

# 広帯域データ伝送システム ULTRAの研究開発

自然科学研究機構  
国立天文台  
大江将史

2014.1.27 SS研ビッグデータのためのキャンパス基盤 -「俺の部屋まで10Gを引け」と言われたら  
15:50-16:40セッション

SS研2014.1

1

## 自己紹介

- 大江将史（おおえ まさふみ）

<http://fumi.org/>

- 所属：自然科学研究機構 国立天文台

天文データセンター 助教

- なにしてるのか？

- 専門は、ネットワークセキュリティ、衛星通信、無線通信など
- 天文と情報ネットワークの融合に関する研究等
- 国立天文台のネットワーク運用や設計等

SS研2014.1


2

# [質問]

## 机のうえに10GbEありますか？

部屋まで10GbE(ユーザー向けアクセスサービスとして10GbE)きてますか？

- 1) きてます
- 2) 上流のアグリゲーションスイッチなら
- 3) コアスイッチなら
- 4) ありません



アーカイブ  
解析  
データ公開

一晩で250GB程度の  
デジタルデータを生成

# 天文学を支えるコンピュータネットワーク

## 国立天文台の研究施設

宇宙へ近づいたため  
よりよい観測環境を求めて  
世界に広がる研究施設

国立天文台の研究・観測施設は日本各地にとどまらず、さらなる望遠鏡や建設中のALMA(アトルマ)のように海外にも進出しています。天文学の観測では、可視光、赤外線、電波、重力波などの観測手段と、太陽とそれ以外の宇宙などの観測対象に応じて、最適な観測条件と環境が必要とされるからです。

この見聞ページを再読してください。現在までわかっている宇宙の全体構造の大きな部分を、地図と写真によって示しました。ここで紹介した国立天文台の各研究観測施設は、互いに連携しながら、その全体の解明に努力を続けています。

### 国立天文台チリ

■手折観測所 (Cプロジェクト) → p.18  
Atacama Large Submillimeter Array (ALMA)  
ALMA(アトルマ)は、日本/台湾/米、欧州の参加によりチリの標高5000mの乾燥した高原に広がる塩湖盆地で、国立天文台が率先して取り組む大型プロジェクトです。2012年から本観測運用がスタートしています。現地で、すでに日本のアンテナの多くが観測シフトされています。(注)



ASTE(アタカマサブミリ波望遠鏡)は、ALMAの前身としてチリに建設された望遠鏡です。サブミリ波で観測する際、大気中の水蒸気の影響を減らすために、標高の低い谷間に望遠鏡を配置しています。(注)

### 天体望遠鏡からの観測データ

コンピュータでの

- ・観測データの計算機解析
- ・数値シミュレーション

観測装置や計算機を支えるシステム

→ネットワークを活用

→コンピュータ&ネットワークによる成果

### 岡山天体物理観測所(Cプロジェクト) → p.16

岡山天体物理観測所は、岡山県津和野町にある、口径188cmの反射望遠鏡を中心に、観測・観望・太陽系外惑星などの光学赤外線観測を推進する国内研究拠点です。東アジア観測能力の一翼も担っています。さらに、ファイバー光伝送システム、赤外線分光装置、赤外線超広視野カメラなど、宇宙を見守る新しい観測手段を開発しています。



### 水沢 VLBI 観測所・山笠

Mitsunaka VLBI Observatory  
Yamaguchi station



### 国立天文台三鷹(本部)

三鷹キャンパスは、国立天文台の本拠が置かれ、さまざまなプロジェクト、センター、研究部、事務局が置かれています。

### 国立天文台三鷹(本部)

- 太陽観測所 (Cプロジェクト) → p.16
- 天文シミュレーションプロジェクト (Cプロジェクト) → p.17
- ひので科学プロジェクト (Cプロジェクト) → p.18
- 重力波プロジェクト推進室 (Bプロジェクト) → p.19
- TMT推進室 (Bプロジェクト) → p.20
- JASMINE検討室 (Aプロジェクト) → p.21
- 太陽系外惑星探査プロジェクト室 (Aプロジェクト) → p.22
- 天文データセンター → p.23
- 先端技術センター → p.24
- 天文情報センター → p.24
- 光赤外研究部 → p.25
- 電波研究部 → p.25
- 太陽天体プラズマ研究部 → p.26
- 理論研究部 → p.26
- 国際連携室 → p.27

### 国立天文台ハワイ

ハワイ観測所 (Cプロジェクト) → p.17

ハワイ島にある国立天文台の本拠です。『すばる望遠鏡』による観測研究の拠点となっています。

すばる望遠鏡  
ハワイ島のマウナケア山頂(標高4200m)に設置された口径3.0mの世界最大級の可視・赤外線望遠鏡です。平成12年度から本格的な観測を始め、現在、世界最先端の研究成果を挙げつづけています。

ヒロオハス  
ハワイ島ヒロ市にあるハワイ観測所の本拠です。『すばる望遠鏡』による観測研究の拠点となっています。

アメリカ合衆国  
ハワイ州ハワイ島

小笠原島 (B) → p.14

VERA観測

高のりどです。

国立天文台

# さまざまな種類のトラフィック 水沢~大手町~三鷹の場合

# 1) スーパーコンピュータ:アテルイ

## •特徴

- 水沢観測所(岩手県奥州市)に設置500TFlops級のCray社のスーパーコンピュータシステム
- 2014年度に 1PFlops級へアップグレード



SS研2014.1

7

# 1) スーパーコンピュータ:アテルイ

- 計算ジョブ(最長8時間)の間隔でデータが出力
  - ジョブ完了→水沢からデータを東京へ取り出す
  - ジョブ継続→再度ジョブ投入
- 8時間単位で、ネットワークに負荷がかかる可能性



HPC計算ノード群  
(水沢)




IPネット  
ワーク



ストレージ  
ノード群(三鷹)



汎用計算サーバ群  
(三鷹)



専用計算ノード群  
(三鷹)

8

## 2) VERA: VLBI Exploration of Radio Astrometry


VERA is a VLBI array to explore the 3-D structure of the Milky Way Galaxy



IRIKI(入来), KAGOSHIMA



ISHIGAKIJIMA(石垣島), OKINAWA




Correlation center



MITAKA(三鷹), TOKYO



MIZUSAWA(水沢), IWATE



OGASAWARA(小笠原), TOKYO

望遠鏡 (山口・茨城・他)

## 2) e-VLBI : ネットワークで結ぶVLBI




観測中は、トラフィックが継続発生

観測日&時間スケジューリング  
月平均400時間、年平均4000時間

Correlation in real-time



Image



# そのほか

## 3) クラウドシステム

- プライベートクラウドサービスを4拠点を運用
  - 「実機より速い」が合言葉
  - 三鷹地区・大手町地区・水沢地区・岡山地区に分散したクラウドシステム
  - iSCSIネットワーク・VMノード


## 4) コンテンツ配信

- デジタル4次元シアター(4D2U)のコンテンツ提供
  - スパコンや観測成果に基づく科学コンテンツの配信
- アウトリーチ: 観測所と学校を結んで最先端の科学にふれる
  - HDビデオ双方向遠隔授業(1から多地点)

# さまざまな属性を持つトラフィックがWANを流れる

- スパコン
  - 水沢の計算ノードからの結果出力を、三鷹の恒久ストレージへ効率よく伝送
    - ノンリアルタイム・利用者の利用傾向に基づく帯域の占有予測
    - 伝送中は高効率化により帯域を占有・ロスは許容されない。
- VLBI
  - 水沢から三鷹へ観測データをバーストラフィックで伝送
    - スケジュールされた観測時間に連動した帯域確保
    - パケットロスには寛容・通信としてのプライオリティは低い扱い
- クラウド・コンテンツ配信
  - 帯域は、クラウドのマイグレーション、ストレージトラフィック、コンテンツ配信などに強く依存
    - 帯域の変動幅が大きい
    - パケットロスに非寛容。

各システムの帯域利用率イメージ



# ULTRA計画

## WAN-LAN間のギャップ解消

SS研2014.1

14

## ULTRA計画(2012～)の背景

- アプリケーションが必要とするネットワークの高性能化・広帯域化・トラフィック個性
  - スパコン・VLBI・クラウド・映像中継等々
- WAN広帯域化とLANさらなる広帯域化
  - WAN-LANの帯域・性能ギャップの存在と絶対処理量の増大

➔地理的に分散する情報システムとIPネットワークを連携させ、かつ、増大する処理量にこたえられる仕組みが自然科学の発展には必要不可欠

### アプリケーション要求要件からの要素技術のブレークダウン



➔ULTRA計画は、高性能・高機能(=問題解決のアイデア)を安価に実装することを目標に開始

SS研2014.1

15

# ULTRA計画のアイデア

## ミドルボックスによるデータ伝送の効率化




水沢・大手町・三鷹地区に、ミドルボックスを設置し、WAN {へ, から} のトラフィックをWANのトラフィック・ウェザー情報に基づき伝送制御

# コストの観点から見る実装方式の検討(2011年)

### 調査研究を実施(~2011)

- \* FPGAで実装  
開発コスト大
- \* 汎用PCで実装  
開発コスト小  
かつ  
マーケットが高性能化をけん引



NIC(Network Interface Card)の高性能化&低価格化  
IAサーバ性能向上

この領域がコストパフォーマンス良

# 開発実装： 100Gbps越えのIP通信処理

## 方針

- 事前検証よりIAサーバ・汎用製品の組み合わせで十分な性能を叩き出せるという目算
  - コモディティ化した製品の応用によるコストパフォーマンスの追及
- 汎用故に成果物のほかシステム・分野への転用による効率化


## 内容

- 2つのトラックに分けて開発実装
  - キャッシュサーバ機能「野川」: SSD超高速ストレージ開発
  - IP通信機能「大沢」「連雀」: 100GbE L3ルーターの開発
  - (継続)FPGAによる方法も検討
- 最終的には、これらを統合する

SS研2014.1

18

# ULTRAの機能ブロック構成



SS研2014.1

19

# 「連雀(れんじゃく)」・「連雀+」:

連雀:

IPフォワーディング性能100Gbps



Intel SandyBridge-E overclock

PCI-E 2.0 2x 10GbE-SFP+ x 10 (最大12port)

Interop2013 オープンルーターコンペティション(ORC)  
富士通賞受賞

国立天文台が天文データ処理用のPCサーバ/ルータープラットフォームとして開発

Linux OSを基に低遅延・広帯域処理能力を目標に設計・開発

SS研2014.1

20

# 「連雀+」: 40GbE対応 / 広帯域・低遅延化

連雀+:

IPフォワーディング性能120Gbps



Intel SandyBridge-E overclock

PCI-E 3.0 2x 40GbE-QSFP+ x 5



Full 40GbE / PCI-E 3.0 対応版

SS研2014.1

21

# 「連雀」の性能 低遅延 & 広帯域の両立

フルメッシュIPフォワーディング性能を計測器で長時間検証



# 「汎用PCで 100Gbps越え」のコスト

## • 連雀

- 物品費 < 80万円

+10%の性能, 機能, 信頼性追及をしなければ, コストは, 40万円以下へ.

## • 野川

- 物品費 < 150万円 (筐体は, 40万円程度, 他はSSD費用) (部品の選定に要した費用は含まず)

➔ クラウドシステムへの応用 (高性能仮想サーバと高速ストレージサーバへ)

➔ 汎用PCの性能向上ノウハウのインハウス蓄積

# ULTRAの進化でかわる PCサーバの性能向上



# ULTRAの進化でかわる PCサーバの性能向上



# PCサーバの性能向上は今後も続く、 手段を問わず研究開発を継続

2011年 ?? Intel Core + PCI-E2.0 1x10GbE NIC

- なんとか10Gbpsを絞り出せるレベル

2012年「大沢」「野川」(第1世代) Intel Nehalem + PCI-E2.0 2x10GbE NIC + Offload

- コンテンツ送信力は、100Gbps

2013年「連雀」(第2世代) Intel SandyBridge-E + PCI-E2.0 2x10GbE NIC + Offload  
「連雀+」

- その処理力は、200Gbpsへ向上

2014年(第3世代) Intel Haswell + PCI-E3.0 NIC Full 40GbE NIC + Offload / ULLtraDIMM  
野川系・連雀系の統合

- その処理力は、400Gbpsへ?

- 誰もが100Gbps～200Gbpsを扱える時代

割り込みモデル  
or  
ポーリングモデル

SS研2014.1

26

## 広帯域通信を支える 国立天文台の基盤ネットワーク


SS研2014.1

27

汎用サーバ性能のトレンド、ネットワーク機器の開発動向など見極め設計  
 \*机の上は、高性能・高信頼なネットワーク  
 \*サーバ室は、超広帯域なネットワーク

NTT 65Mbps 商用回線  
 NICT JGN-X 10GbE 回線

NTT 1GbE 商用回線  
 SINET4 10GbE 回線



高速系：帯域重視、主要サーバ室  
 10GbE/40GbEをユーザーに提供  
 アップリンクを40GbE/2x40GbEで収容

電話統合：Cisco社 UCS  
 ビデオIP電話・無線IP電話  
 アナログ電話

## 低価格が進む要因 L3/L2スイッチング機器のトレンド

- 10ギガビットイーサネット = 1万円の世界はすぐそこ。
- L3/L2を支えるハードウェア技術
  - 専用LSI
    - 目標性能・クロックをもとに回路設計
      - コストが高く、自社専用or汎用に二極化
    - 汎用は、あらゆるスイッチング機器ベンダー向けに設計、量産効果
      - ブロードコム (Dune) ・インテル (Fulcrum) など
      - シャーシ向け、多機能、超低遅延、低価格など品種多数
    - カスタムは、自社 (機能実装) 向けにデザイン
      - シスコ・メラノックスなど
  - 専用ASIC
    - ASICチップに機能 (論理合成) を搭載
      - LSIより安価だが、ASICのデザインクロックの制約やデザイン上の制約などから、性能を出すのがむづかしい

# L3/L2スイッチング機器の構成と今後

- 事業者・製品性能に応じて、LSI/ASICを活用
  - 汎用LSIをフル活用
  - 汎用LSIを部分的に使い、独自実装のためASIC, FPGA併用
  - カスタムLSIをフル活用
    - Cisco / Mellanox / ARISTA / Extreme 等, 各社ごとにデザインが異なる.
  - \* ) LSIフル活用であっても、ASICやFPGAを支援のために使う場合もあります.
- 次世代
  - 発熱問題, リソグラフィ・プロセスの進化の必要性
  - 差別化, 汎用LSI上でのプログラマブル領域実装
  - トラフィックの多段処理, メニーコア化

SS研2014.1

30

## まとめ

- 汎用サーバ分野
  - 10ギガ級性能は超越, 今は, 40, 100ギガです.
- ネットワーク分野
  - 広帯域の低価格が進む: 10GbE = 1万円は近い.
    - LSI汎用化による低価格が進行中だが, 帯域向上には, リソグラフィが課題
  - 汎用サーバを生かし切ることやその導入促進には, 基盤ネットワークの整備が重要
    - 利用者は, もっとも価格競争が働き進化が速い汎用サーバ部分を用意すればよい.

SS研2014.1

31

まとめ:

机に10G?, まだいらいないかな

•高性能化・広帯域化・低価格化・仮想化→システムの集約化と集中運用のトレンド

•様々なシステムがハウジング内で広帯域ネットワーク上に密結合

•仮想サーバ, ストレージサーバ, セキュリティプラットフォーム, WAN等々

•10・40Gが活用できるのはハウジングの中, 机じゃない.

•組織内の計算機を垣根を越えて, 横断的なリソースの運用と効率化が可能な基盤ネットワークが重要

## お知らせ

\* 国立天文台三鷹キャンパスでは, 毎月2回公開天体望遠鏡を使った観望会を開催中!

詳しくは国立天文台ホームページをご覧ください.

ありがとうございました



口径30m次世代超大型望遠鏡(TMT) 始動  
<http://tmt.mtk.nao.ac.jp/>