥  
KMR_INST/lib/libkmr.a
```

- 実行

```
$ mpiexec -np 4 ./a.out
```

- 環境変数設定

```
$ cat kmrrc  
verbosity=9  
$ KMROPTION=kmrrc mpiexec -np 4 ./a.out
```

## 環境変数

verbosity	1~9を指定(デフォルトは5)。 数値を小さくすると、デバッグ 用メッセージを表示しなくなる
trace_map_spawn	0/1を指定(デフォルトは0)。 kmr_map_via_spawn() の実行をトレース

# サンプルプログラム

- KMR\_SRC/ex 以下にいくつか
  - 付属のMakefileにMakeターゲットが定義されています
  - 例)k-means法のサンプルプログラム (kmeans-kmr.c) のコンパイル

```
$ cd KMR_SRC/ex  
$ make kmeans
```

# KMRライブラリ 注意点

- Mapper/Reducerの計算量を考慮して並列度(-np)を指定する
  - Mapper/Reducer共に同じ並列度で動作します
  - 入力ファイル(Mapperへの入力)がたくさんあるが、出力するKeyの数が少ない場合、高い並列度を指定すると、Reduce時に資源の無駄が生じ得ます(逆もしかり)
    - 例) 入力ファイルは1,000個、Map結果の出力Keyは10個  
=> 並列度1,000で実行すると、Reduceにて990の無駄
- Reduce結果はソートされない
  - HadoopではReduce結果はソートされて出力されるが、KMRではソートしません
- MPIで動作しているので、1プロセスで障害が起こると、全体の実行が中断する

# Agenda

---

- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- **KMR利用事例**
  - **ゲノム解析**
  - **レプリカ交換分子動力学法**
- KMRの次期機能の紹介
- まとめ

# KMR利用事例

- 計算科学アプリケーションにKMRを適用した事例を紹介
  - アプリケーションのワークフロー (処理の流れ) を MapReduceモデルにて記述
- ゲノム解析
- レプリカ交換分子動力学法

# ゲノム解析

- ゲノム解析

- DNAシーケンサーにより読み取られた膨大なゲノムデータと、参照ゲノムデータ(既知のゲノム配列)の差異を解析

解析対象ゲノム

GATCGCG

ATGGCGAA

参照ゲノム

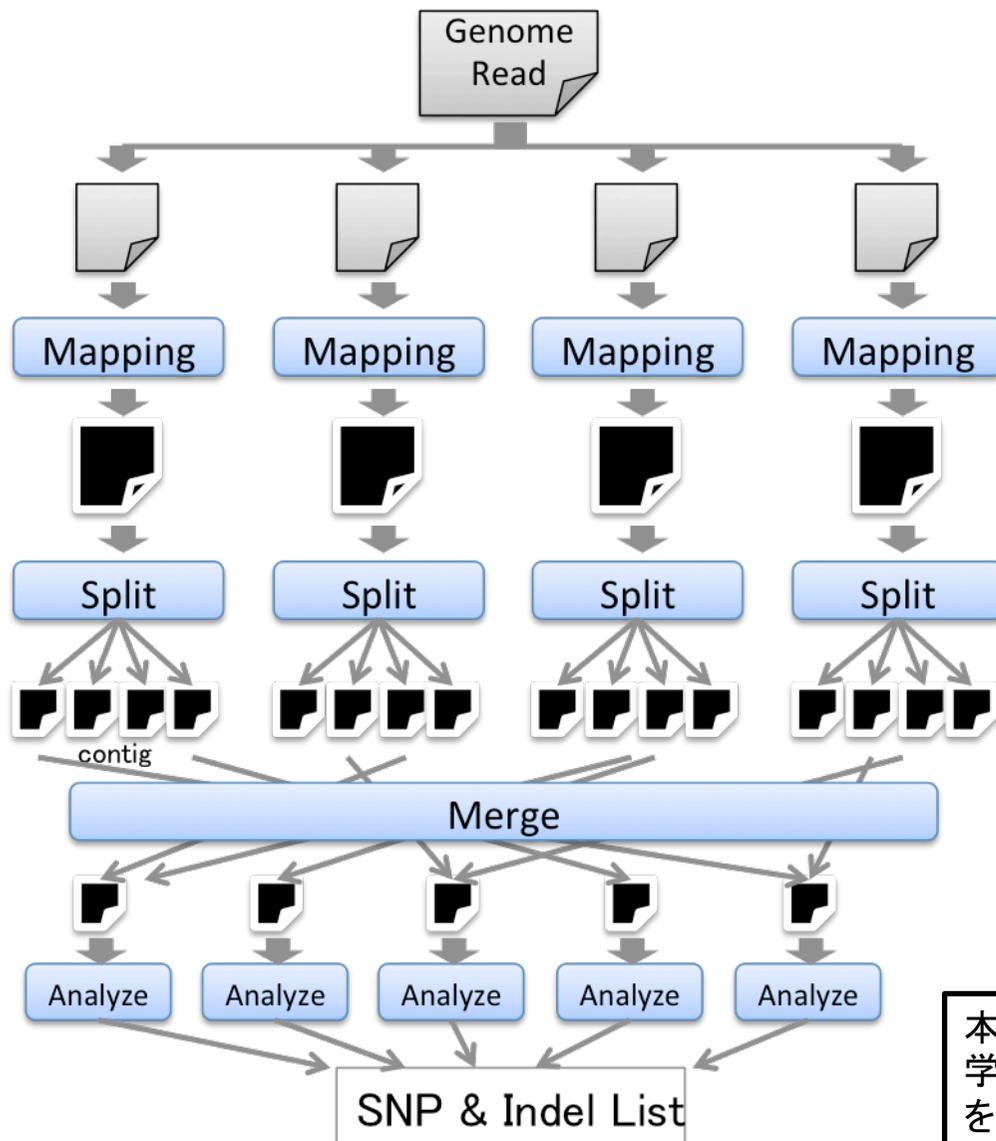
ATCGATGGCGAACTTAC...

- パイプライン実装

- 一連の解析を行うために、種々のツール群を組み合わせて実装

- シーケンスマッピングツール
- データフォーマットツール
- 解析ツール

# ゲノム解析：ワークフロー



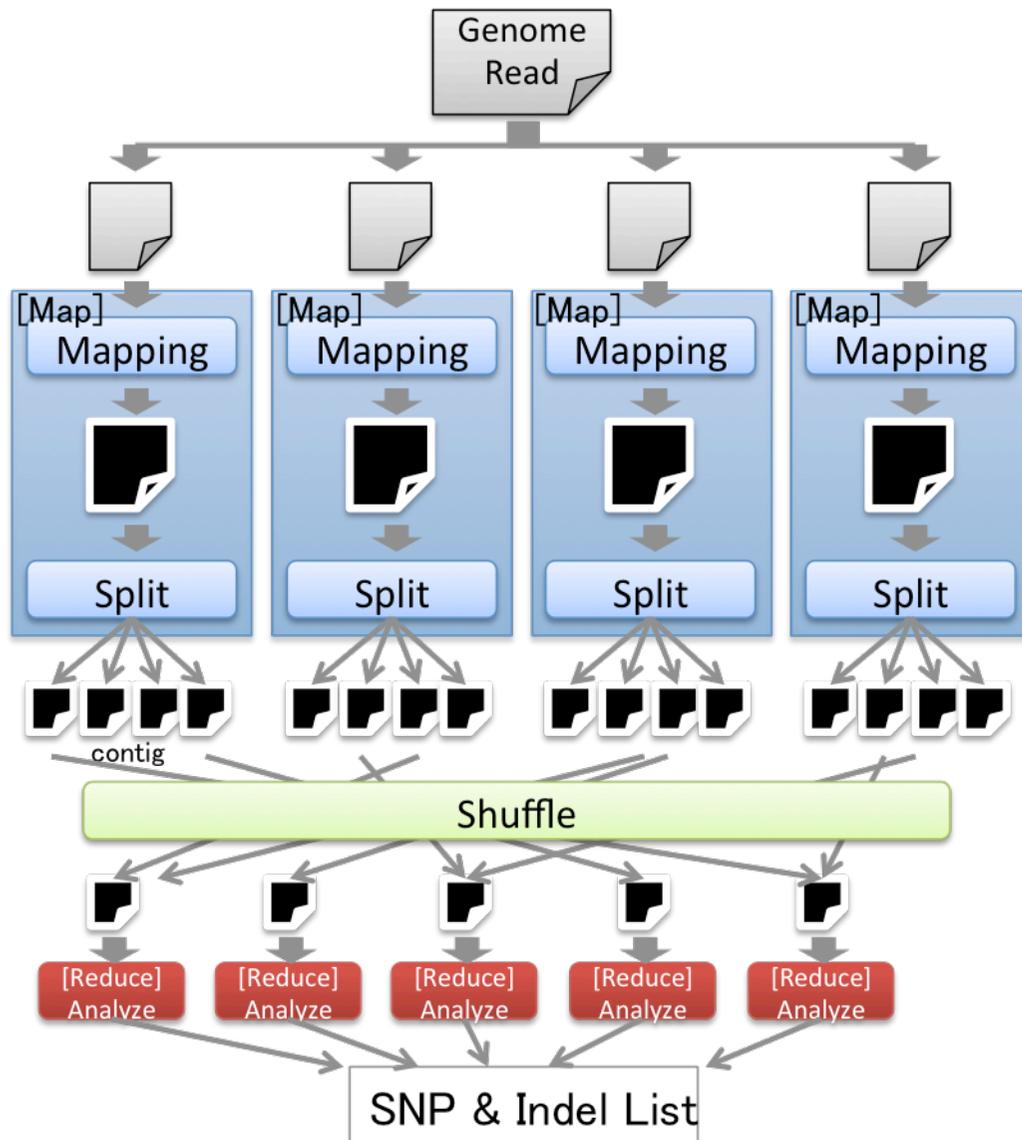
Mapping	リードを参照ゲノムにマッピング
Splits	contig (連続する塩基配列パターン) 毎にMapping結果を分割
Merge	contig毎に結果をマージ
Analyze	contig単位に変異解析

- 各タスク間のデータの受け渡しはファイルベース
- Mergeは共有ファイルシステム上で行われる

本ワークフローは、理化学研究所 統合生命医科学研究センターにて開発されているNGS Analyzerを参考に行っている

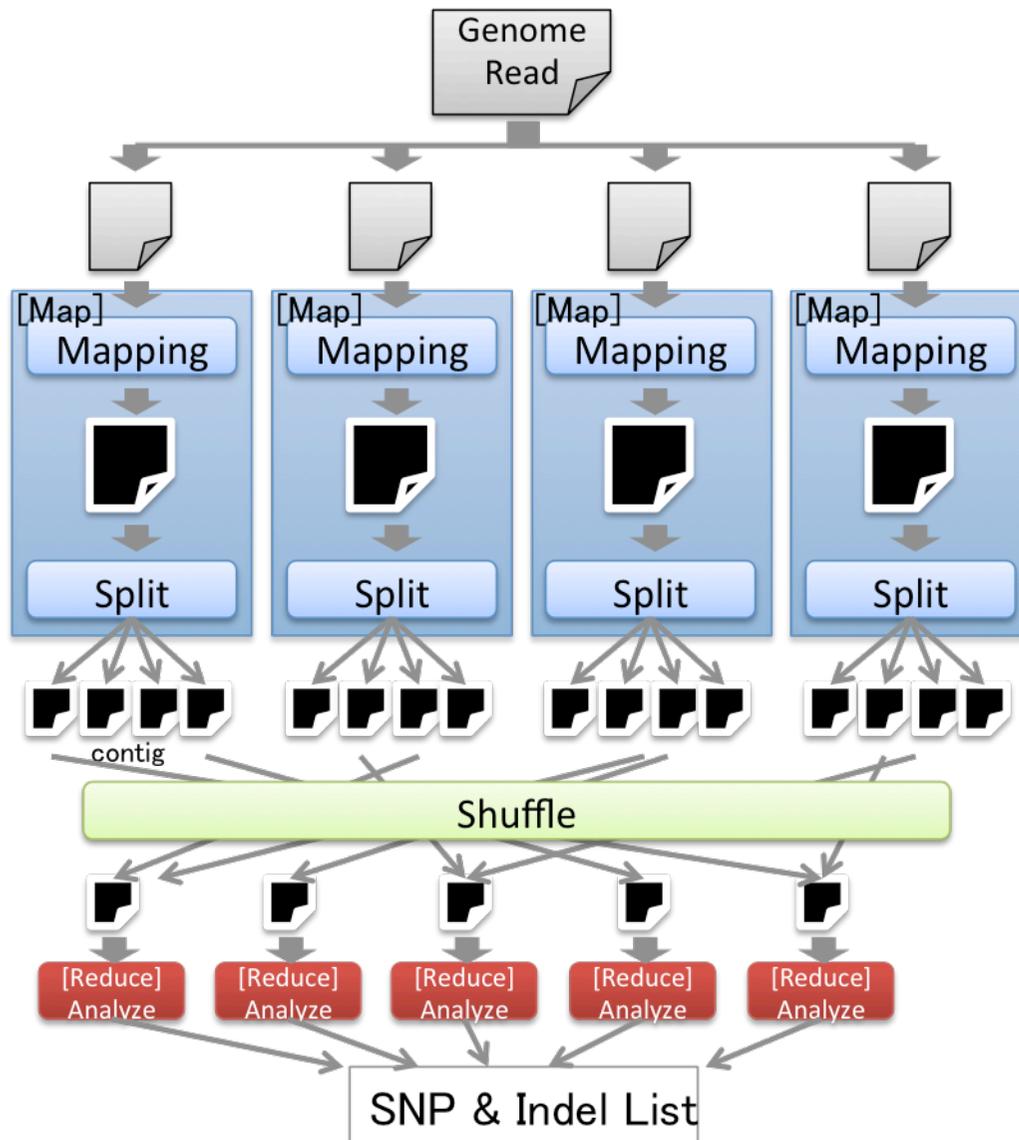


# ゲノム解析：MapReduce実装 (1/2)



- Map処理
  - MappingとSplitを実行
  - KV <contig, マッピング結果> を出力
- Reduce処理
  - KV <contig, マッピング結果> を入力
  - Anayzeを実行
- MergeはShuffleで置き換え
  - IOを伴わない、オンメモリ転送

# ゲノム解析：MapReduce実装 (2/2)



- KMRShellにて実装
  - Mapper/ReducerともにPythonにて逐次プログラムとして実装
    - ワークフロー実行管理はKMRShellが行う
  - 合計**111行**
    - NGS Analyzer: 748行
      - ワークフロー実行管理含む

# ゲノム解析：性能

- 日本人全ゲノム解析
  - ヒト一人全体で490GB
    - 25万配列毎にファイル分割、Mapperの入力へ
  - 参照ゲノム：6.3GB
- 実行環境：京コンピュータ
  - 1 MPIプロセス / ノード、16GBメモリ、ノード内並列なし
  - 1Mapper / ノードのタスク割り当て

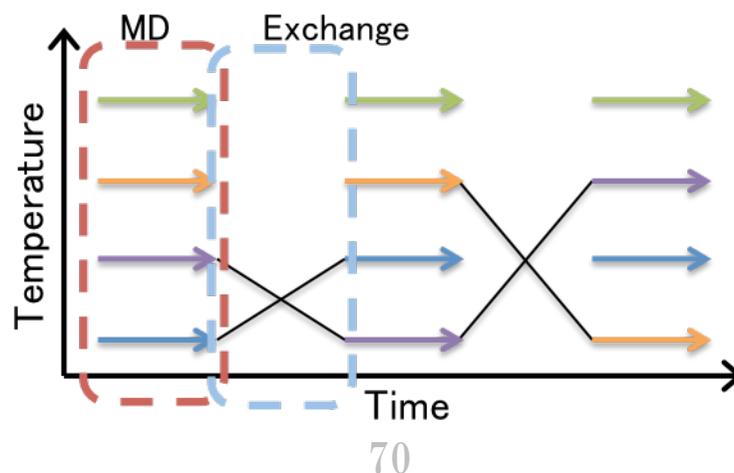
データサイズ	118 MB / 12 Nodes	87.9 GB / 512 Nodes	490 GB / 4160 Nodes
NGS Analyzer シェル	357秒	4,985秒	22,848秒
KMR実装	353秒	3,691秒	14,593秒

NGS Analyzerシェル：

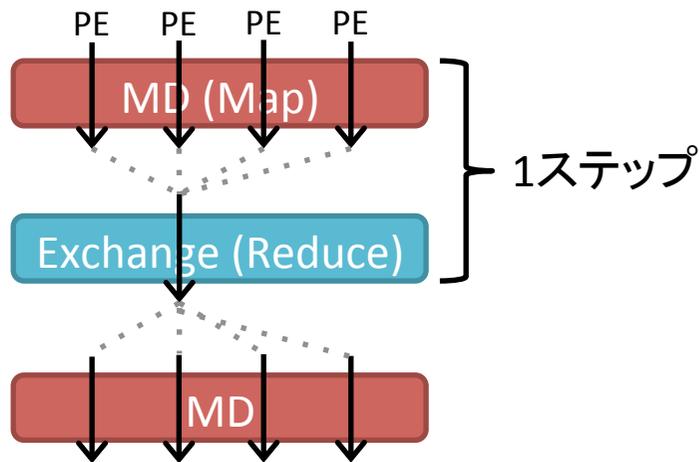
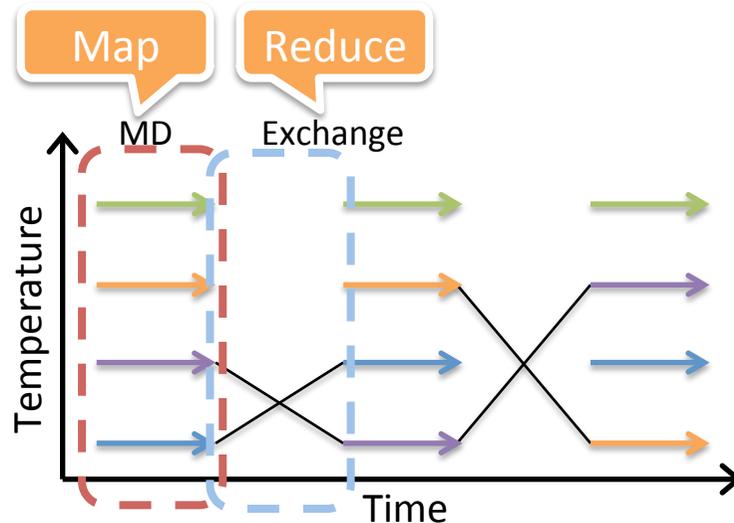
NGS Analyzerのワークフローを忠実に1つのシェルスクリプトとして実装(124行)

# レプリカ交換分子動力学法

- レプリカ交換分子動力学法 (REMD)
  - 創薬等で、タンパク質の構造解析に用いられる1手法
- ワークフロー
  - 分子構造の複数のレプリカを用意し、それぞれに異なる温度を割り振り、構造サンプリング (MD) を行う
  - MD実行後、レプリカの温度パラメータを交換 (Exchange)
  - 以上を繰り返し実行する、アンサンブル計算



# REMD: MapReduce設計



- REMDの1ステップを1 MapReduceとして実装
  - [Map] 複数プロセスで並列にMD計算
  - [Reduce] 1プロセスにMD結果を集約し、交換条件を計算
- REMDステップを繰り返し実行
  - Iterative MapReduce
  - 次のステップ開始前に、温度交換結果を全プロセスで共有

# REMD: KMR実装 (1/2)

- KMRライブラリを用いてFortranで実装

- Map処理

- MD実行条件を設定し、MDを実行

- MDには NAMD2 を使用 => `kmr_map_via_spawn()`にて起動

- 入力KV: <レプリカID, 入力ファイルパス>

- 出力KV: <0, レプリカIDとエネルギー>

- Reduce処理

- 温度交換の計算

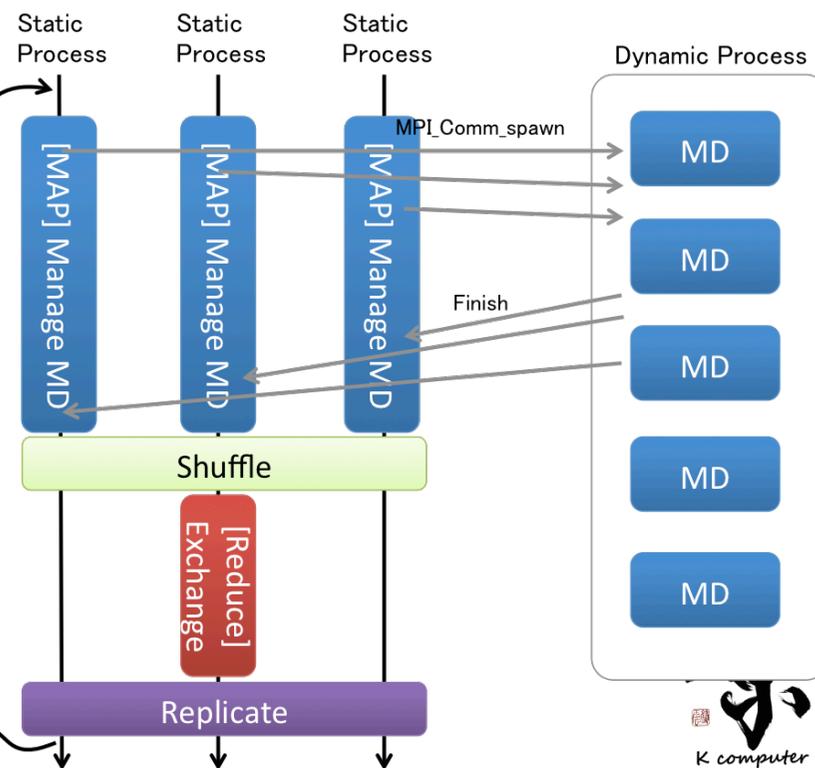
- 入力KV: <0, レプリカIDとエネルギー>

- 出力KV: <結果の種類を表す文字列, Exchange結果>

- 結果共有

- Reduce完了後、`kmr_replicate()`にて全プロセスで結果を共有

本実装は、理化学研究所 計算科学研究機構 粒子系生物物理研究チームにて開発されているREINを参考にしている。



# REMD: KMR実装 (2/2)

- 実際にはMap処理、Reduce処理双方にて、多数のMapper/Reducerを実行

- Map処理

MD入力ファイルの作成

- [入力] Key: Replica ID, Val: Replica ID
- [出力] Key: Replica ID, Val: MDコマンド

MD Rescaling

- [入力] Key: Replica ID, Val: MDコマンド
- [出力] Key: Replica ID, Val: MDコマンド

MD実行

- [入力] Key: Replica ID, Val: MDコマンド
- [出力] Key: Replica ID, Val: Replica ID

MD出力結果の取得

- [入力] Key: Replica ID, Val: Replica ID
- [出力] Key: Replica ID, Val: Replica ID

Shuffle用KVSの作成

- [入力] Key: Replica ID, Val: Replica ID
- [出力] Key: 0, Val: Replica ID & エネルギー

- Reduce処理

構造型へのレプリカ情報の書き込み

- [入力] Key: 0, Val: Replica ID & エネルギー
- [出力] Key: 0, Val: Replica ID

エネルギートラジェクトリファイルの作成

- [入力] Key: 0, Val: Replica ID
- [出力] Key: 0, Val: Replica ID

Exchange実行

- [入力] Key: 0, Val: Replica ID
- [出力] Key: 0, Val: Replica ID

リスタートファイルの作成

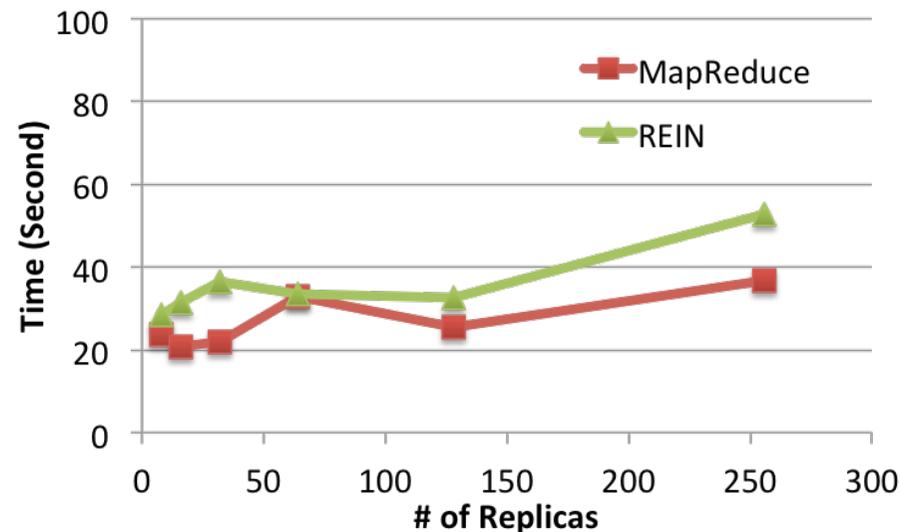
- [入力] Key: 0, Val: Replica ID
- [出力] Key: 0, Val: Replica ID

Replicate用KVSの作成

- [入力] Key: 0, Val: Replica ID
- [出力] Key: 文字列, Val: Exchange結果

# REMD: 性能

- 実行設定
  - データ: REIN 付属のサンプルデータ
    - 1次元REMD、10 Iteration
    - レプリカ数: 8, 16, 32, 64, 128, 256
- 実行環境: 京コンピュータ
  - 使用ノード数: 9, 18, 36, 72, 144, 288
    - レプリカ数に応じて設定
  - 1 MD 実行で使用するMPIプロセス数: 8 (1ノード)



# Agenda

---

- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- **KMRの次期機能の紹介**
- まとめ

# KMRの次期機能の紹介

---

- **KMRShell2**
  - KMRShellのタスク実行機能を強化
- **Checkpoint/Restart**
  - 耐故障機能の実装
- 5月下旬～6月にかけて公開

# KMRShell2

- 逐次プログラムだけでなく、MPIプログラムもMapper/Reducerとして実行
- 共有ディレクトリからのファイル読み込みをサポート
  - 複数入力ファイルがあるとき、各プロセスが異なるファイル进行处理するよう、ファイルを自動分配
- 仕様の変更
  - Mapperにはファイルコンテンツではなく、ファイル名を渡す

# Checkpoint/Restart

- 用途

- マシン障害が起きたとき、障害直前の状態から再開
- 最大ジョブ実行時間を超過したときに、その時点の状態から実行を続ける

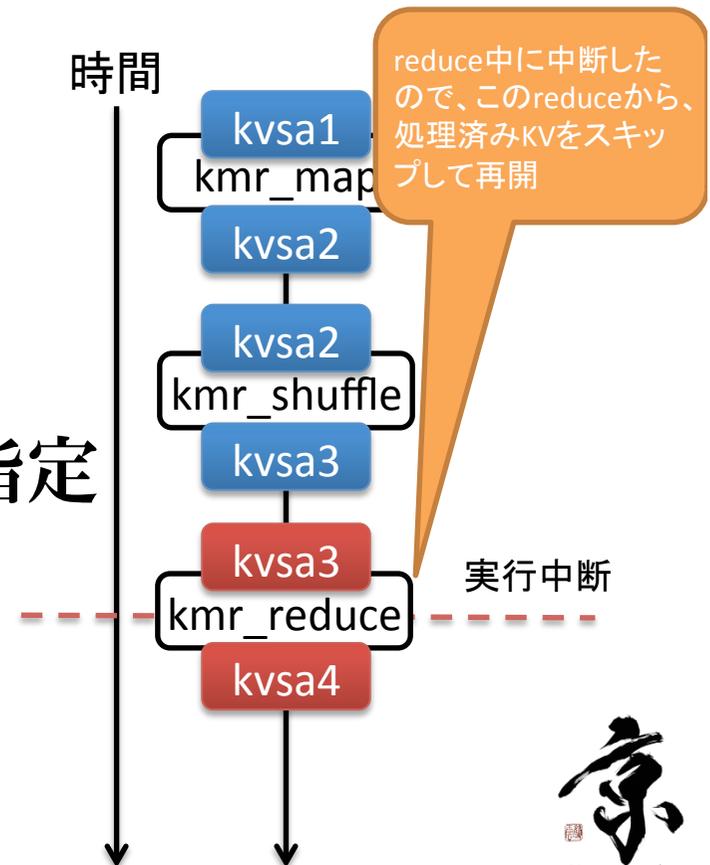
- 機能

- 実行状態の保存と復帰
- ノード数を変更(縮退)して再開

- 環境変数にて機能の有効・無効を指定

- プログラムの修正は不要

```
$ vi kmrrc
ckpt_enable=1
$ KMRPTION=kmrrc mpiexec -np 4 ./a.out
```



# Agenda

---

- MapReduceプログラミングモデル
- K MapReduce (KMR)
  - 概要・特徴・導入方法
  - 利用方法
    - KMRShellによる簡易MapReduce実行
    - KMRライブラリを用いたプログラミング
- KMR利用事例
  - ゲノム解析
  - レプリカ交換分子動力学法
- KMRの次期機能の紹介
- まとめ

# まとめ

- MapReduceプログラミングモデルの紹介
- KMRを用いたMapReduceプログラムの実行
  - KMRShellによる簡易実行
  - KMRライブラリを用いたプログラム実装
- KMR利用事例
  - KMRを用いたMapReduceモデルによる計算科学アプリケーションの実装例の紹介
    - ゲノム解析
    - レプリカ交換分子動力学法
- 次期KMRに実装される予定の機能紹介
  - KMRShellのタスク実行機能強化
  - CheckPoint/Restart機能

# おわり

---



## ご質問・お問い合わせ

丸山: nmaruyama

松田: m-matsuda

滝澤: shinichiro.takizawa

@riken.jp