

Pwrake/Gfarmによる ビッグデータ解析

田中昌宏

筑波大学 計算科学研究センター、JST/CREST



「ビッグデータ」といえば...


- ▶ ペタバイト級のデータ
- ▶ 大量データのデータマイニング
 - には直接関わっていません
- ▶ 「スケールアウト」が可能な基盤システム
 - Gfarmファイルシステム
 - Pwrakeワークフローシステム
 - について話します

本日の内容

- ▶ Pwrakeワークフローシステム
 - Pwrakeシステムの概要
 - タスクスケジューリングに関する研究
- ▶ 関連システム
- ▶ Gfarm/Pwrakeによる科学データ処理
- ▶ Amazon EC2 で Gfarm/Pwrake のデモ


ネットワークファイルシステムの比較

NFS




1ストレージにアクセスが集中

分散ファイルシステム



ネットワーク経由のアクセス

Gfarmファイルシステム



ローカルアクセスにより
スケールアウト可能

ワークフローシステムPwrake

- ▶ Rake: Rubyによる make に似たツール
 - ファイル入出力の依存関係に従って、コマンドラインを実行
 - Ruby本体に付属
- ▶ Pwrake: Parallel Workflow extension for RAKE
 - <https://github.com/masa16/Pwrake/>
 - Rake を拡張し、複数ノードで並列実行

Rakefileによるワークフロー記述

Rakefile

```
SRCS = FileList["*.c"]
OBJS = SRCS.ext("o")

task :default => "foo"

file "foo" => OBJS do |x|
  sh "cc -o #{x} #{OBJS}"
end

rule ".o" => ".c" do |x|
  sh "cc -o #{x} -c #{x.source}"
end
```

rule

拡張子パターンその他、正規表現、
スクリプトによる変換ルールを記述可能
⇒ 科学ワークフロー記述に適する

Makefile (GNU make)

```
SRCS := $(wildcard *.c)
OBJS = $(subst .c,.o,$(SRCS))


foo: $(OBJS)
    cc -o $@ $^

%.o : %.c
    cc -o $@ -c $<
```

Pwrake の方針:
Rakefile と互換性を保つ


科学ワークフローの例: Montage

- ▶ 少しずつずらして撮像した天文画像を、1つの画像に結合するためのソフトウェア



科学ワークフローの例: Montage


Workflow DAG (Directed Acyclic Graph)



Pwrake の構成

Master node


Worker nodes




ファイルアクセスパターンとI/O性能

▶ ファイルアクセス速度

- Local > Remote
- Cached > Disk
 - Disk Cache (Buffer/Page Cache)



Read performance of Gfarm file (HDD, GbE)



IOを考慮したタスクスケジューリングに関する研究


▶ ローカルアクセスの向上

- “Workflow scheduling to minimize data movement using multi-constraint graph partitioning”
- CCGrid 2012
- タスク実行ノードを決めるスケジューリング


▶ キャッシュ効率向上

- “Disk Cache-Aware Task Scheduling For Data-Intensive and Many-Task Workflow”
- IEEE Cluster 2014
- タスク実行順序を決めるスケジューリング

Multi-Constraint Graph Partitioningによるローカルアクセスの向上





Multi-Constraint Graph Partitioningによるローカルアクセスの向上



キャッシュ効率のためのタスクスケジューリング


Workflow DAG



	Trailing tasks ↑		HRF: Highest Rank First	
	FIFO (HRF)	LIFO	LIFO+HRF	Rank Equalization+HRF
Disk Cache	×	⊙	⊙	○
Trailing Task	○	×	○	○
Task Overlap	×	×	×	○

キャッシュ効果による性能向上

(1-12 nodes, Logarithmic graph)



関連するワークフローシステム

▶ **GXP make**

▶ **Swift**

▶ **Hadoop**

関連システム1



▶ GXP make

○ GXP: 並列/分散シェル

- <http://www.logos.ic.i.u-tokyo.ac.jp/gxp/>
- 田浦さん(東大)らによる開発
- Pythonで実装

○ GNU make のタスクを、GXPで実行

- Makefile でワークフローを定義
- SHELL=mksh により、コマンドラインを横取り
- 入出力ファイル名までは取れないので、高度なスケジューリングは難しい

関連システム2



▶ Swift

- <http://swift-lang.org>
- シカゴ大学他による研究開発
- ワークフロー定義言語
 - 独自の遅延評価型の並列スクリプト言語
- Swift/T
 - Armstrong et.al., “Compiler Techniques for Massively Scalable Implicit Task Parallelism,” in *SC14*.
 - **1.47 billion** tasks/s on 524,288 cores of Blue Waters
- 特殊目的の独自言語の学習コスト

関連システム3



▶ Apache Hadoop

- <http://hadoop.apache.org/>
- 大規模データの分散処理の定番
- MapReduceフレームワーク
 - 任意のワークフローを実行できない
- HDFS
 - 既存のツールからファイル読み書きできない

Gfarm/Pwrakeによる科学データ処理

- ▶ すばる Hyper Suprime-Cam (HSC)
- ▶ NICTサイエンスクラウド

すばる望遠鏡 Hyper Suprime-Cam(HSC)


(画像クレジット: 国立天文台・HSC プロジェクト)



すばる望遠鏡



HSC 全体像



HSC 焦点面CCD

有効視野角: 1.5度角 (Suprime-Camの3倍)

CCD数: 116枚


1CCD画素数: 4272×2272

一晩で約 300 GB のデータを生成

HSC観測目的の1つ: 超新星の早期発見


HSCによる超新星の発見の例

1晩のHSC観測で、50個の超新星候補を発見
(Gfarm/Pwrakeは未適用)



<http://tpweb2.phys.konan-u.ac.jp/~tominaga/HSC-SN/ATel7565/index.html>


超新星の光度曲線の理論予想



Tominaga, et al. 2009, ApJL, 705, L10

超新星の早期発見
↓
データ処理速度が重要
↓
Gfarm/Pwrake による
処理の高速化


HSCデータのFrames処理実行時間



NICT サイエンスクラウド



<http://sc-web.nict.go.jp/>



<http://himawari8.nict.go.jp/>

ひまわり8号リアルタイムWebにも
Gfarm/Pwrakeが活用されているとのこと

デモ

- ▶ <https://github.com/masa16/amazon-ec2-gfarm-demo>
- ▶ Amazon EC2 にクラスタ環境を構築
- ▶ Gfarmファイルシステムを設定
- ▶ PwrakeでMontageワークフローを実行