並列分散ワークフローシステム Pwrakeによる天文データ処理

田中昌宏、建部修見（筑波大）

発表内容

- eサイエンス基盤
  - 広域分散ファイルシステム Gfarm
  - 並列分散ワークフロー実行システム Pwrake
- 天文学データ処理
  - ワークフローの記述
  - 性能評価

天文データの流れ

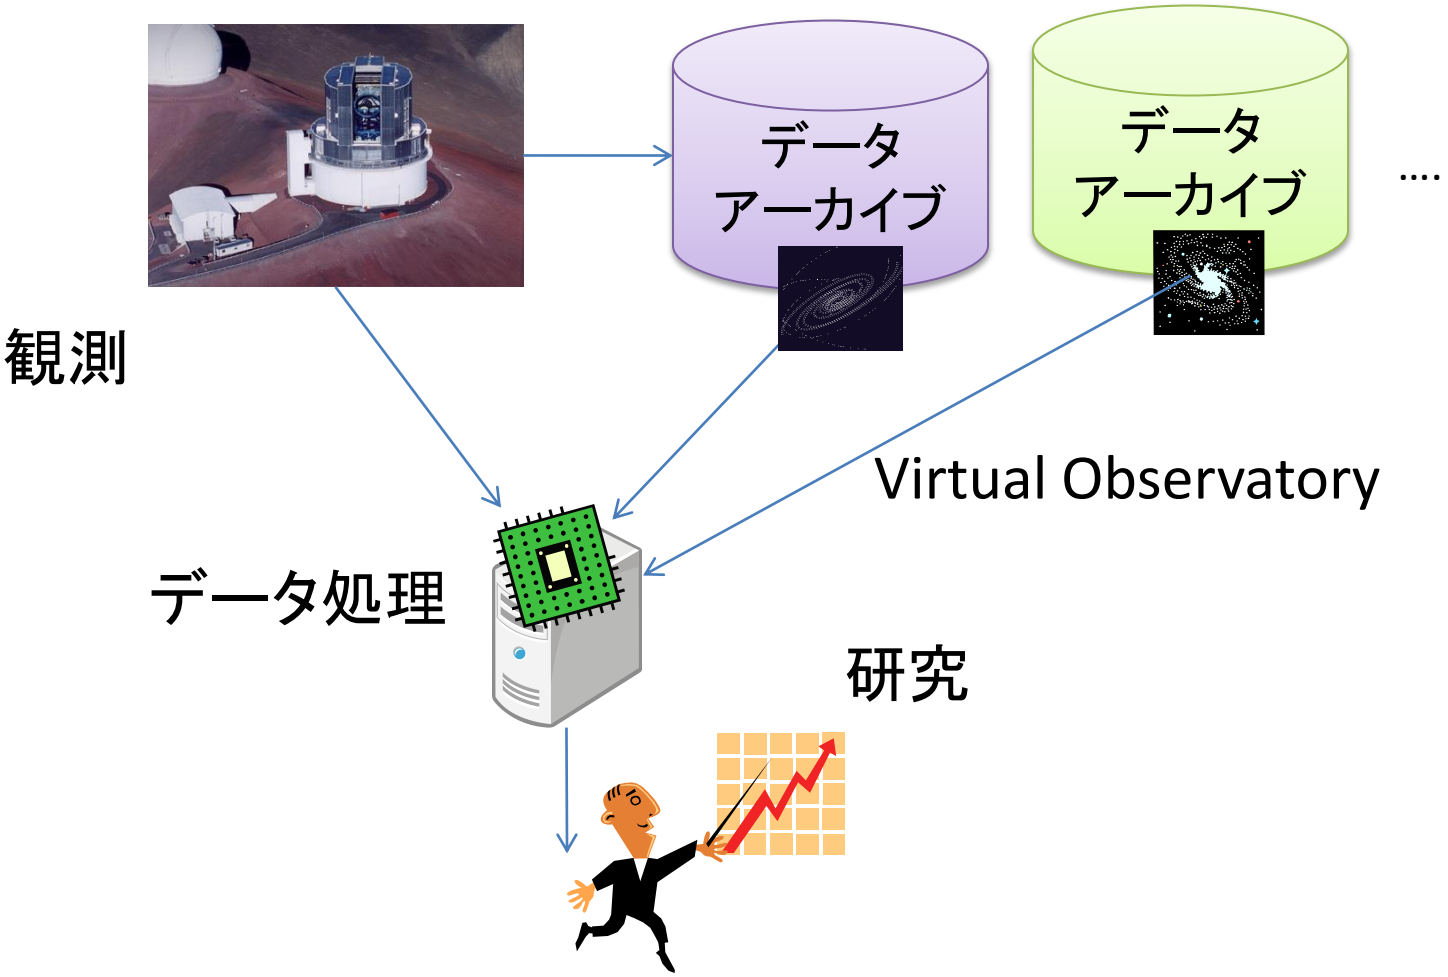

Gfarm 広域分散ファイルシステム

- 各ノードのストレージを統合
- 統一したディレクトリ空間
- 広域でファイルを共有
- http://datafarm.apgrid.org/

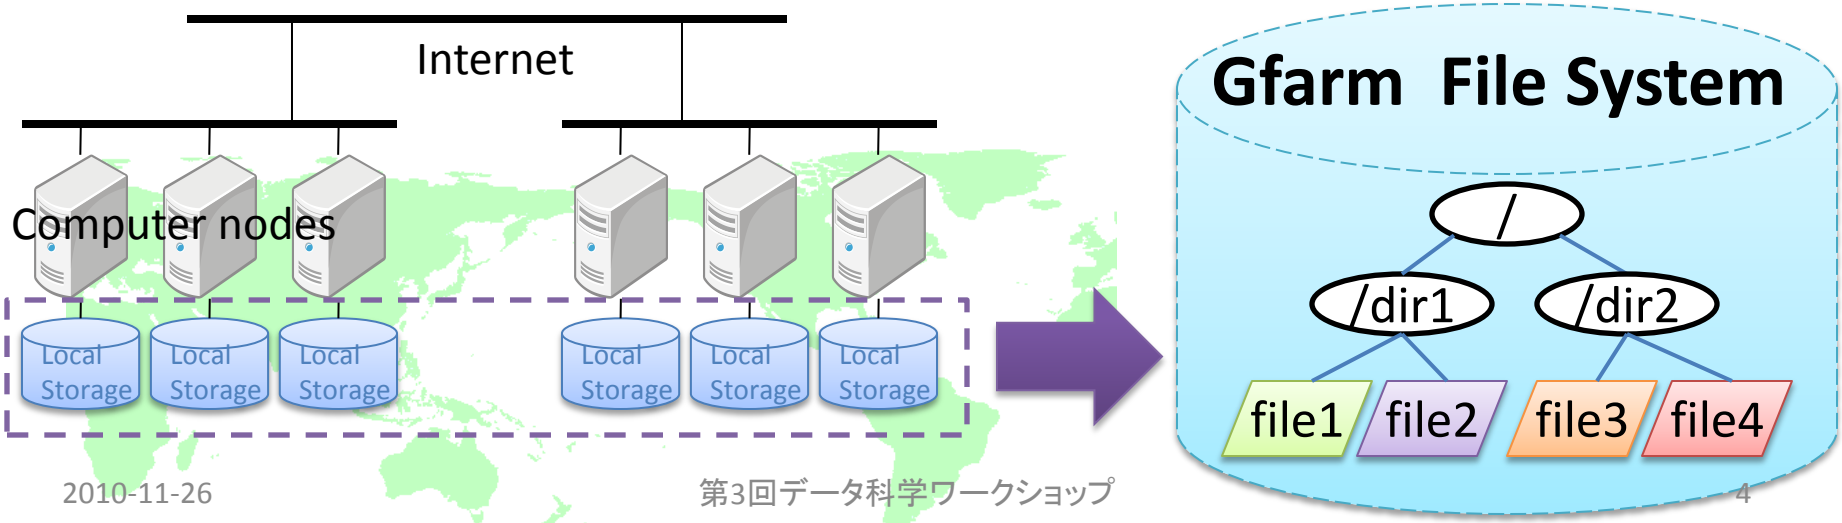

並列I/O性能の向上

- 集中型ファイルシステムでは、ストレージI/Oがボトルネック
- 分散ファイルシステムにより、スケーラブルな並列I/O性能が実現

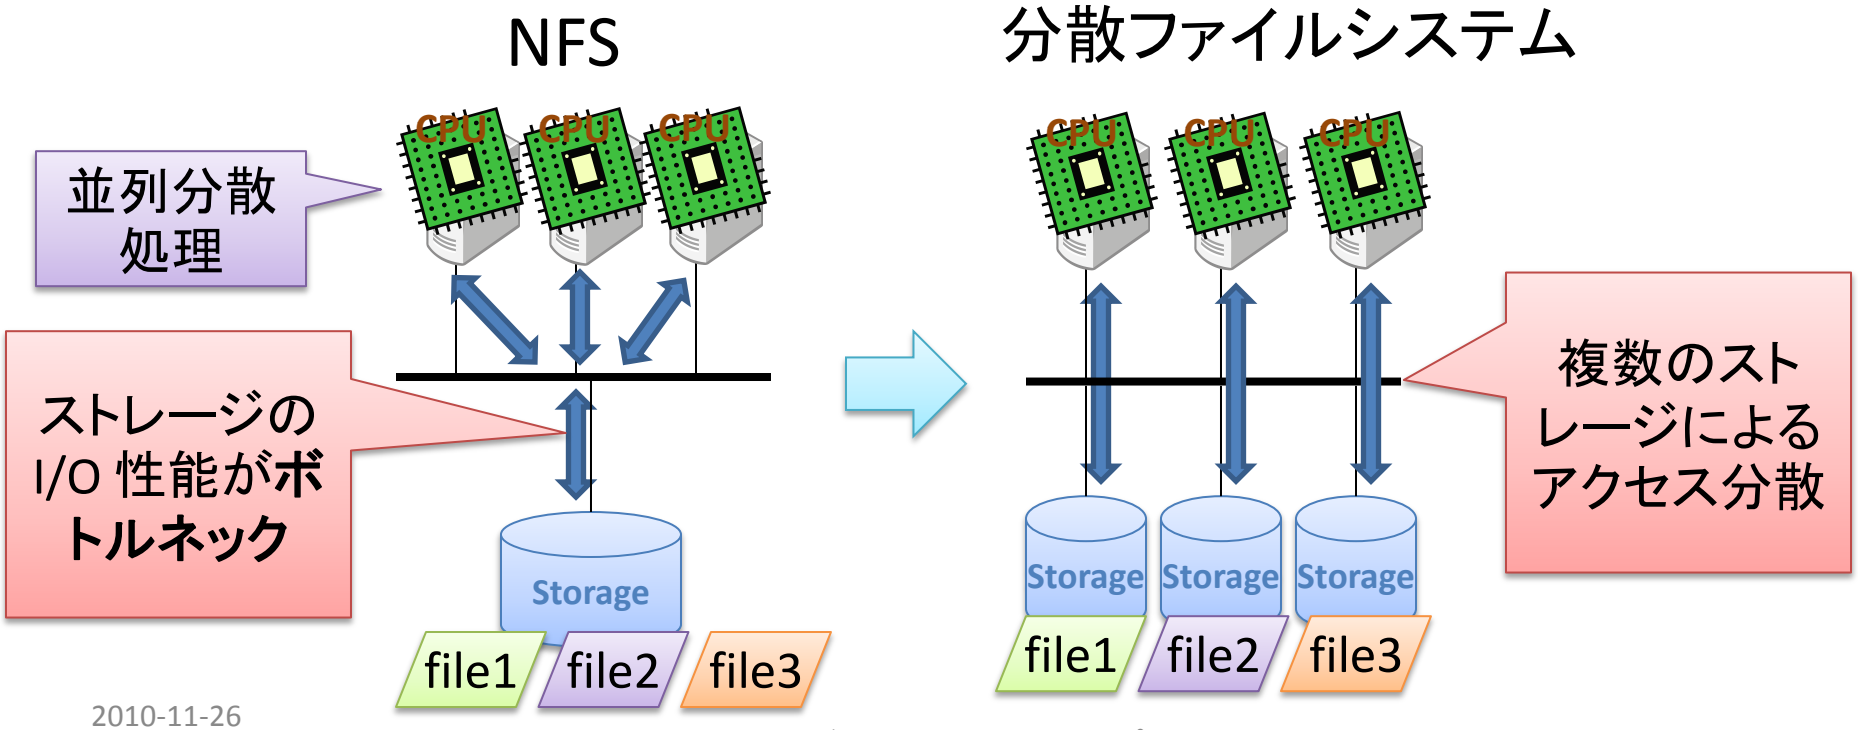

ローカリティを考慮したタスク実行

- Gfarmは、計算ノードとストレージノードを兼ねることができる
- ファイルが存在するノードで処理すれば、性能が向上
- タスク実行は、ワークフローシステムが行う

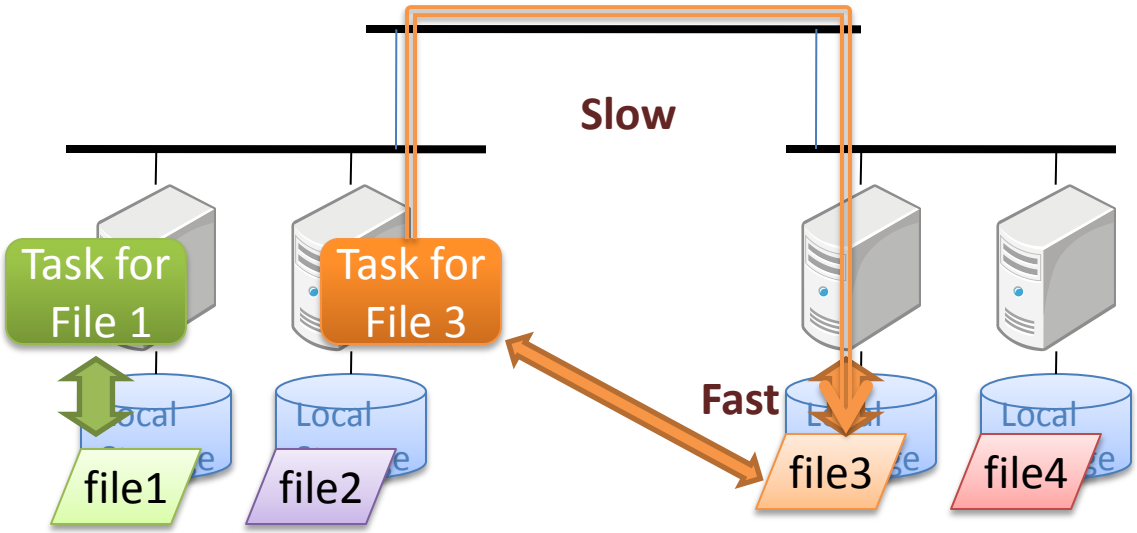

ワークフロー処理システム

- ワークフロー
  - タスク
  - 出力ファイル
  - 依存関係
- ワークフローシステム
  - ワークフロー定義に従って、タスクを各ノードで実行

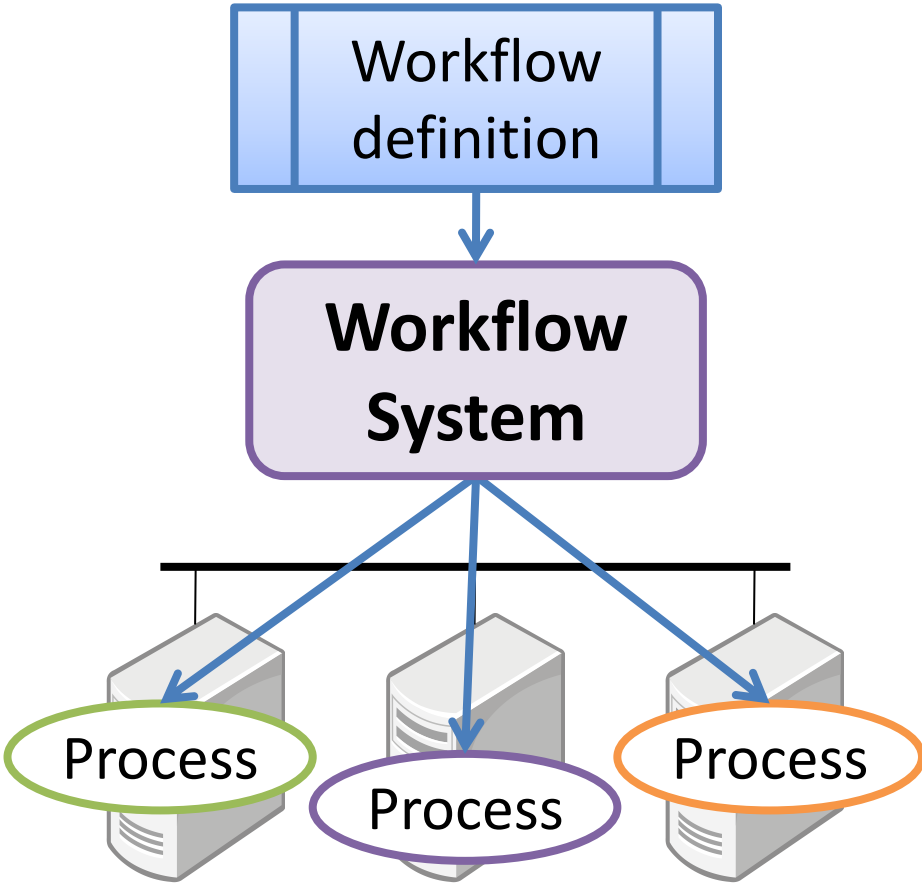

ワークフローの記述言語

- 課題
  - システムに詳しくない人でも記述できるか？
  - 複雑なワークフローを記述できるか？
  - 再利用可能か？

ワークフローのグラフ表現

- Task:　　頂点（楕円）
- File:　　頂点（四角）
- 依存関係:　辺

- **DAG**
  - **D**irected **A**cyclic **G**raph
  - 有向非循環グラフ

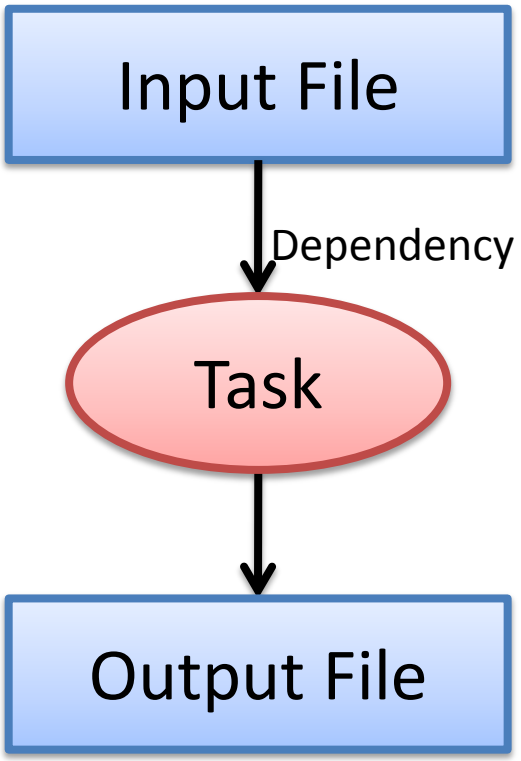

天文データ処理の例

- Montage
  - software for producing a custom mosaic image from multiple shots of images.
  - http://montage.ipac.caltech.edu/

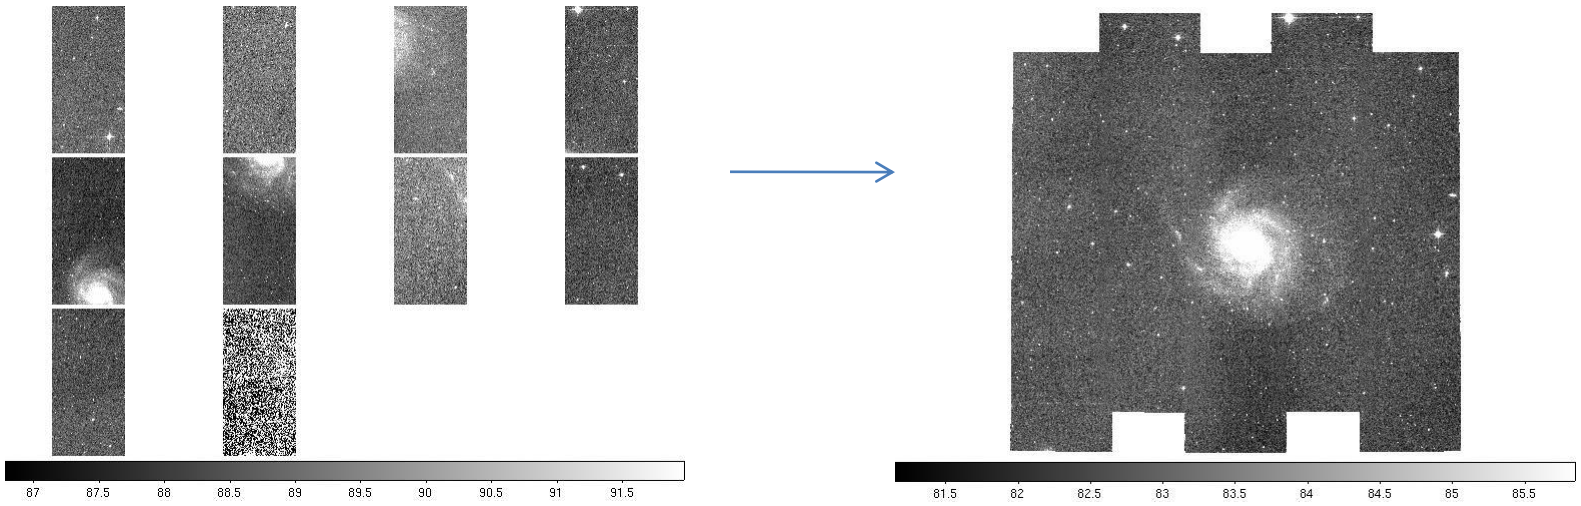

Montage Workflow

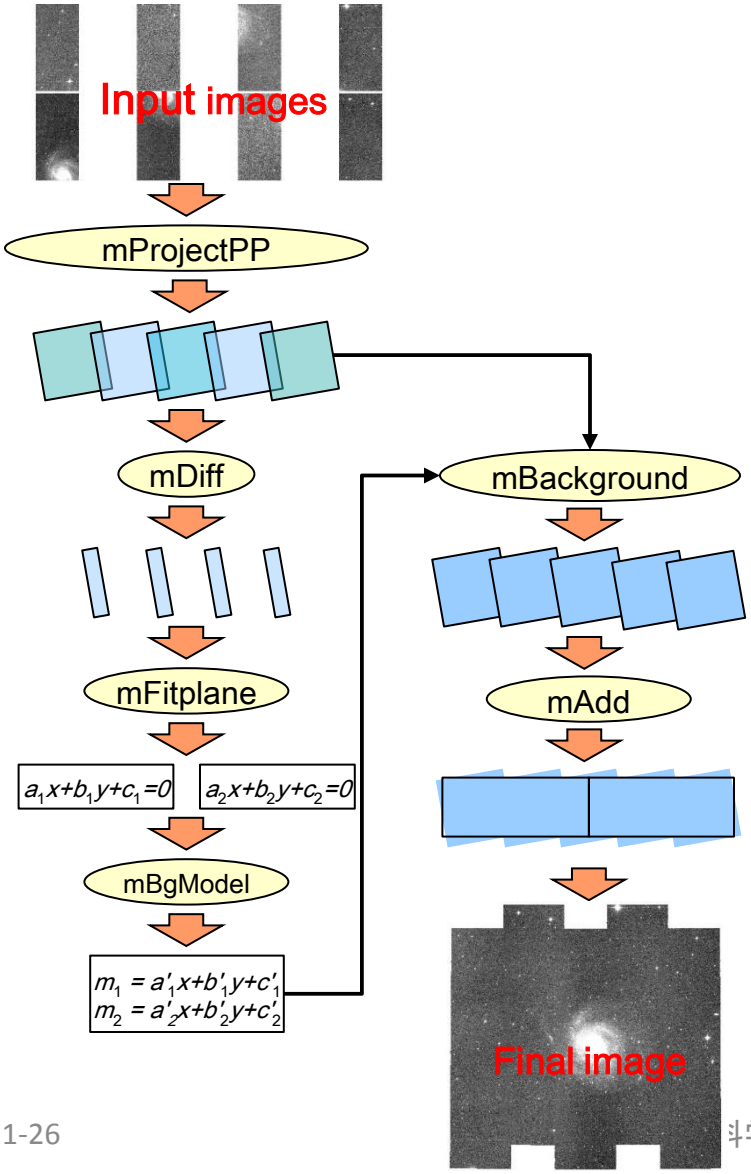

- 処理内容:
  - 座標変換
  - 明るさ補正
  - 足し合わせ
- 1 image : 1 process

Montageワークフローのグラフ

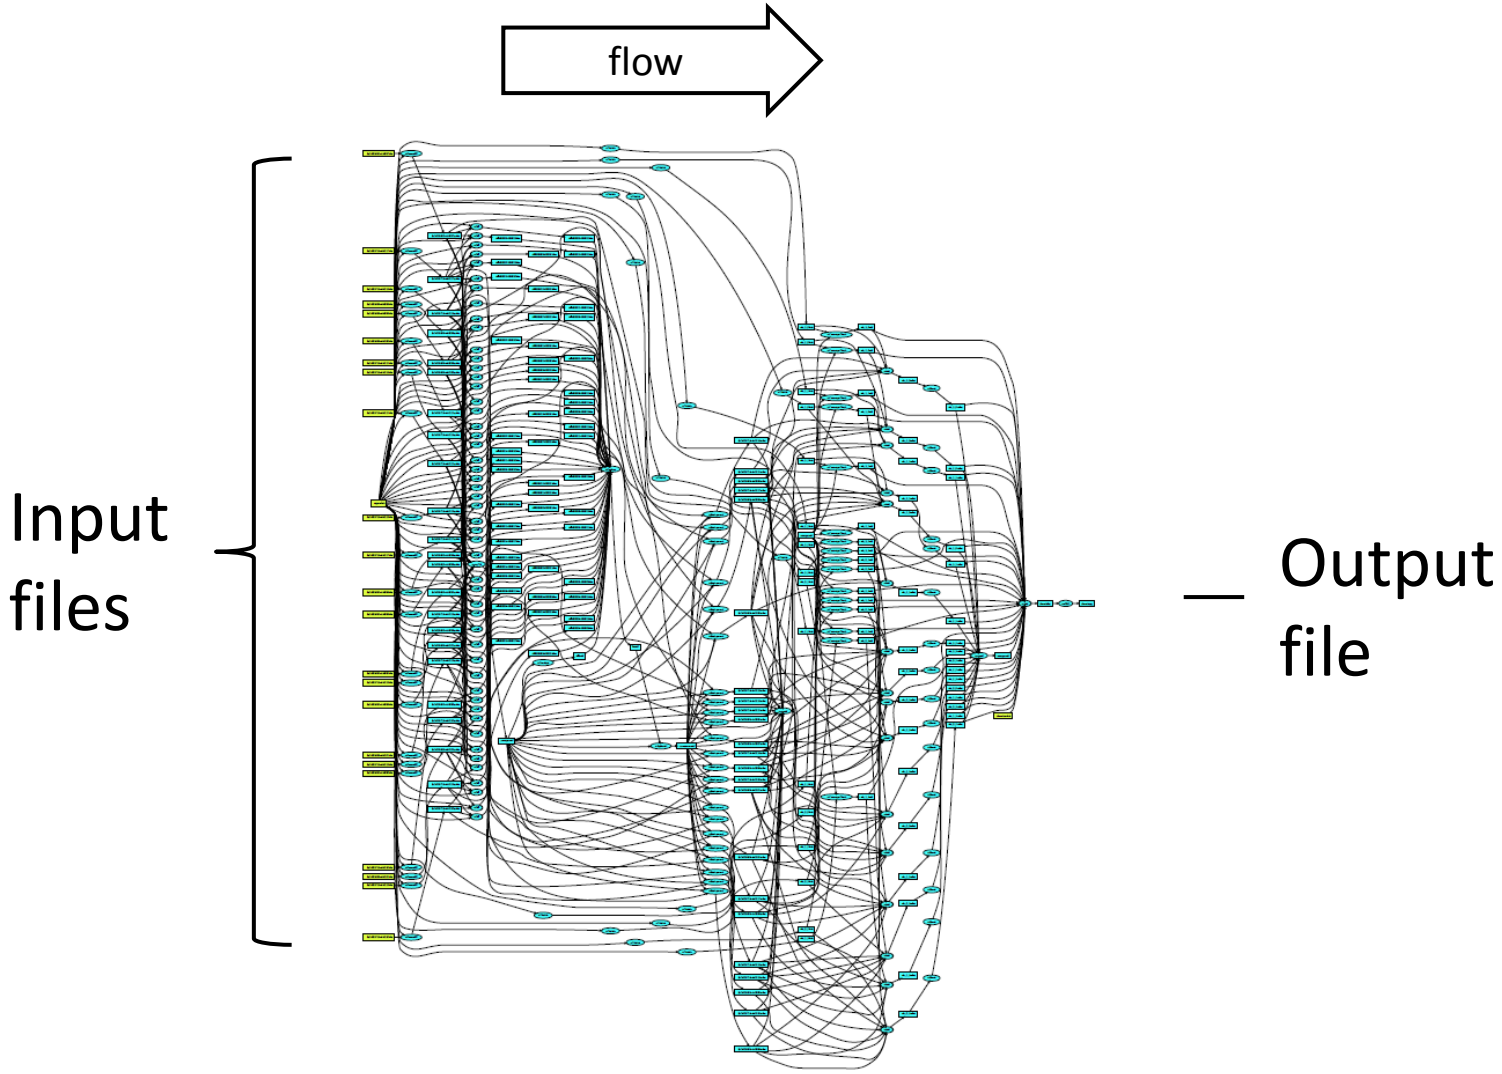

DAGによるワークフロー定義

- 多くのワークフローシステムで採用
- 問題点
  - 手書きは不可能:
    - DAG生成プログラムが必須
  - 入力ファイルが異なれば、DAGを作り直す
  - 大規模なワークフローでは、DAGが膨大になる

XMLで記述したDAG:

```
<adag xmlns="http://www.griphyn.org/chimera/DAX"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:schemaLocation="http://www.griphyn.org/chimera/DAX
        http://www.griphyn.org/chimera/dax-1.8.xsd"
    count="1" index="0" name="test">
<filename file="2mass-atlas-981204n-j0160056.fits"
        link="input"/>
 …
 <job id="ID000001" name="mProject" version="3.0" level="11"
        dv-name="mProject1" dv-version="1.0">
  <argument>
   <filename file="2mass-atlas-981204n-j0160056.fits"/>
   <filename file="p2mass-atlas-981204n-j0160056.fits"/>
   <filename file="templateTMP_AAAaaa01.hdr"/>
  </argument>
  <uses file="2mass-atlas-981204n-j0160056.fits" link="input"
        dontRegister="false" dontTransfer="false"/>
  <uses file="p2mass-atlas-981204n-j0160056.fits" link="output"
        dontRegister="true" dontTransfer="true"
        temporaryHint="tmp"/>
  <uses file="p2mass-atlas-981204n-j0160056_area.fits"
        link="output" dontRegister="true" dontTransfer="true"
        temporaryHint="tmp"/>
  <uses file="templateTMP_AAAaaa01.hdr" link="input"
        dontRegister="false" dontTransfer="false"/>
 </job>
 …
 <child ref="ID003006">
  <parent ref="ID000001"/>
  <parent ref="ID000006"/>
 </child>
…
</adag>
```

Makefileによるワークフロー記述

- Makeflow http://www.nd.edu/~ccl/software/makeflow/
- GXP make http://www.logos.ic.i.u-tokyo.ac.jp/gxp/
- 利点
  - タスク定義言語である
  - 広く使われている
  - ルール定義が可能
  - ファイルのタイムスタンプに基づき、途中から実行を再開
- 問題点
  - 複雑な定義を記述できない
  - 動的なワークフローを記述できない

Rake

- Ruby 版 make。ビルドツール
- タスク記述ファイル : Rakefile
- タスク記述文法 : Ruby
  - 内部DSL (Internal Domain Specific Language)と呼ばれる。
- Rakefile はRubyスクリプトとして実行されるので、Rubyでできることはすべて可能。

Rakefile におけるタスク記述

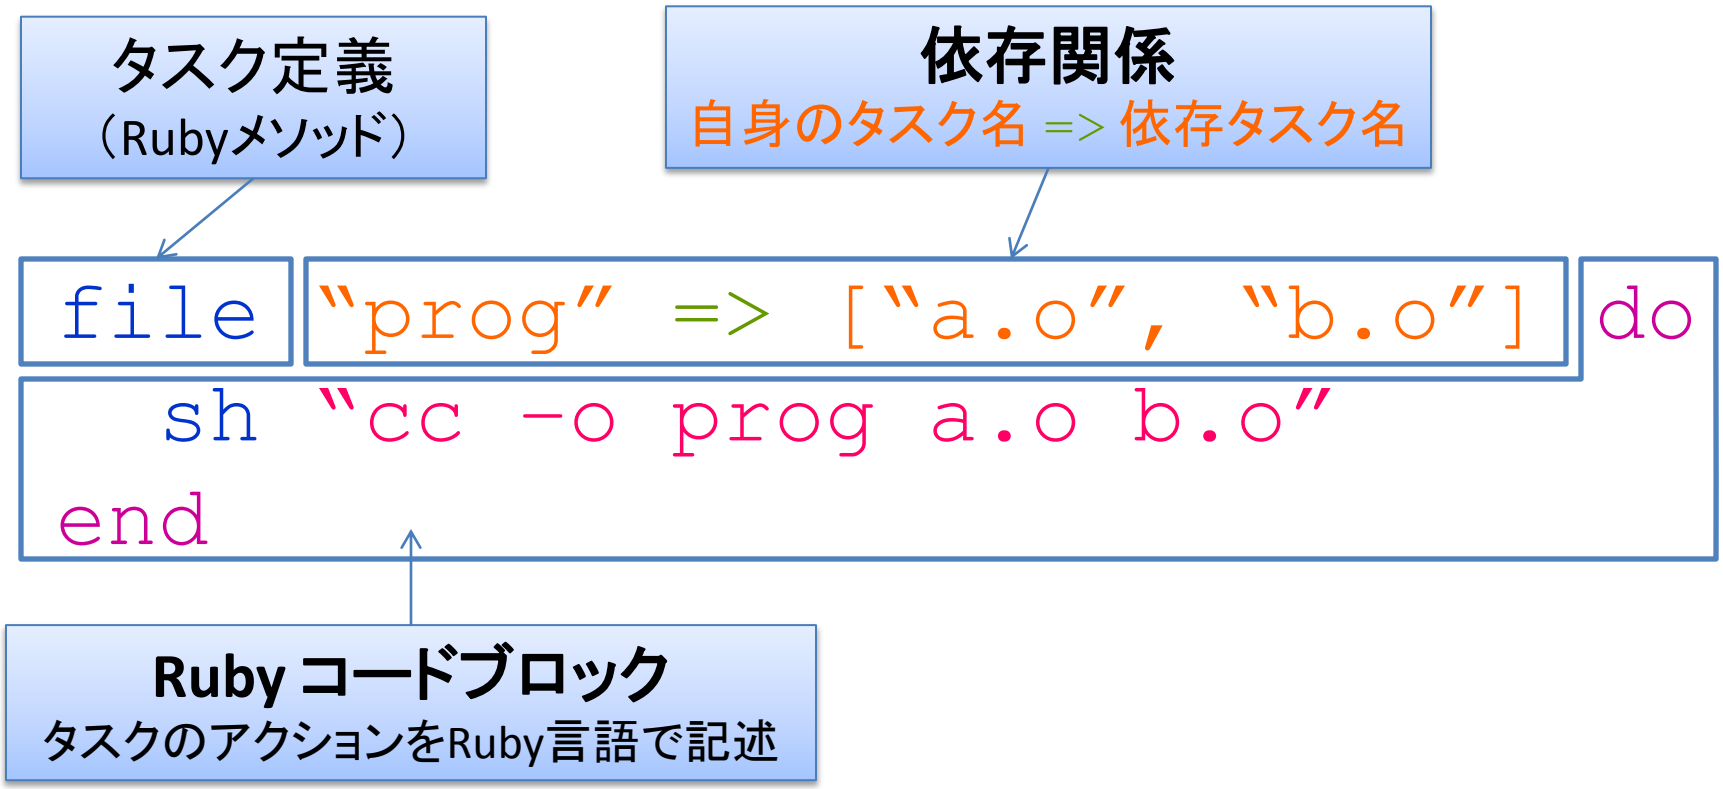

拡張子から定義できない依存関係

- ファイルの依存関係が拡張子ベースではない

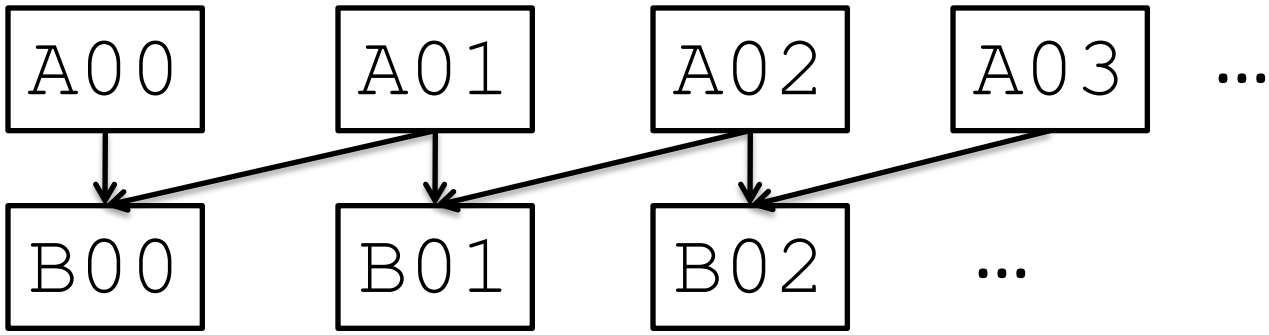

ファイル番号に基づく場合

Comparison of task definition

- Make:

```
B00: A00 A01
        prog A00 A01 > B00
B01: A01 A02
        prog A01 A02 > B01
B02: A02 A03
        prog A02 A03 > B02
……
```

- Rake:

```
for i in "00".."10"
  file "B#{i}" => ["A#{i}","A#{i.succ}"] do |t|
    sh "prog #{t.prerequisites.join(' ')} > #{t.name}"
  end
end
```

複雑な依存関係

– ジオメトリによって依存関係が決まる

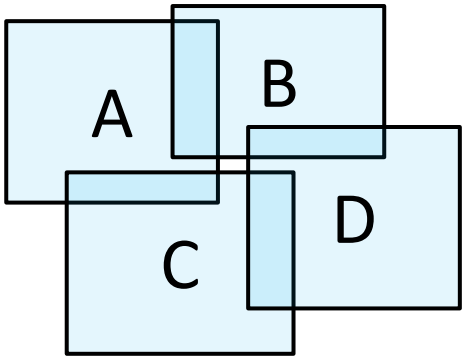

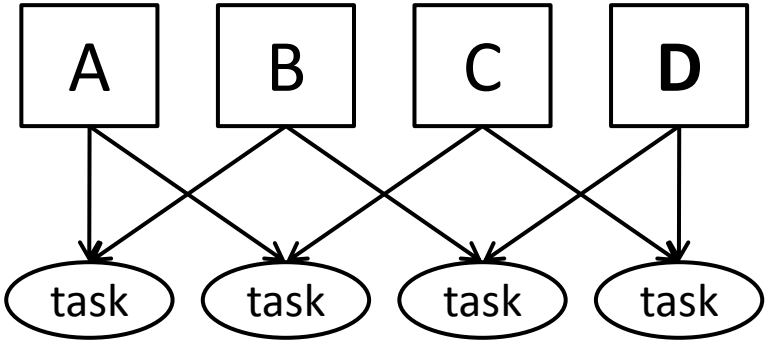

依存関係がファイルに書かれている場合

- File dependency is given as a list written in a file:

```
$ cat depend_list
dif_1_2.fits image1.fits image2.fits
dif_1_3.fits image1.fits image3.fits
dif_2_3.fits image2.fits image3.fits
...
```

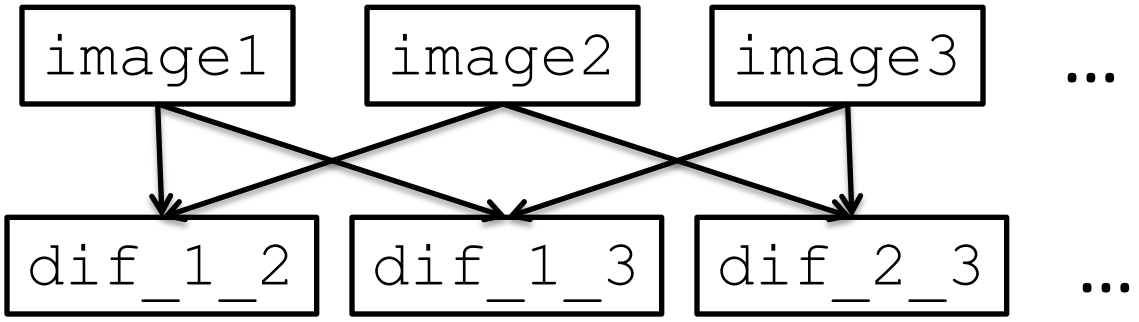

-

Dependency is given as a file list

- Make:
  - 依存関係を記述したファイルを読み、Makefile を作成するプログラムが必要
- Rake:

```
open("depend_list") { |f|
  f.readlines.each { |line|
    name, file1, file2 = line.split
    file name => [file1,file2] do |t|
      sh “prog #{t.prerequisites.join(' ')} #{t.name}"
    end
  }
}
```

動的なワークフローの生成

- タスクを実行した結果により、それ以降のファイル・タスクが定義できる

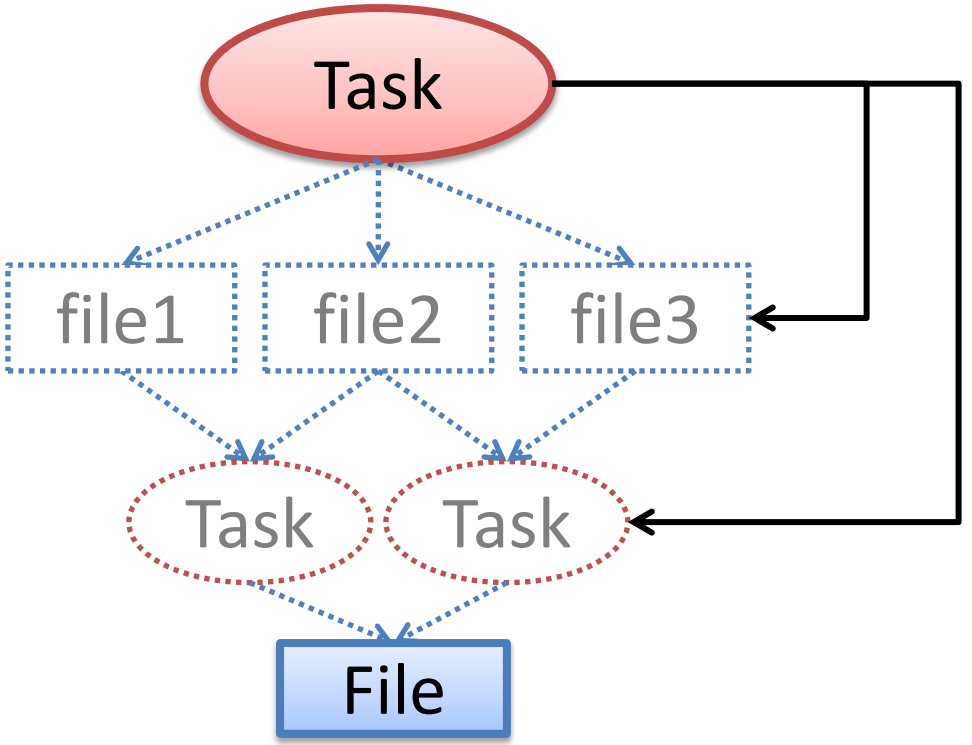

Makefileの動的生成

- make実行中にMakefileを生成
- Makefile だけではワークフローを定義できない

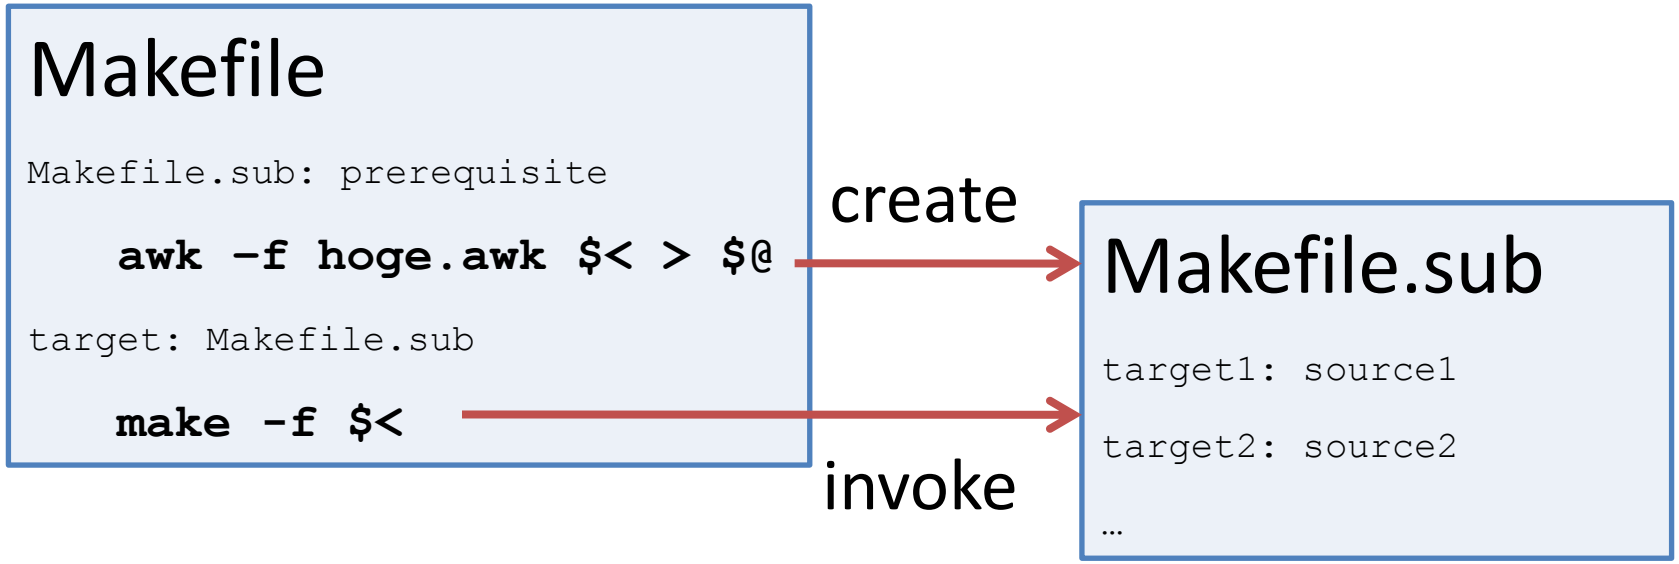

Rakeにおける動的タスク生成（失敗）

```
task :A do
  task :B do
    puts “B”
  end
end
task :default => :A
```

- task A の実行中に task B を生成
- しかし task B は実行されない
  - task B が生成される前に、すでに依存関係が決定

Rakeにおける動的タスク生成（成功）

```
task :A do
  b = task :B do
    puts “B”
  end
  b.invoke
end
task :default => :A
```

- 変数 b に、Taskオブジェクトを格納
- invoke メソッドにより、明示的に実行
- Rake により、動的なワークフローが実現

並列分散ワークフロー処理システム Pwrake

- Rakeには並列分散機能がない
- 並列分散機能を拡張：Pwrake
  - Parallel Workflow extension for Rake
    - 「プレイク」と呼んでます
    - http://github.com/masa16/pwrake
  - タスク記述は、Rakeと同じ
  - プロセスを並列に実行
  - SSHによる遠隔実行

Pwrake のローカリティ機能

- Gfarm ファイルのローカリティに基づき、実行ノードを決定

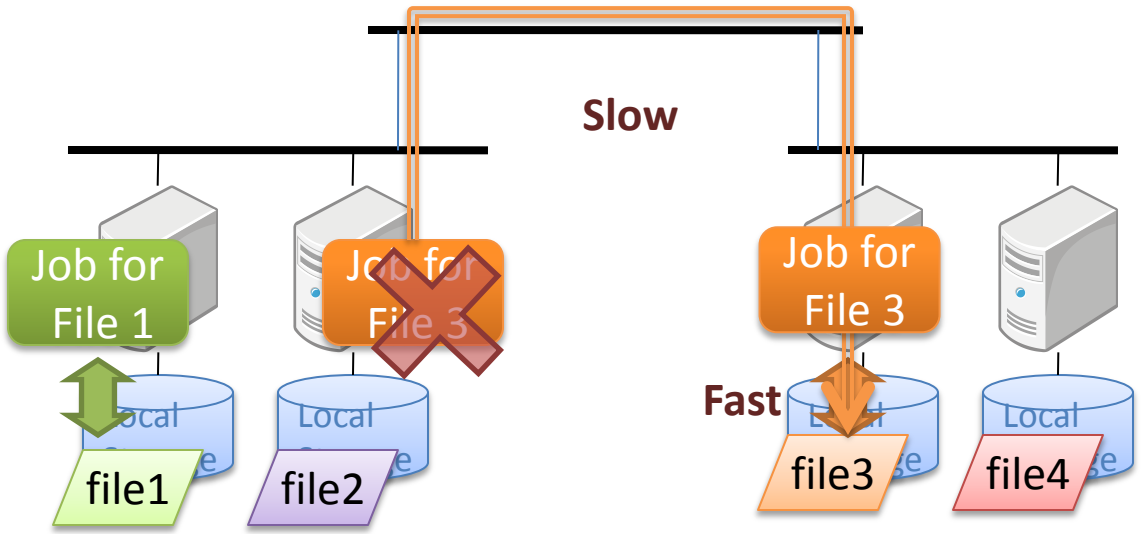

Montage Workflow 性能評価

- ワークフローを Rakefileとして記述

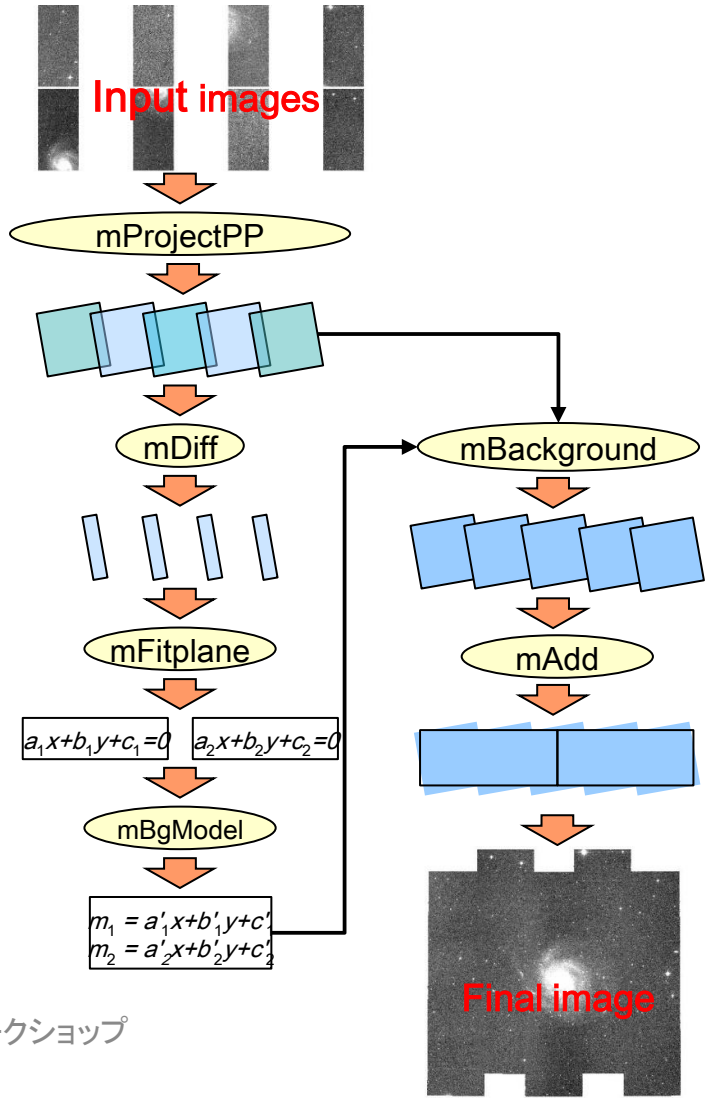

Montage Workflow の実行時間

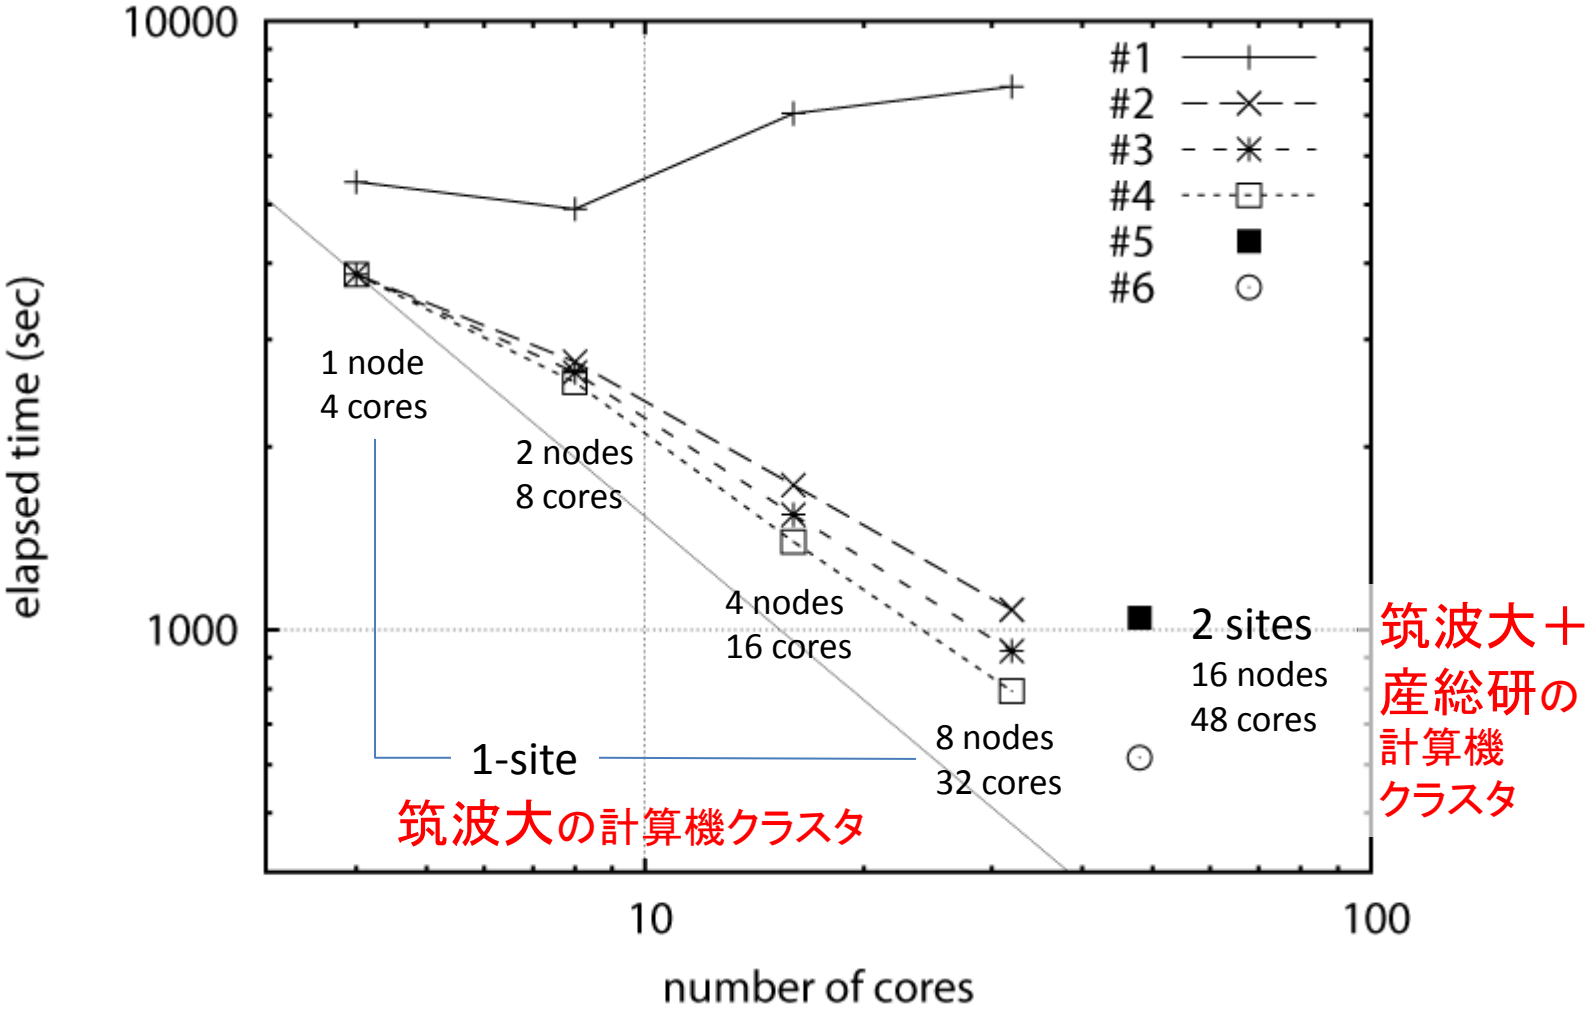

Montage Workflow の実行時間

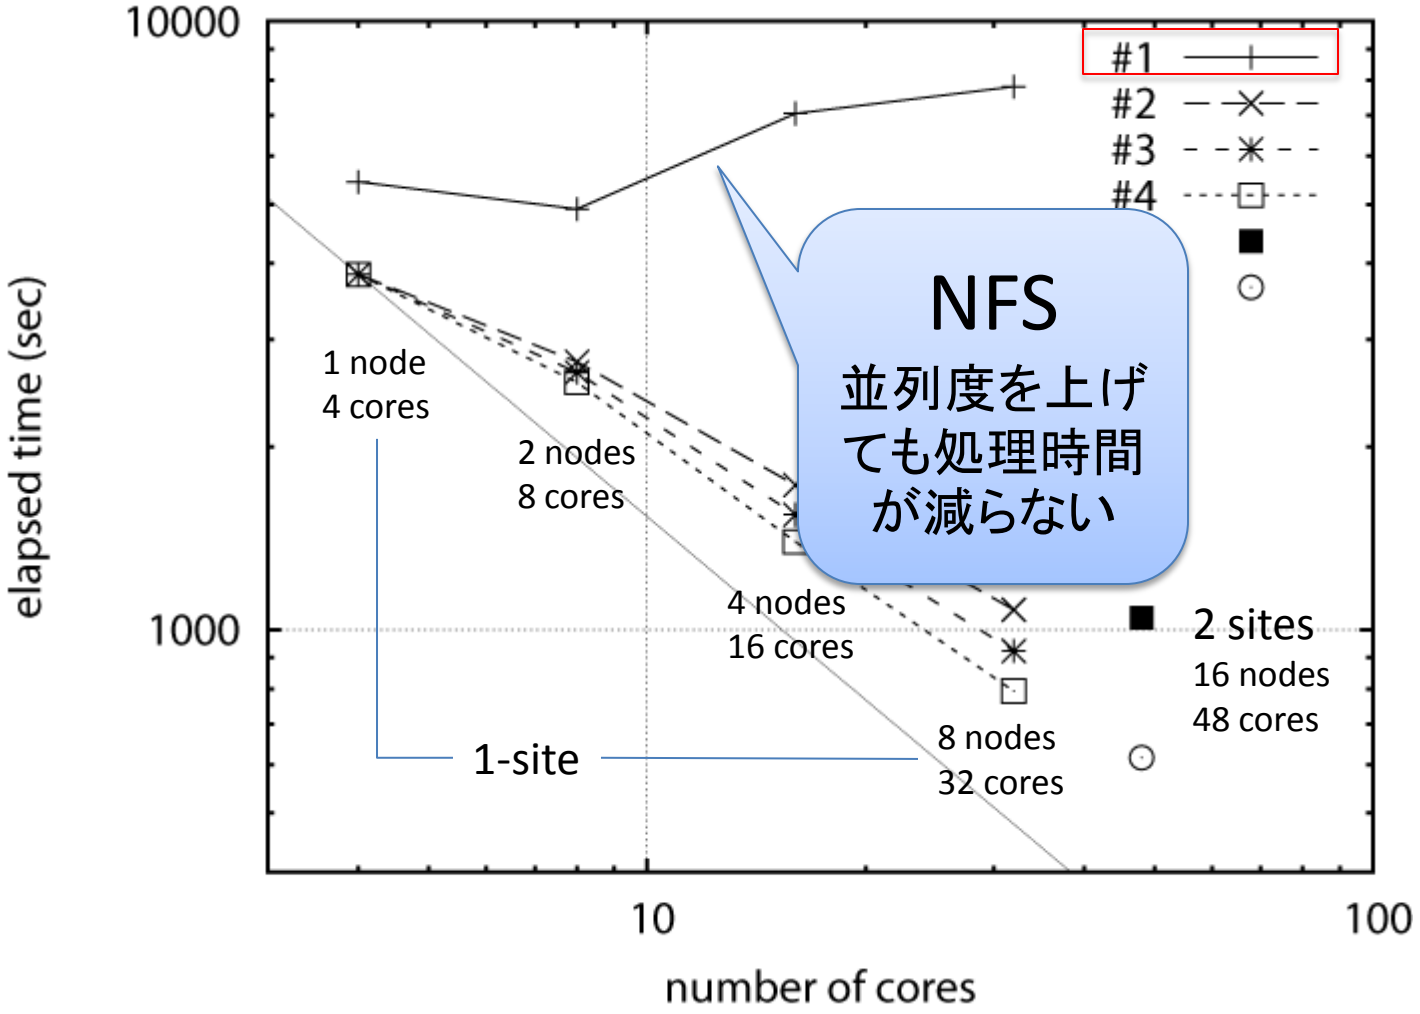

Montage Workflow の実行時間

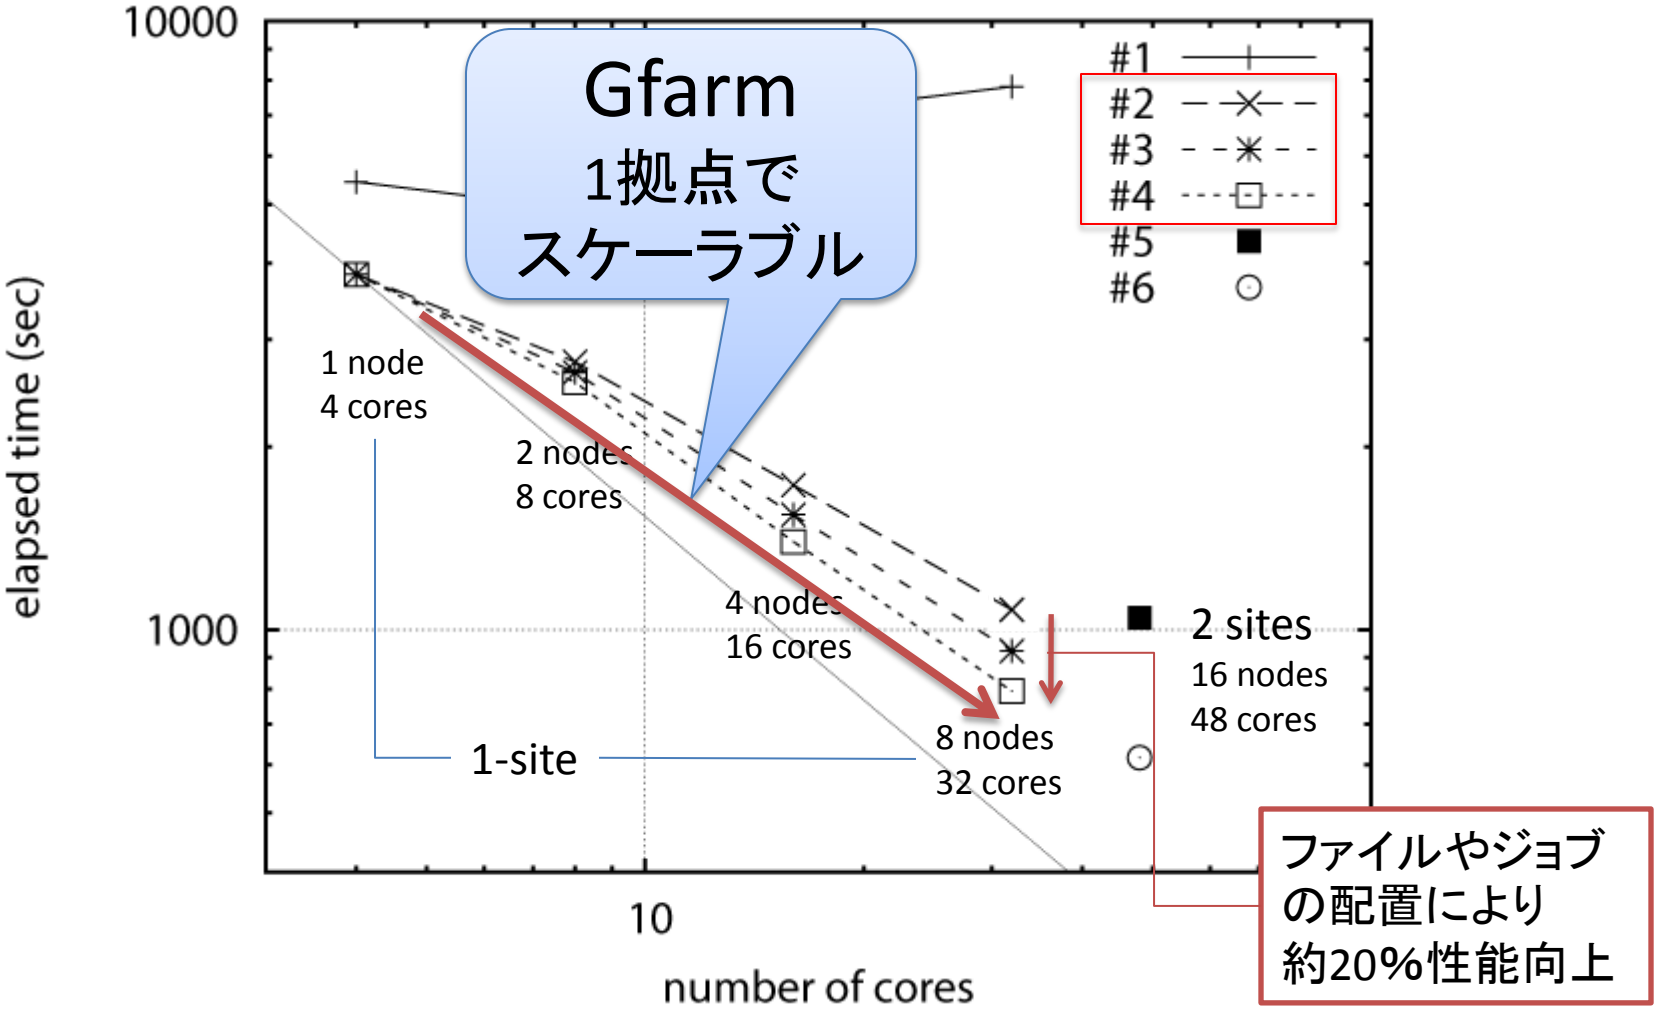

Montage Workflow の実行時間

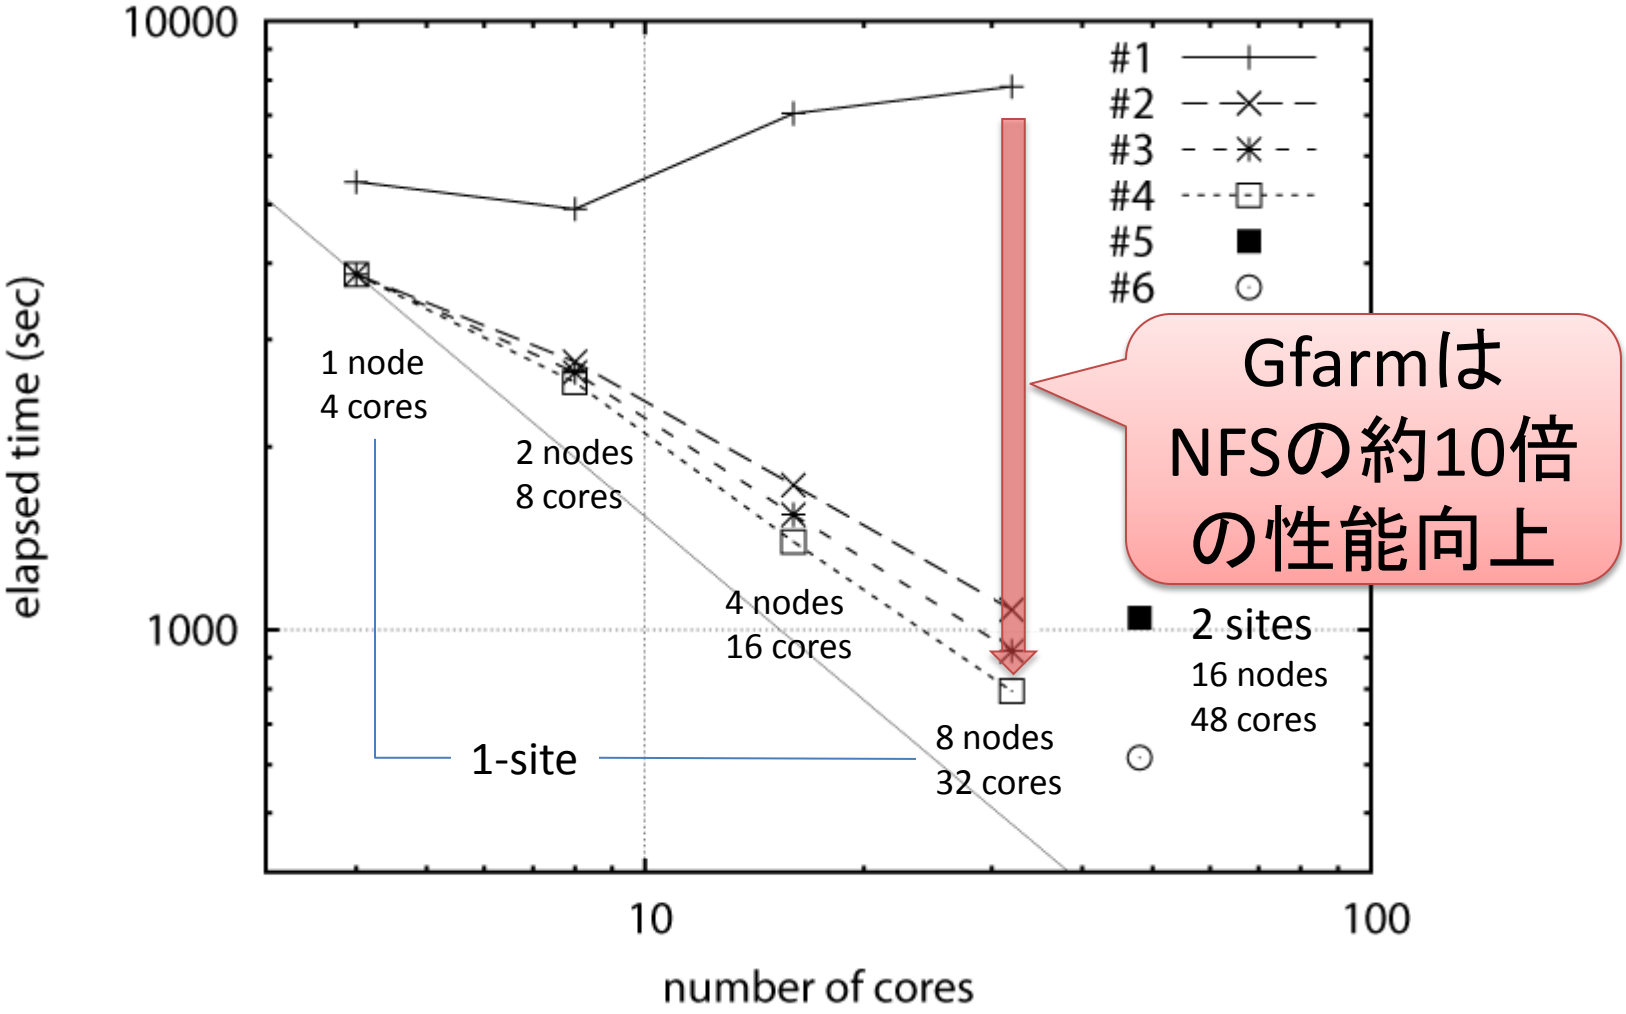

Montage Workflow の実行時間

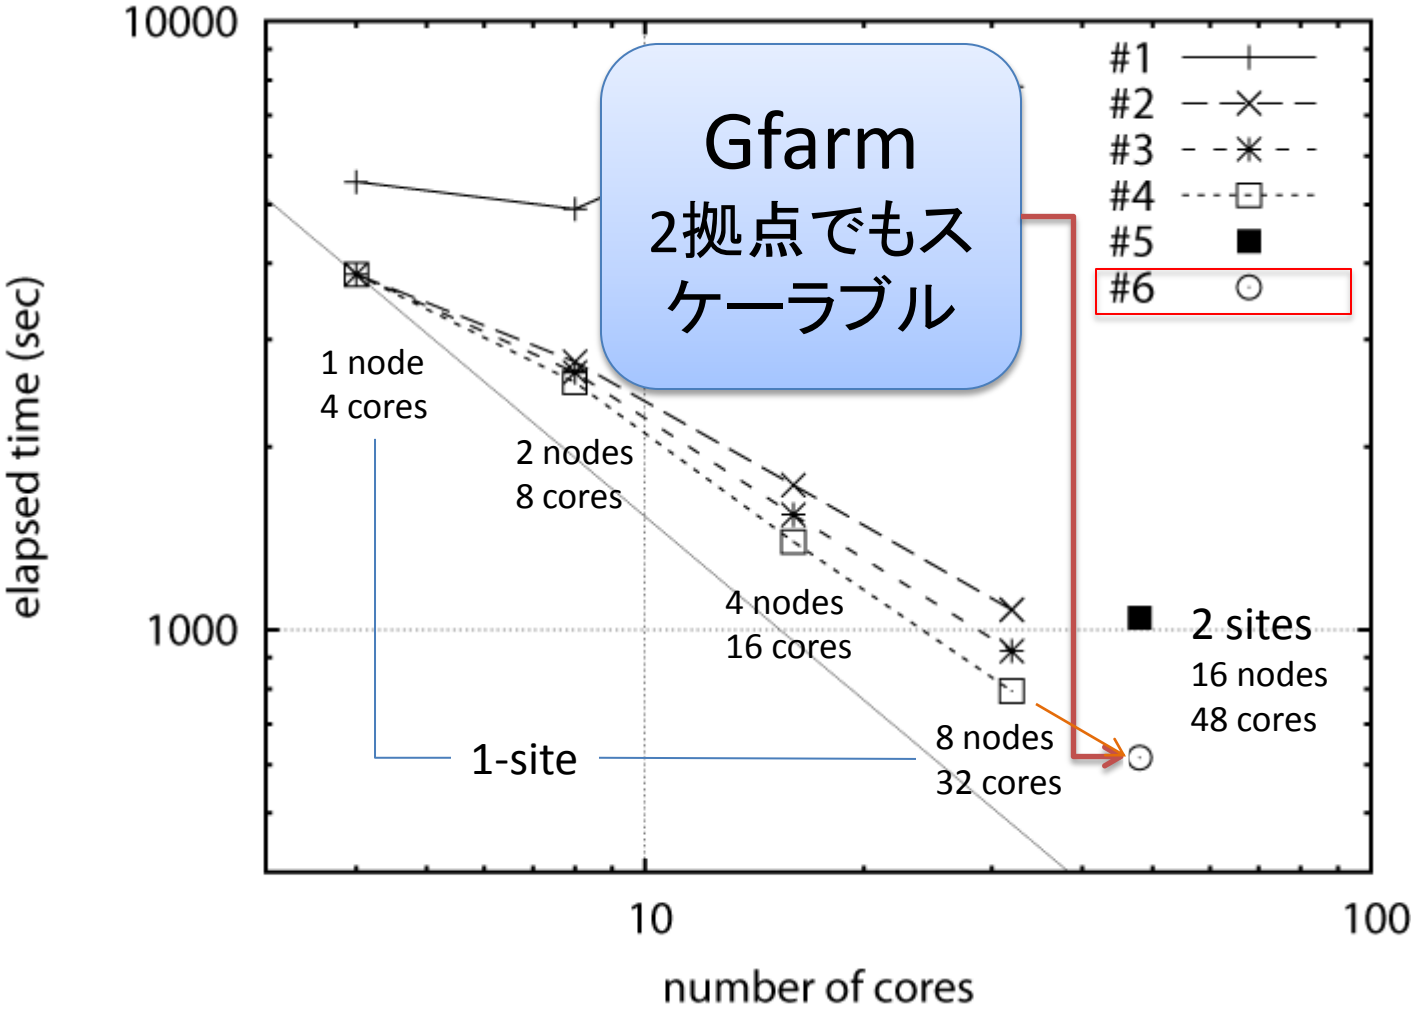

デモ

タスク配置による性能向上

- 複数拠点のクラスタを用いたワークフロー実行
- 適切なタスク配置により、拠点間のファイル転送を少なくする
- 「エッジカット最小」となるグラフ分割問題を解くことにより、タスクをグループ化
- 座標によるグループ化と、同等の結果
- 座標情報がなくても、ワークフローを記述するだけで適切に配置

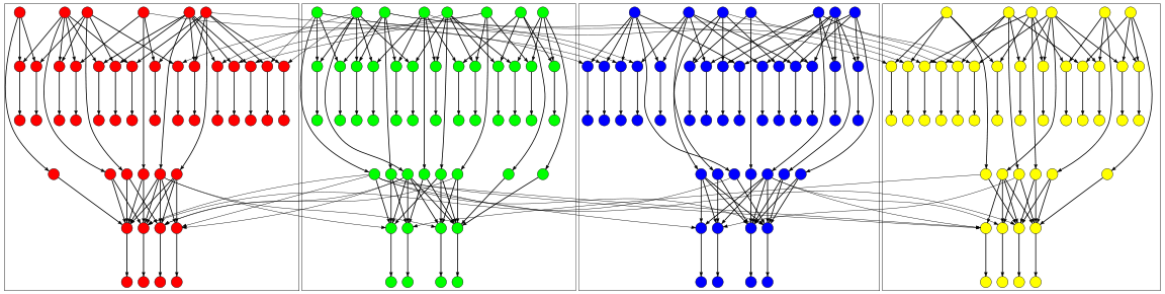

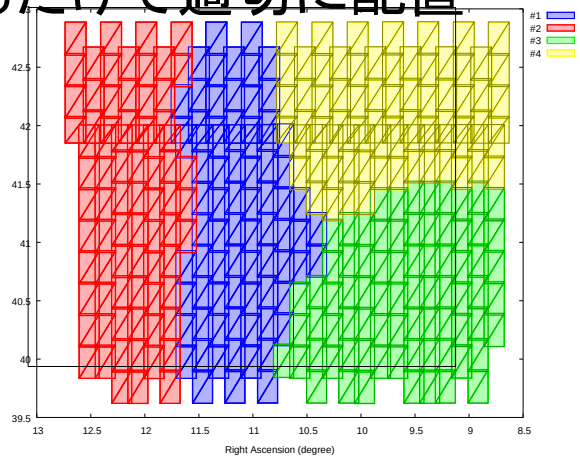

SDFRED (Suprime-cam Deep Field REDuction)

- SprimeCam: すばるの主焦点に 4096x2048 画素の CCD を 5x2 枚並べたカメラ。満月とほぼ同じ大きさの広い視野が特徴。
- SDFRED : SprimeCamが撮影したデータから、位置補正、感度補正などの処理をおこない、1枚の画像に合成するソフトウェア
- http://subarutelescope.org/Observing/DataReduction/

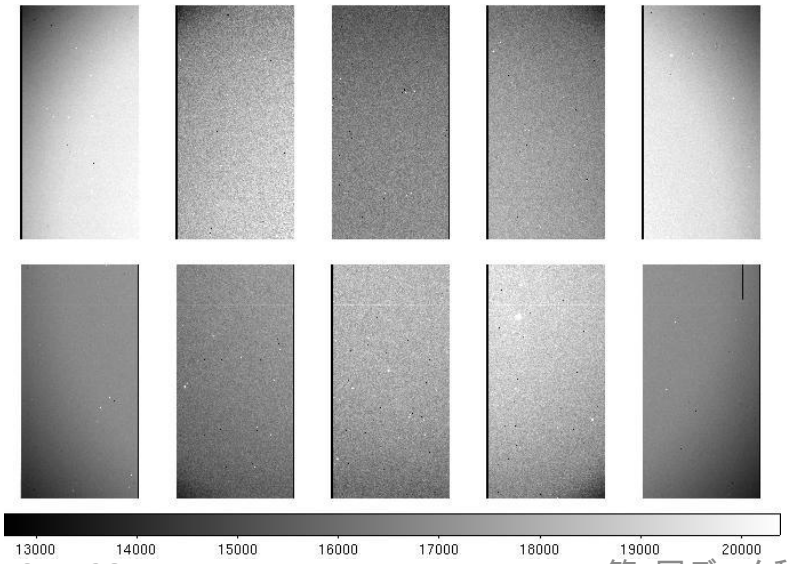

複数ショット
合成

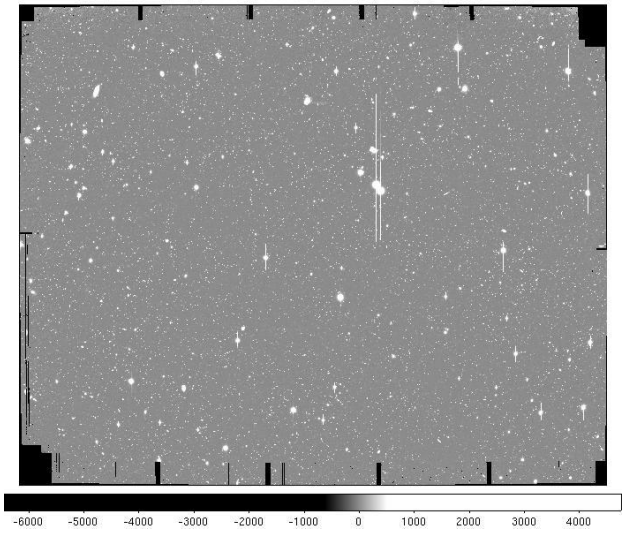

SDFRED処理内容

	処理の内容	(所要時間A,B)
1.	画像ファイル名の変換および画像の確認	(1秒,1秒)
2.	bias引きおよびoverscanの切り取り	(20秒,1分)
3.	flat 作り	**(6分,20分)**
4.	感度補正 (flat fielding)	(30秒,2分)
5.	歪補正および微分大気差補正	(1分,6分)
6.	PSF 測定	(*,*)
7.	PSF 合わせ	**(40分,80分)**
8.	sky の差し引き	(1分,3分)
9.	AG probeの影を自動でマスク	(15秒,2分)
10.	画像を目で見て、悪い部分をマスク	(15秒,1分)
11.	組み合わせ規則作り(matching)	(2分,15分)
12.	組み合わせ(mosaicing)	(3分,12分)

（所要時間）は国立天文台の ana.adc (Intel Xeon 3.0GHz) のローカル作業領域 /wa を使って、a) 練習用データ(5shot)を解析した場合にかかった時間、b) 別のデータ(17shot)を解析した場合にかかった時間

SuprimeCam Data Reduction SDFRED1

- 下記スクリプトをRakefileで記述
  - overscansub.csh
  - mask_mkflat_HA.csh
  - blank.csh
  - ffield.csh
  - distcorr.csh
  - fwhmpsf_batch.csh
  - fwhmpsf.csh
  - psfmatch_batch.csh
  - psfmatch.csh
  - skysb.csh
  - mask_AGX.csh
  - blank.csh
  - makemos.csh
- トレーニング画像の自動処理に成功

ワークフローのグラフ

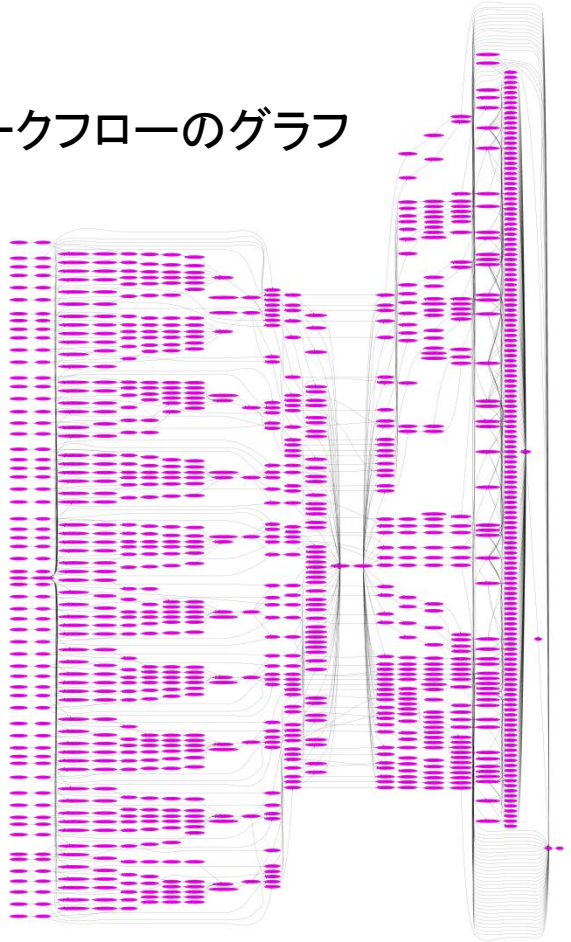

SDFRED1ワークフローの経過時間

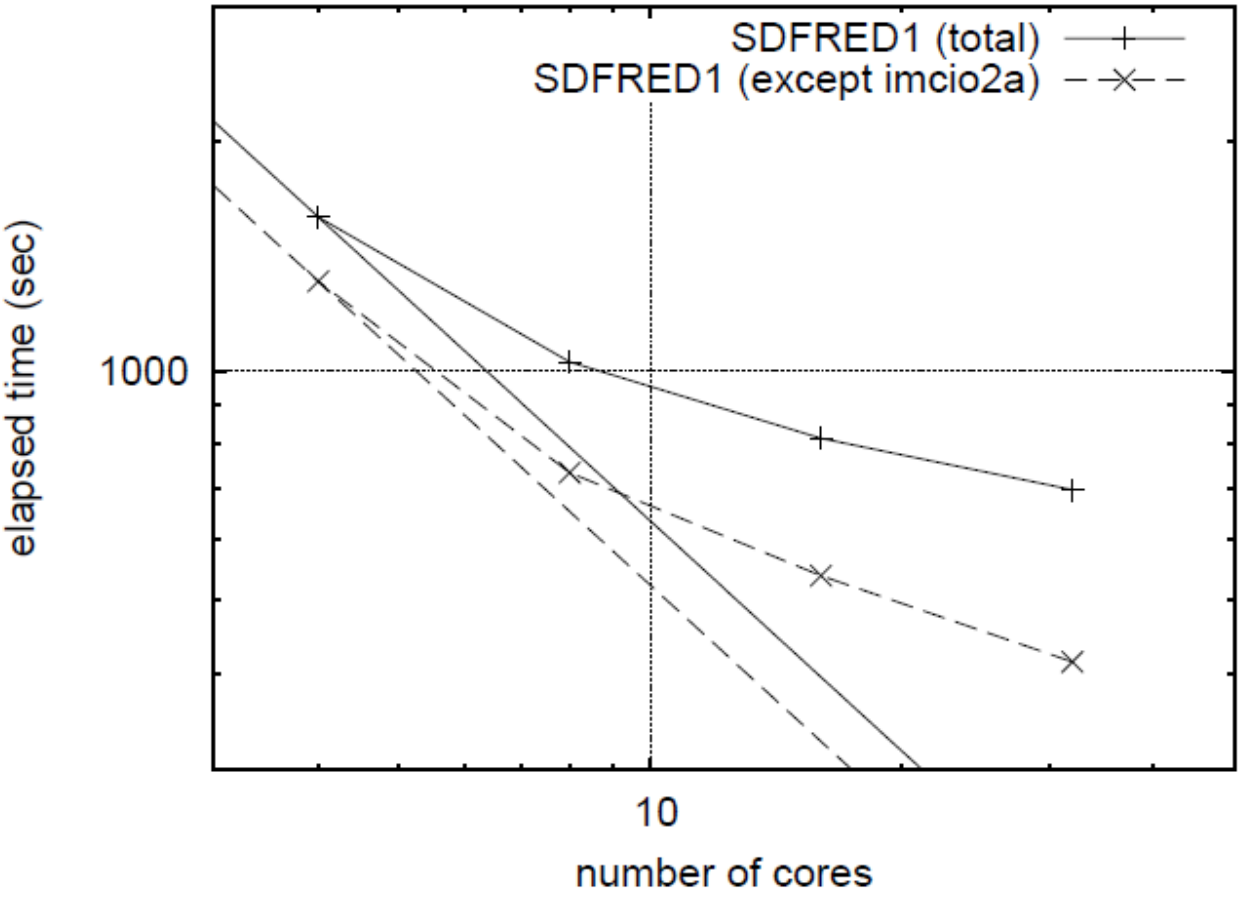

Pwrake開発の今後の予定

- 障害対策
  - 障害情報の取得
  - タスクの再試行
  - 故障ノードの判別
- 機能向上
  - 資源に応じた実行制御
  - 接続方法
- 性能向上
  - タスク配置アルゴリズムの向上
  - ファイル複製の自動配置

まとめ

- 大量データの迅速な解析には、並列処理が必要
- ワークフロー記述言語として、Rakeを採用
- 並列分散ワークフロー処理システムPwarkeを開発
- 分散ファイルシステムGfarmを用いることにより、スケーラブルな性能向上を達成