プログラム環境特論
2009年12月17日

グリッドプログラミング環境（２）

建部修見
筑波大学システム情報工学研究科
コンピュータサイエンス専攻

概要

- **グリッド技術とは？**
  - 計算グリッド
  - データグリッド
  - アクセスグリッド
- **グリッド技術とその要素技術**
  - 単一認証技術
  - 情報サービス
  - ファイル管理
  - 高速広域データ転送技術
  - 資源管理
- **オープングリッドフォーラム (OGF)**
- **グリッド基本ソフトウェア**
  - Globus
- **グリッドプログラミング**
  - コンポーネントモデル
  - MPI
  - GridRPC
  - Grid Datafarm

グリッドの本

- **グリッド技術入門**
  - インターネット上の新しい計算・データサービス
- **合田憲人，関口智嗣編著**
- **コロナ社**

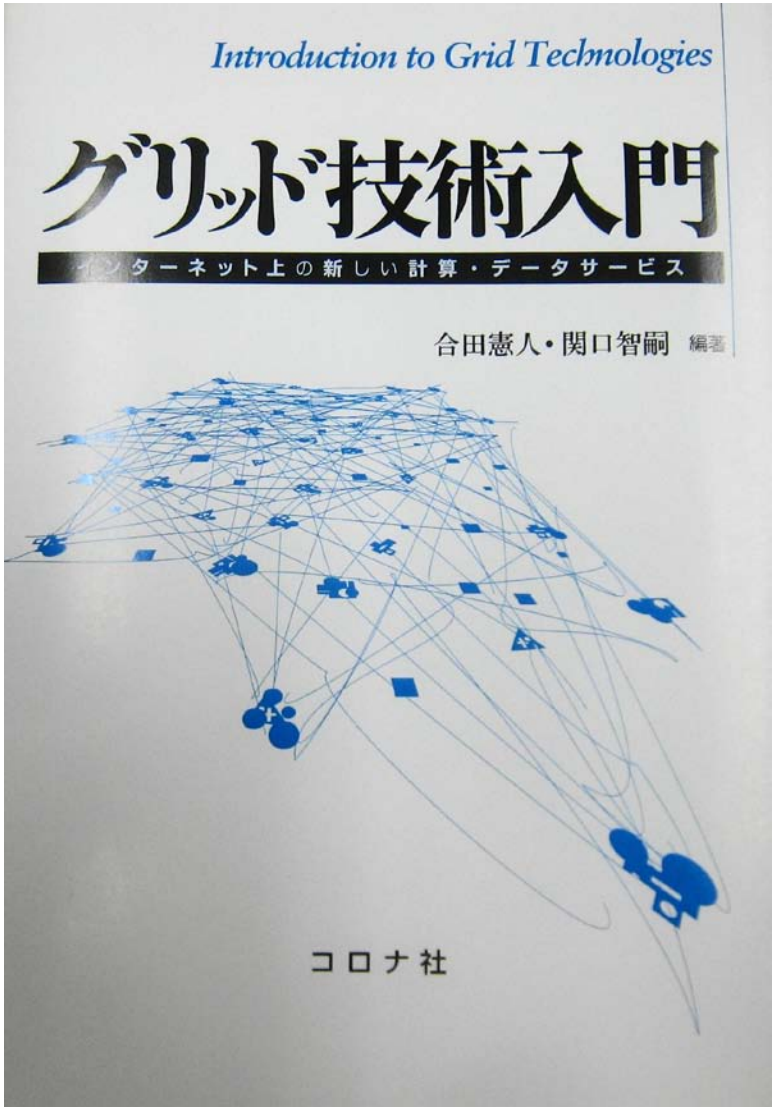

グリッドの要素技術

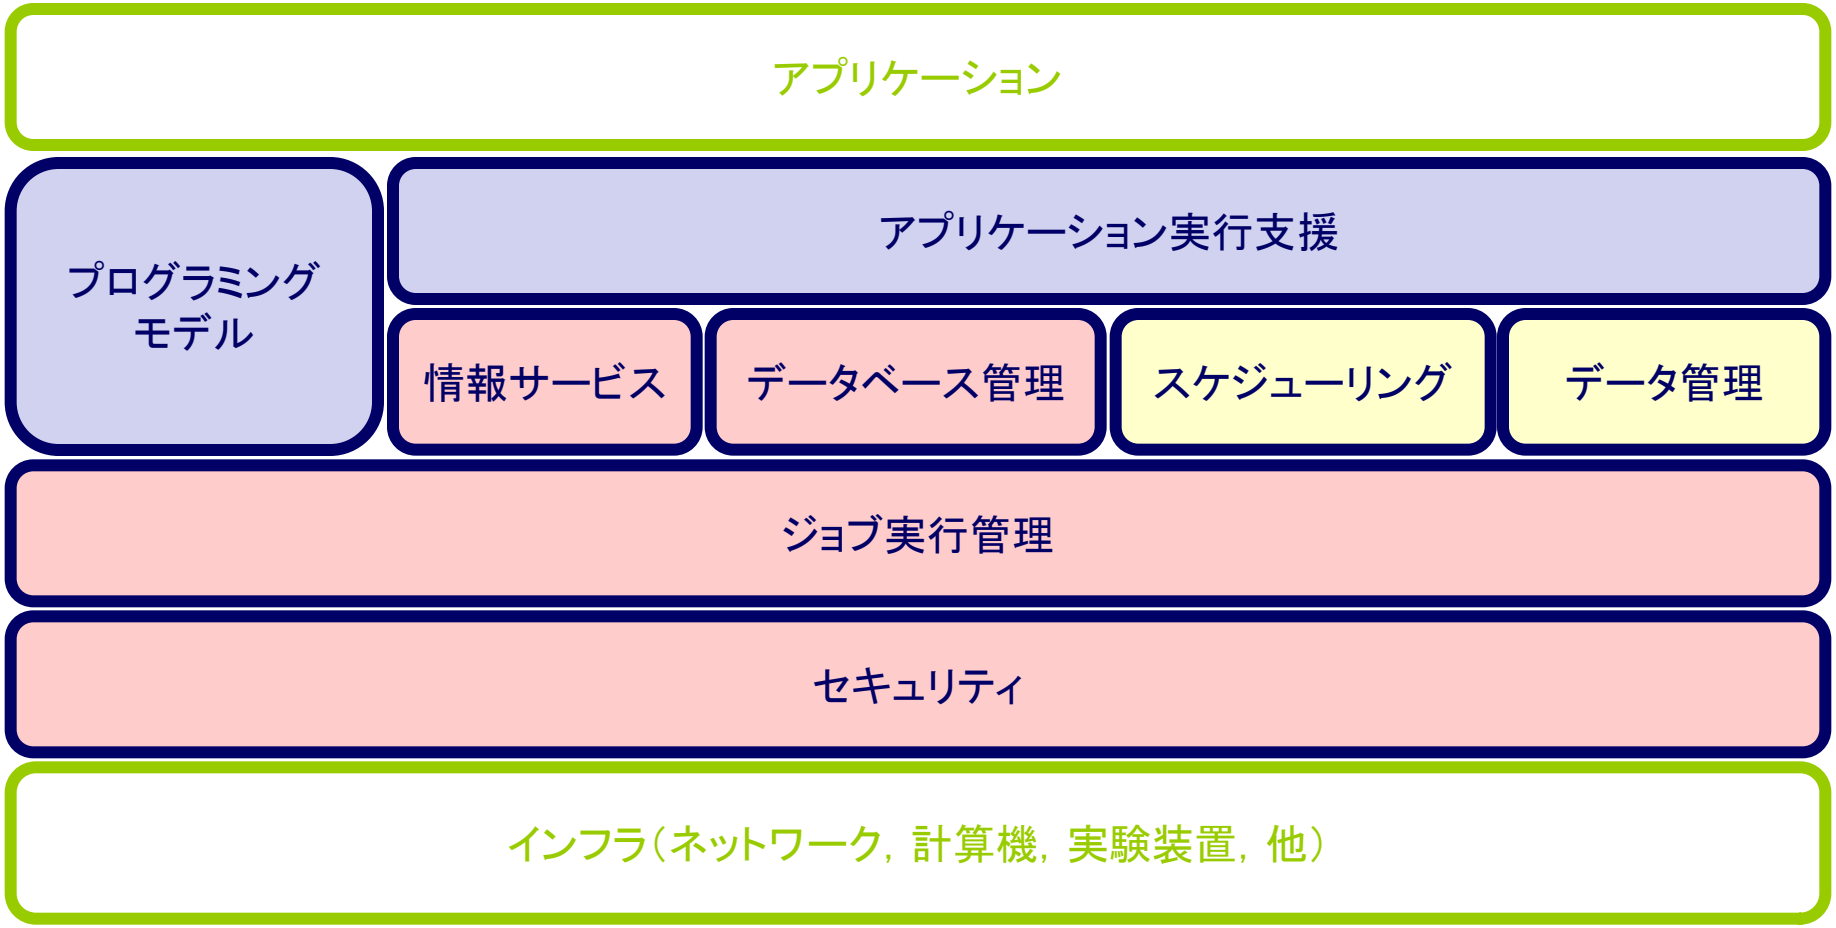
アプリケーション
プログラミング
モデル
アプリケーション実行支援
情報サービス
データベース管理
スケジューリング
データ管理
ジョブ実行管理
セキュリティ
インフラ（ネットワーク，計算機，実験装置，他）

グリッドにおけるデータ管理

- **ネットワーク上のストレージにアクセス**
  - サーバの名前
  - プロトコル
  - サーバ内のパス名
- **何らかの理由で，ファイルが移動することも**
- **ファイル複製を作成していたつもりが，一貫性がなくなることも**
- **巨大ファイルに対する高速なアクセスも**

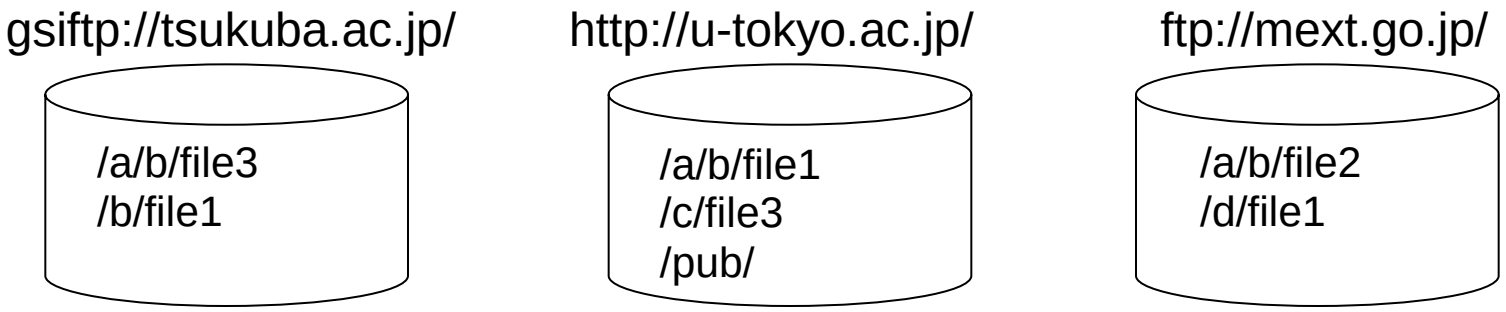

ファイル管理の役割（1）

- **グリッド上で必要なファイル，検索したいデータに対し，**
  簡単，高速なアクセス，安定したアクセス
  を提供すること
- **「簡単」（透明性，透過性）**
  - ファイルのパス名，検索式，検索条件などを指定し，欲しいデータへのアクセスを可能にする
    - サーバ名，プロトコルを指定しない
  - ファイルのパス名，検索式などから所在，プロトコルに変換する機構が必要
    - パス名の場合，ディレクトリ管理サービス
    - 検索式の場合，メタデータ管理サービス
  - 間接的な管理により，サーバ，プロトコルの動的決定が可能となり，柔軟性が向上する
    - ファイルの移動，利用可能なファイル複製の選択など

ファイル管理の役割（2）

- 「高速」なアクセス
  - アクセス帯域を大きく
    - 高速転送技術
    - 必要数の複製を適切な場所に配置し，アクセスを分散
  - アクセス遅延を短く
    - ネットワーク的に近い複製を選択
    - よく利用される場所の近くに複製を作成
    - よく利用されるデータはアクセス集中を避けるため，複製を作成

ファイル管理の役割(3)

- **「安定」して提供する**
  - ストレージ，ネットワークの障害時でも，障害を意識させず，アクセスを可能にする
  - SPOF (Single Point of Failure)をなくす
    - ある特定部分の故障によりシステム全体が停止することを避ける
  - データの消滅を防ぐため，データ複製を異なる組織に配置し，二重化，三重化を図る
  - データへアクセスするためのディレクトリ管理サービスなどの二重化，三重化を図る

ファイル管理におけるサービスの連携

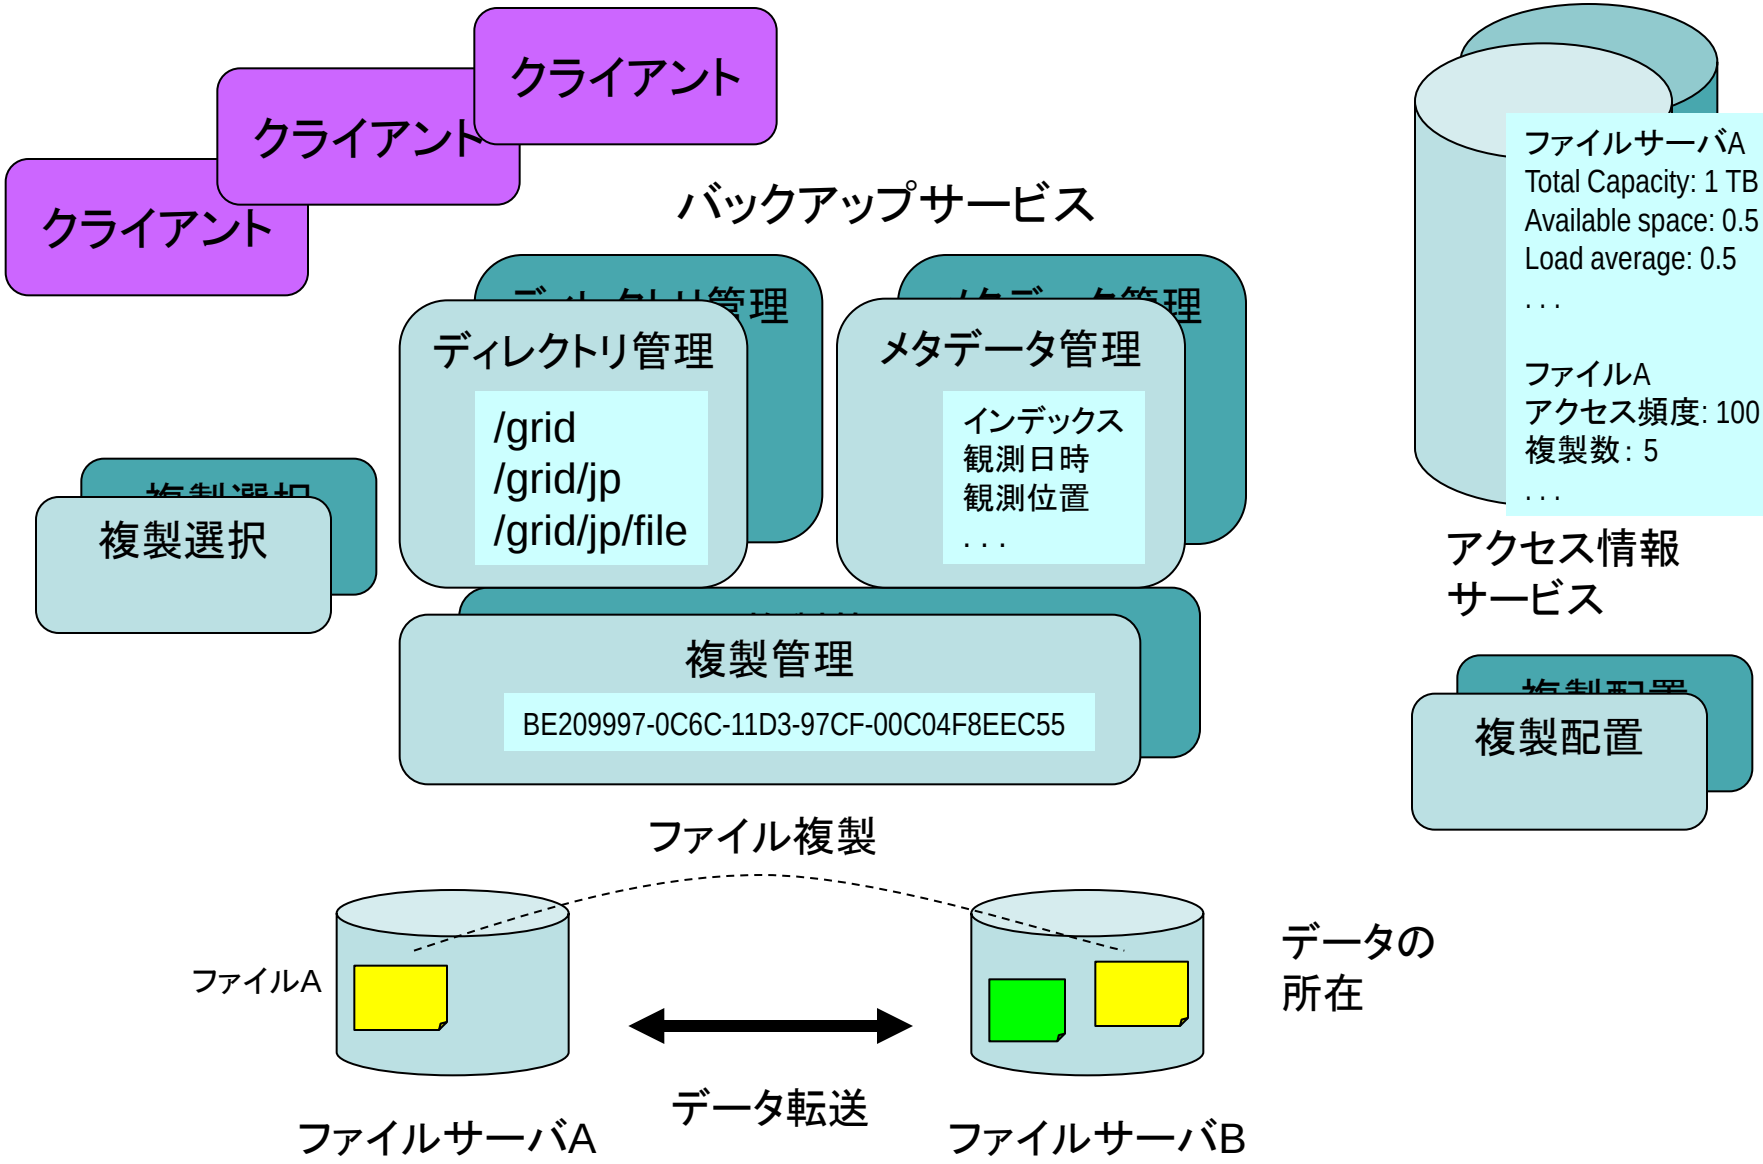

ファイル管理の例

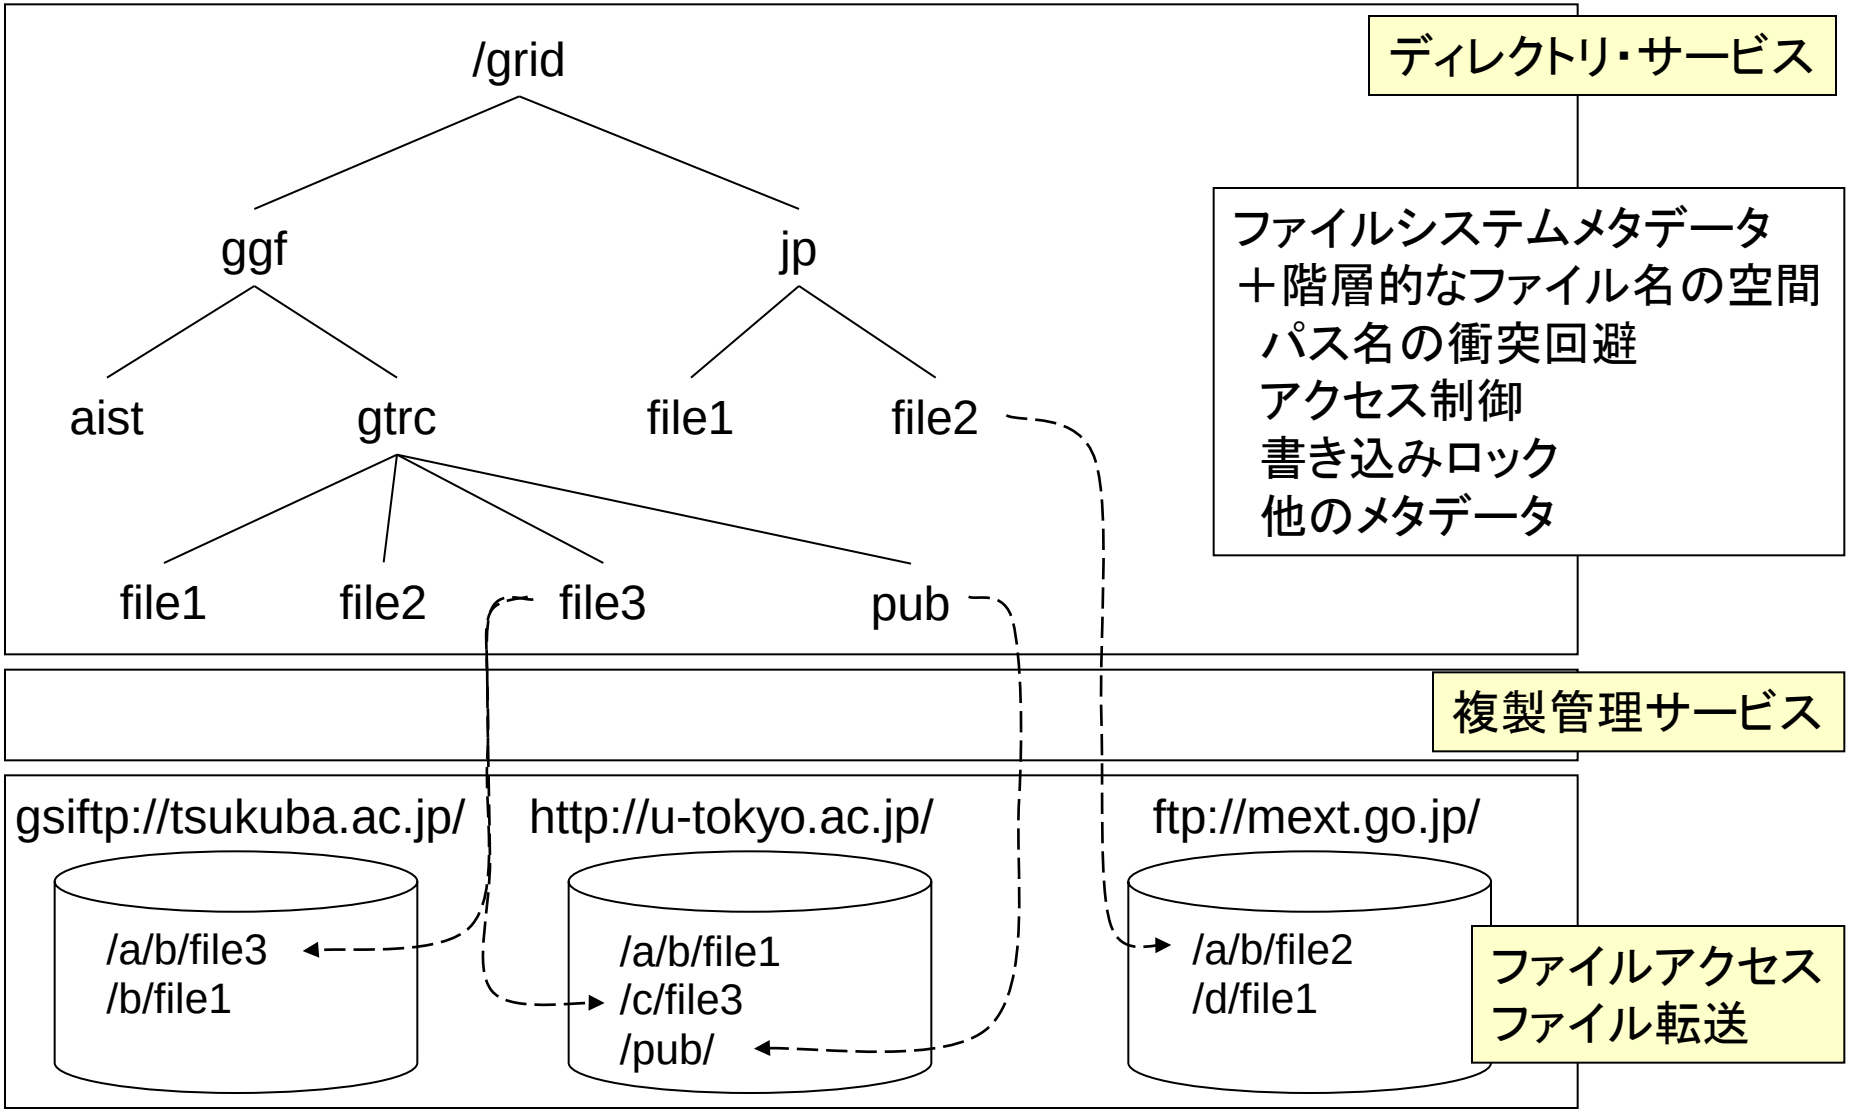
/grid
ggf
jp
aist
gtrc
file1
file2
file1
file2
file3
pub
ディレクトリ・サービス
ファイルシステムメタデータ
＋階層的なファイル名の空間
パス名の衝突回避
アクセス制御
書き込みロック
他のメタデータ
複製管理サービス
gsiftp://tsukuba.ac.jp/
http://u-tokyo.ac.jp/
ftp://mext.go.jp/
/a/b/file3
/b/file1
/a/b/file1
/c/file3
/pub/
/a/b/file2
/d/file1
ファイルアクセス
ファイル転送

ディレクトリ管理サービス

- **仮想的な階層名前空間の管理**
  - ファイルシステムのディレクトリツリーのような
- **ファイル，データ，ファイルシステム，データベースなどを参照するポインタを保持することにより，分散配置されたデータを統一的な階層名前空間で管理**

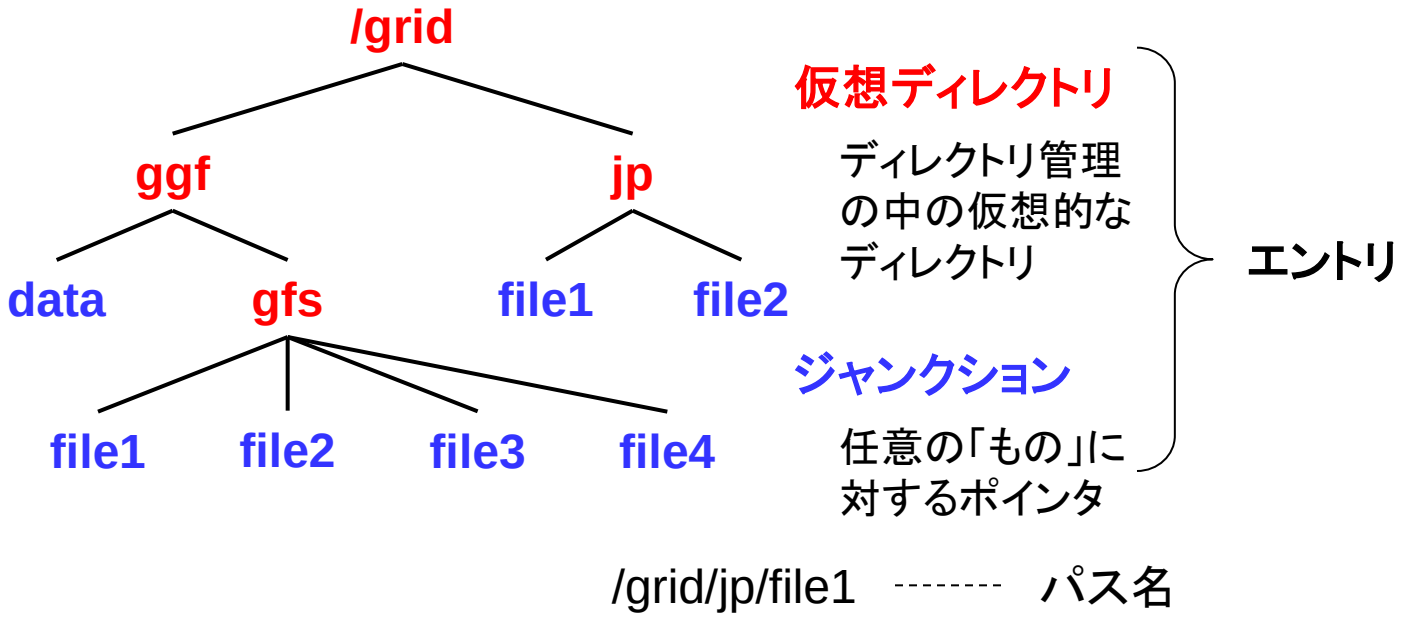

階層化によるディレクトリの分散管理

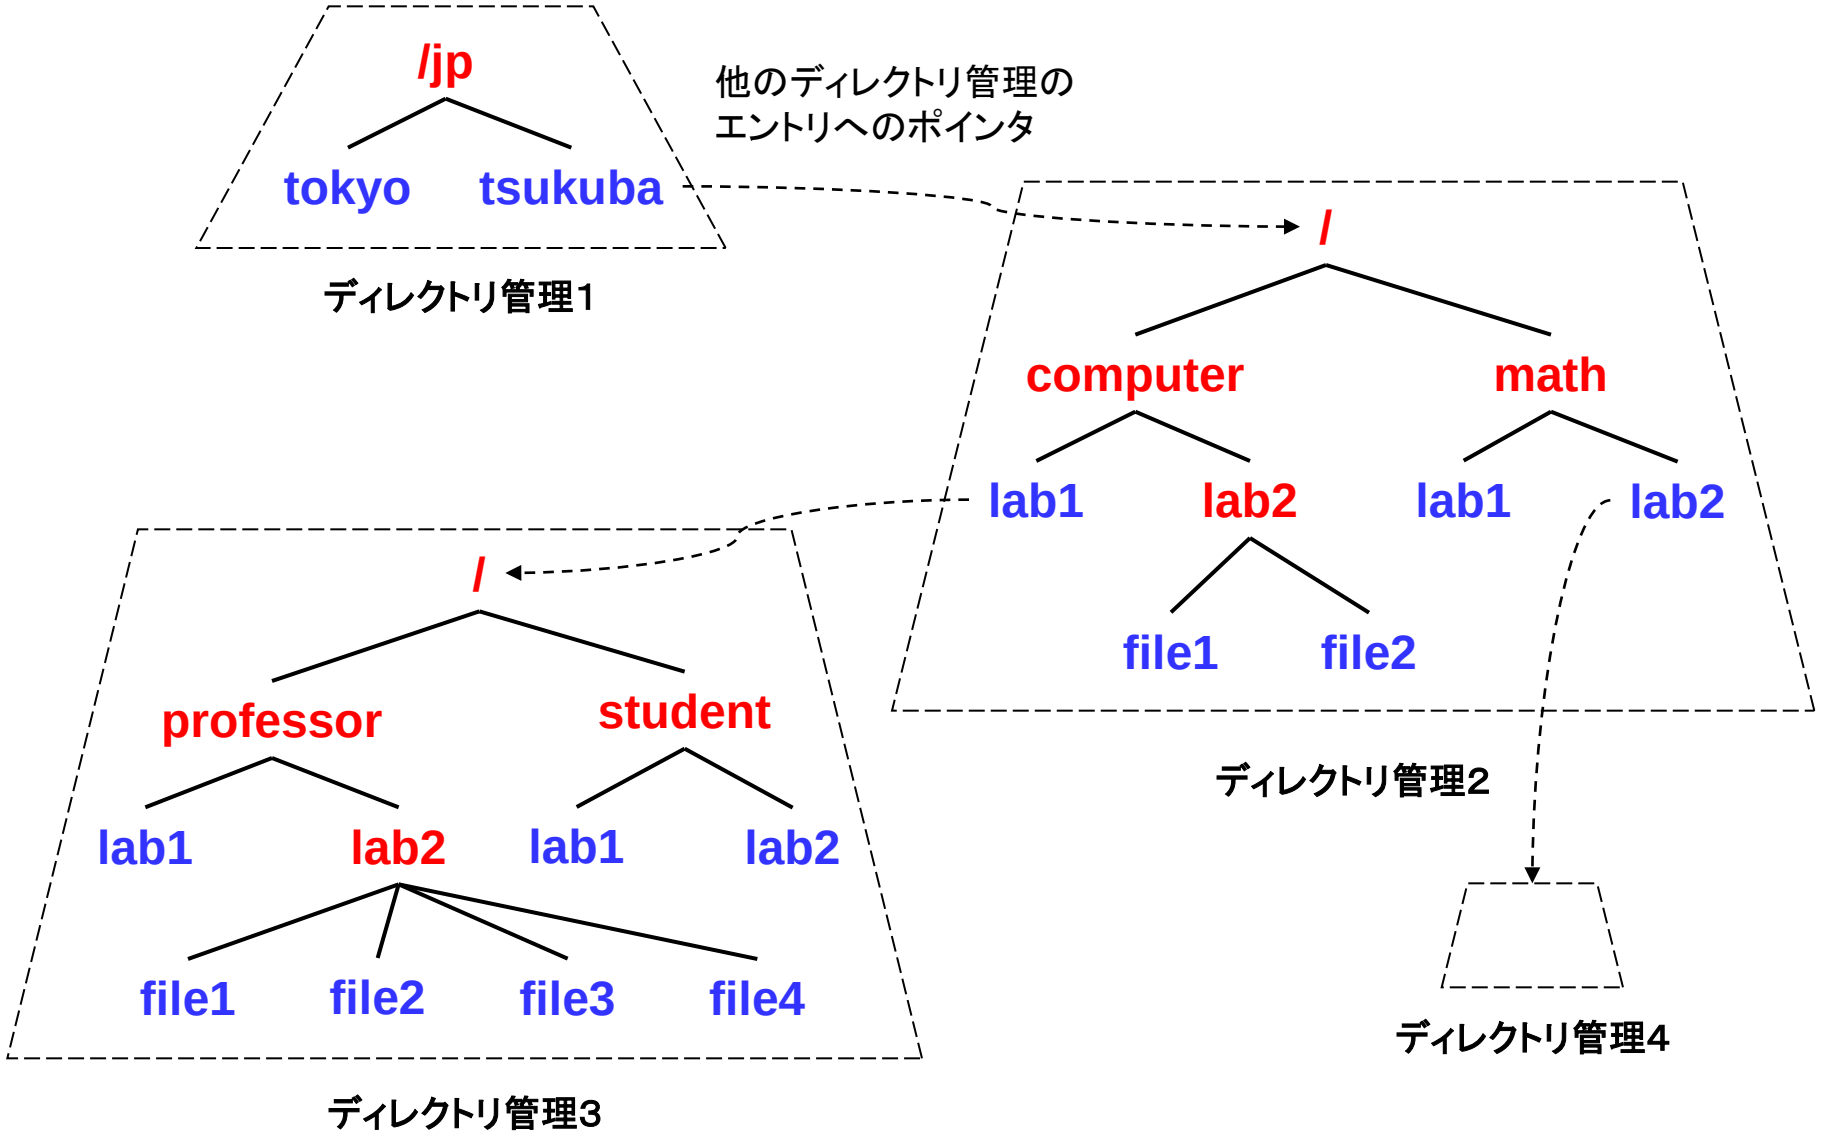

ディレクトリ管理の標準化 - RNS

- **Open Grid Forum**
  - http://www.ogf.org
- **M. Pereira, O. Tatebe, L. Luan, T. Anderson, “Resource Namespace Service Specification”, GFD.101, 2007**
- **5つのインターフェース**
  - Add, list, update, query, remove
- **エントリに自由にメタデータを追加可能**
  - グリッドファイルシステムのメタデータ管理
  - バイオ，ナノなどのアプリケーション分野のメタデータ

RNSの操作

add **(string: entry_name, EPR: entry_reference, . . .)**

list **(string: entry_name_regexp)**

update **(EPR: parent, string: entry_name, EPR: entry_reference, . . .)**

query **()**

remove **([string: entry_name | string: regexp])**

Add (1)

- **add request message**

```
<rns:add>
  <rns:entry_name>
    xsd:string
  </rns:entry_name>
  {any}*
  <rns:entry_reference>
      wsa:EndpointReferenceType
  </rns:entry_reference>
</rns:add>
```

Add (2)

- **addResponse response message**

```
<rns:addResponse>
  <rns:entry_reference>
      wsa:EndpointReferenceType
  </rns:entry_reference>
</rns:addResponse>
```

ファイルの複製（１）

- **アクセス性能の向上，安定性の向上のため，ファイル複製を作成することは有効**
- **複製管理サービスは**
  - 「論理名」を管理し，
  - 「論理名」から同一な「もの」へのポインター覧へ変換する
- **「論理名」はファイルやデータを一意に表すID**
- **UUIDのような人にとって意味をなさないものとなるため，ディレクトリ管理などと併用される**
  - パス名→論理名→ポインタ

ファイルの複製（2）

- **複製選択**
  - もっとも「適切な」ファイル複製を選択する
  - データアクセス時間最短など
    - データサイズ小の時，ネットワーク的に近い場所
    - データサイズ大の時，バンド幅大の場所
- **複製配置**
  - 複製を作成する場所を決定する
    - ファイル複製作成時間を短くしたい
    - ディザスタリカバリを想定して，地理的に離れた場所に複製を作成したい
    - ホットスポットの回避
      - アクセスが集中しているファイルの特定
      - アクセス集中をもっとも適切に防ぐように

複製管理に関する標準化 – WS-Naming

- 「論理名」からポインタへの変換（リゾルバ）部分
- A. Grimshaw, D. Snelling, “WS-Naming Specification”, GFD.109, 2007
- ポインタはEPR (WS-Addressing Endpoint Reference) で表される
- EPRを拡張，「論理名」のエンドポイント識別子を埋込
- エンドポイント識別子により，同一性の判定
- EPRのアドレスを更新するリゾルバのアドレスも埋込まれ，アドレスの更新が可能

WS-Namingの例

```
<wsa:EndpointReference xmlns:wsa="..." xmlns:naming="...">
        <wsa:Address>http://tempuri.org/application</wsa:Address>
        <wsa:Metadata>
                <naming:EndpointIdentifier>
                        urn:guid:B94C4186-0923-4dbb-AD9C-39DFB8B54388
                </naming:EndpointIdentifier>
                <naming:ReferenceResolver>
                        <wsa:Address>
                                http://tempuri.org/resolver
                        </wsa:Address>
                </naming:ReferenceResolver>
        </wsa:Metadata>
</wsa:EndpointReference>
```

エンドポイント識別子

EPR更新のための
リゾルバ

ファイル管理に関するサービスの連携

- **ホットスポットとなるファイルの複製作成**
  - アクセス情報サービスによりアクセスが頻繁なファイルリストを取得
  - アクセス頻度から必要な複製数を決定
  - 複製配置により作成先の決定
  - それぞれのファイル複製作成に対し，複製作成元となるファイル複製を複製選択により決定
  - ファイル複製生成のスケジュールの決定
  - スケジュールに従い，データ転送を行う
  - データ転送完了後，作成した複製を登録

サービス連携の問題

- **エラーや障害発生時の処理**
- **データ転送の途中でネットワーク障害が発生**
  - 転送途中のゴミファイルが残ってしまう

→一連のサービス連携に対し，トランザクションを保証する

  - 処理を見張るサービスを導入
  - 処理途中のチェックポイントを保存
  - エラー発生時には再実行を試みる
  - 失敗した場合は，ロールバックを行う
  - 処理を見張るサービスが（障害により）中断することにも配慮が必要

広域高速データ転送

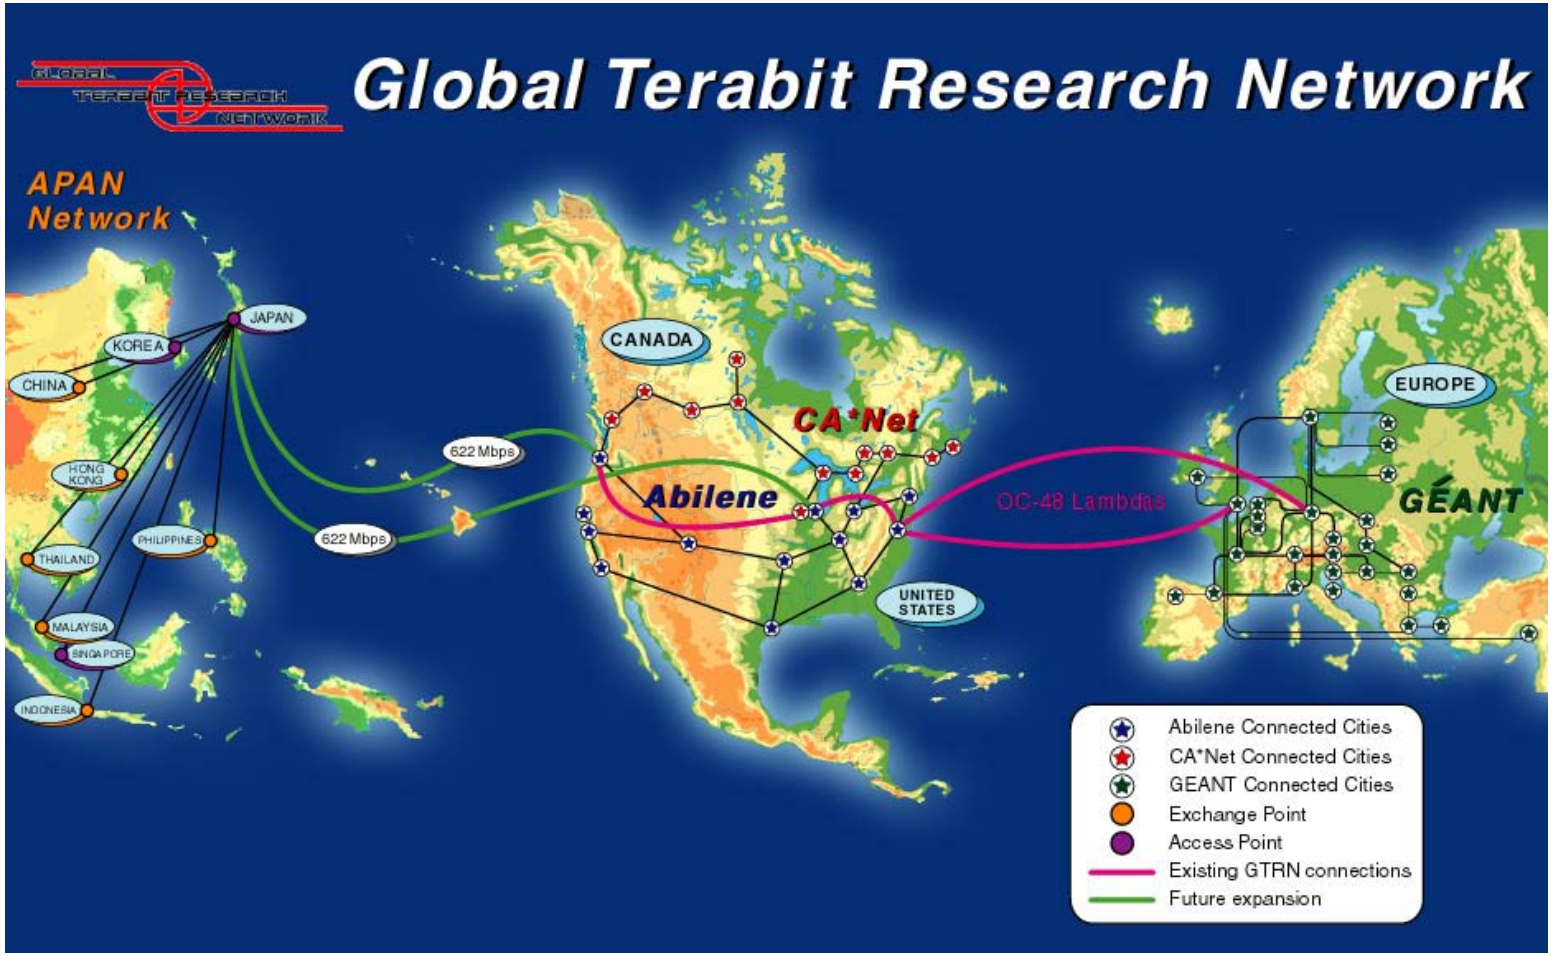
Global Terabit Research Network
APAN Network
JAPAN
KOREA
CHINA
HONG KONG
PHILIPPINES
THAILAND
MALAYSIA
SINGAPORE
INDONESIA
622 Mbps
622 Mbps
CANADA
CA*Net
Abilene
UNITED STATES
OC-48 Lambdas
EUROPE
GÉANT
Abilene Connected Cities
CA*Net Connected Cities
GEANT Connected Cities
Exchange Point
Access Point
Existing GTRN connections
Future expansion

IP (RFC791, 1981)

- **Internet Protocol**
- **Internet address で指定される source から destination へデータグラムと呼ばれるデータを転送**
- **必要であれば長いデータグラムの分割、再構成も行う**
  - MTU – Maximum Transmission Unit
  - DFフラグにより断片化禁止
- **ネットワーク上のデータグラムの転送のみを提供し、信頼性、フロー制御などは行わない**
- **生存期間、チェックサム**

- **Internet address (IP address)**
  - Version 4
  - 32 bits

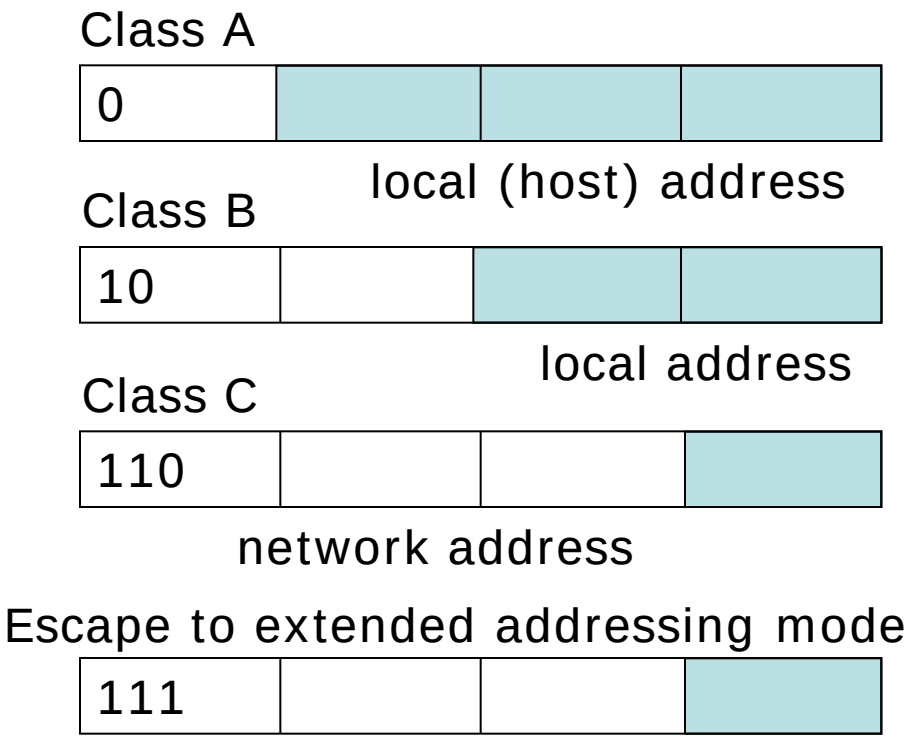

TCP (RFC793, 1981)

- **Transmission Control Protocol**
- **プロセス間の信頼性のある通信サービス**
- **基本データ転送**
  - 双方向のバイトストリームの転送
  - 転送の確認のためのプッシュファンクション。プッシュは直ちにデータを送信する
- **信頼性**
  - TCPはデータ化け、損失、重複、順序の入れ替えなどを復元
  - Sequence numberとacknowledgment (ACK)による
  - ACKがタイムアウト(Retransmission timeout; RTO)したら再送する
  - 受信側はsequence numbersにより重複、順序の入れ替えを検出
  - それぞれのセグメントにチェックサムを付加することによりデータ化けを検出、検出時は捨てる
- **フロー制御**
  - 受信側が送信データ量を制御
  - それぞれのACKと同時に”（広告）window”を返す
  - “window” は、さらなる許可なしに送信してもいいデータ量を示す（空きバッファ量）
  - 輻輳制御
    - 送信側、受信側、その間のネットワークのうち送信側以外にボトルネックがあった場合、ボトルネックを超えて送信し続けることを防ぐ
- **多重送信 (multiplexing)**
  - 単一ホストの多くのプロセスがTCPを利用するためにいくつかのポートがある
  - ポートとホストアドレスでソケット、コネクションはソケットのペア
  - Well-known ポート番号 (cf. /etc/services)
- **コネクション**
  - ソケット、sequence numbers、ウィンドウサイズなど通信の情報をコネクションと呼ぶ
  - プロセス間通信の前にコネクションを確立する必要がある
  - 信頼性のないホストと信頼性のないインターネットにおけるコネクションの確立のため、clock-based sequence numbers が用いられる

ウィンドウ（輻輳）制御アルゴリズム

- **Ackがなくても送信してもよい輻輳ウインドウサイズの制御アルゴリム**
  - Ackのたびに変更（RTTに依存）
- **Reno, Newreno, Vegas, Sack, Fack などが知られる**
- **Renoが現状で最もよく使われ、かつほかのアルゴリズムより強い**
- **Renoでの輻輳ウィンドウの変化**
  - スロースタートフェイズ
    - 輻輳ウィンドウが最小の場合
    - ウィンドウサイズを指数的に増加
  - 輻輳回避フェイズ
    - ウィンドウサイズを1ずつ増加
    - パケットロスが起きた時点で輻輳ウィンドウを半分に

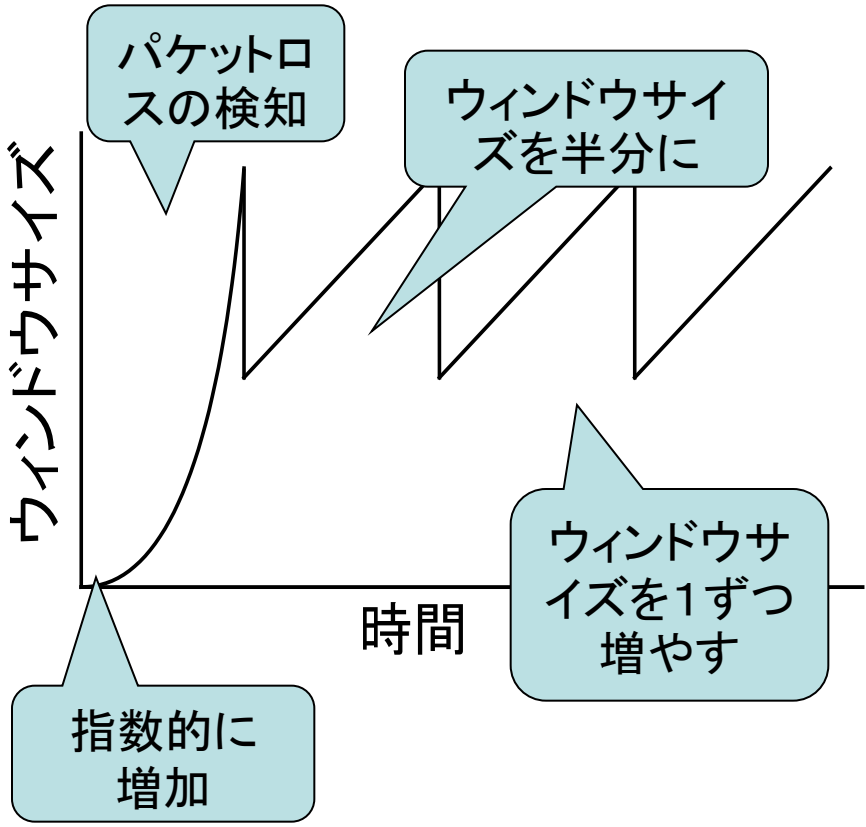

- **⇒バンド幅を75%程度しか使用できない**

高速広域ネットワークにおけるデータ転送

- **LFN (elephan(t), Long, Fat Network)における TCPの性能低下**
- **RFC1323 TCP Extensions for High Performance (1992)**
  - TCPの転送速度はネットワーク速度ではなく、バンド幅×遅延による
  - バンド幅×遅延はネットワーク上で転送されるデータ量であり、TCPで最大バンド幅を出すためには、このバッファ量が送信側、受信側に要求される

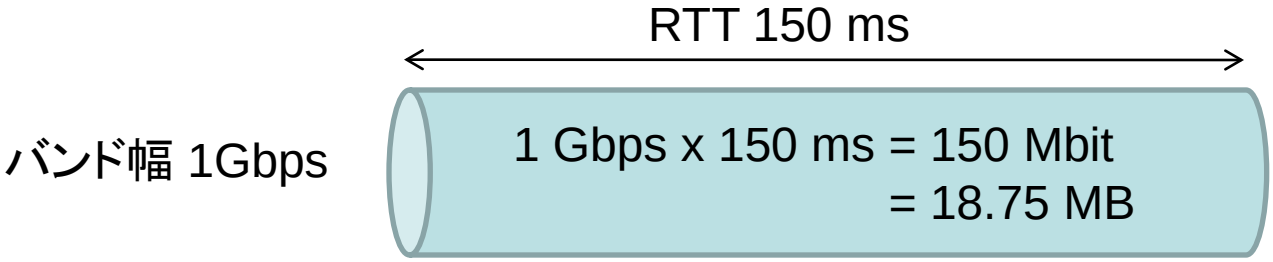

TCP over LFN における性能の問題

- **ウィンドウサイズの制限**
  - 受信ウィンドウサイズはTCPヘッダの16bitのフィールドで送信側に送られる
    - 最大ウィンドウサイズ=64KB
    - バンド幅の上限=64KB/RTT
  - TCPオプションWindow Scaleの導入 (RFC1323)
    - 16bit -> 30bit = 1GB (31bit sequence number の制限)
- **パケットロスからの復帰**
  - LFNにおけるパケットロスは悲劇的
  - パケットロスにより、データパイプラインのフラッシュとスロースタートによる復帰
  - ウィンドウサイズを広げることによりより可能性が大
- **往復の遅延測定**
  - 適切なRTOの動的決定がTCP性能において重要
  - RTOはRTT (round-trip time) の平均と分散により決定
  - TCPオプションTimestampsの導入 (RFC1323)
- **RTTの増加により輻輳ウィンドウがなかなか大きくならない**
  - MTUの増加
  - HighSpeed TCP (RFC3649), Scalable TCP, CUBIC（Linuxデフォルト）, Compound TCP（Windows Vistaデフォルト）

ネットワークストライピング

- 大容量ソケットバッファサイズの指定はroot権限が必要
- アプリケーションレベルの複数ストリームによる転送
- デフォルトのバッファサイズ(=64KB)×ストリーム数を指定する効果
- 実験では上記をしのぐ効果

TransPAC (Tokyo – Seattle)とNistNETによる並列ストリームのバンド幅の評価

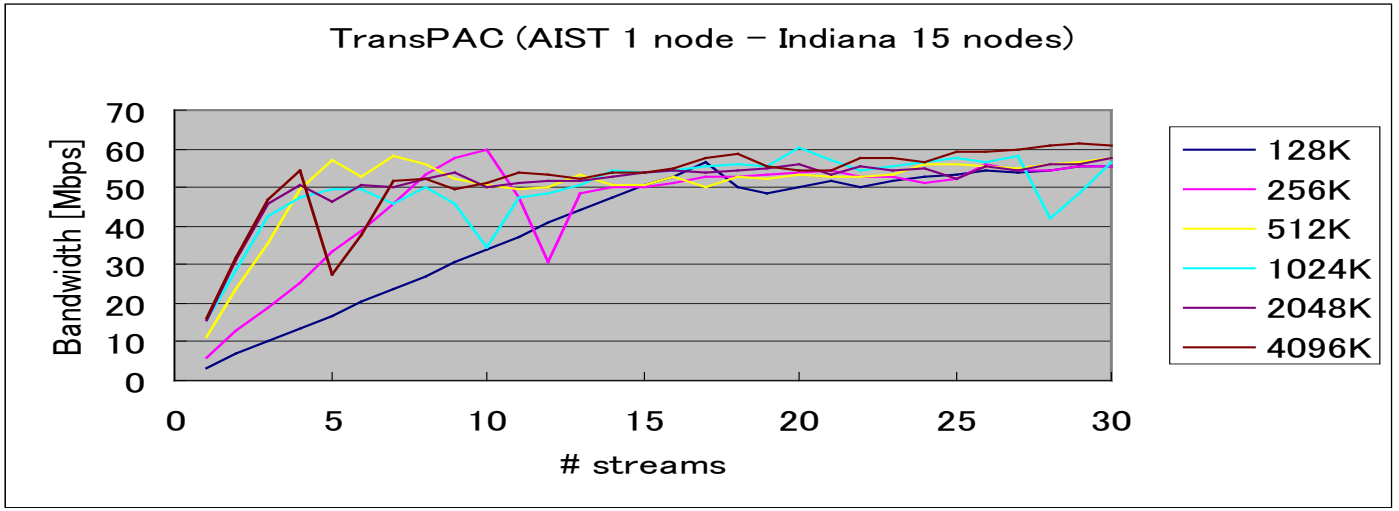

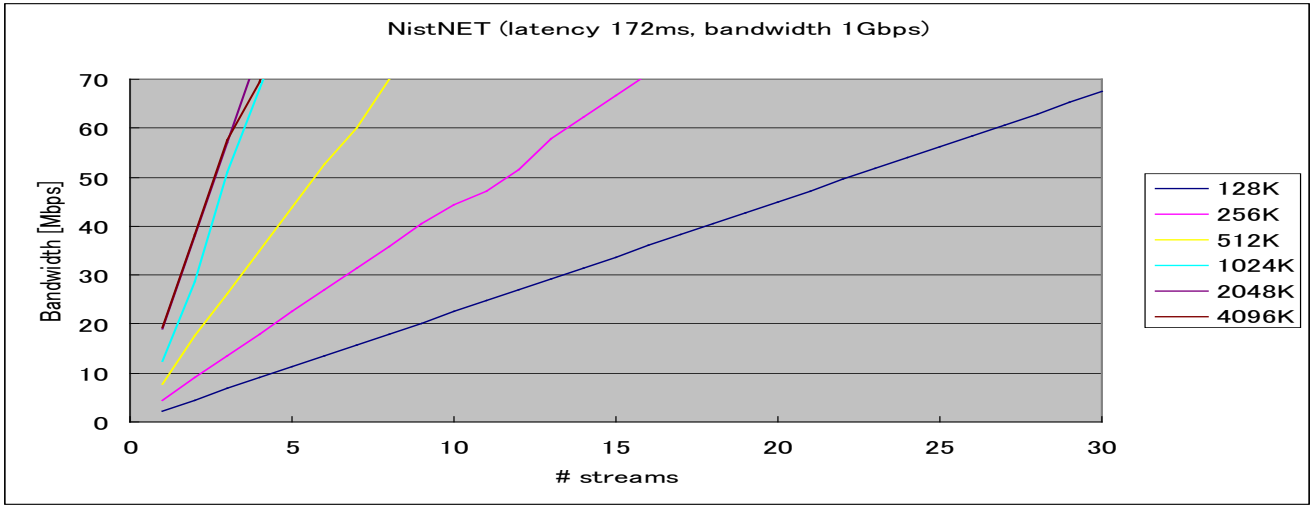

GridFTP (GFD20, 2003)

- **GridFTP: extended version of popular FTP protocol for Grid data access and transfer**
- **Secure, efficient, reliable, flexible, extensible, parallel, concurrent, e.g.:**
  - Third-party data transfers, partial file transfers
  - Parallelism, network striping, striping server (e.g., on PVFS)
  - Automatic and manual TCP tuning
  - Reliable, recoverable data transfers, data channel authentication
- **Reference implementations**
  - gridftp-server, globus-url-copy, uberftp
  - Flexible, extensible libraries in Globus Toolkit

GridFTPによる拡張

- **プロトコル拡張**

SPAS	Striped Passive	Host/portの配列を返す
SPOR	Striped Port	Host/portの配列を返す
ERET	Extended Retrieve	ファイルを一部分を転送する
ESTO	Extended Store	ファイルの一部分を格納する
SBUF	Set TCP Buffer Size	TCPのバッファサイズを設定する
ABUF	Auto-negotiate TCP Buffer Size	自動的にTCPのバッファサイズを決定する
DCAU	Data Channel Authentication	制御チャネルはRFC2228でGSS認証が導入されたが，データチャネルにも導入

- **モード拡張**
  - EBLOCK (Extended block)モード
  - データをブロックに分割して送信可能とするため
  - 8bitのフラグ，64bitのサイズ，64bitのオフセット，データ

参考文献:広域高速データ転送

- H. Sivakumar, S. Bailey, R. L. Grossman. PSockets: The Case for Application-level Network Striping for Data Intensive Applications using High Speed Wide Area Networks, Proc. SC2000 http://www.sc2000.org/techpapr/papers/pap.pap240.pdf
- Thomas Dunigan, Matt Mathis, Brian Tierney. A TCP Tuning Daemon, Proc. SC2002 http://www.sc2002.org/paperpdfs/pap.pap151.pdf
- Thomas J. Hacker, Brian D. Noble, Brian D. Athey. The Effects of Systemic Packet Loss on Aggregate TCP Flows, Proc. SC2002 http://www.sc2002.org/paperpdfs/pap.pap270.pdf
- B. Allcock, J. Bester, J. Bresnahan, A. L. Chervenak, I. Foster, C. Kesselman, S. Meder, V. Nefedova, D. Quesnal, S. Tuecke. Data Management and Transfer in High Performance Computational Grid Environments. Parallel Computing Journal, Vol. 28 (5), May 2002, pp. 749-771. http://www.globus.org/research/papers/dataMgmt.pdf
- W. Allcock, J. Bester, J. Bresnahan, A. Chervenak, L. Liming, S. Meder, S. Tuecke. GridFTP Protocol Specification. GGF GridFTP Working Group Document, September 2002. http://www.globus.org/research/papers/GridftpSpec02.doc

参考文献:複製管理

- A. Chervenak, E. Deelman, I. Foster, L. Guy, W. Hoschek, A. Iamnitchi, C. Kesselman, P. Kunst, M. Ripenu, B, Schwartzkopf, H, Stockinger, K. Stockinger, B. Tierney. Giggle: A Framework for Constructing Scalable Replica Location Services. Proc. SC2002 http://www.sc2002.org/paperpdfs/pap.pap239.pdf

Resource Management

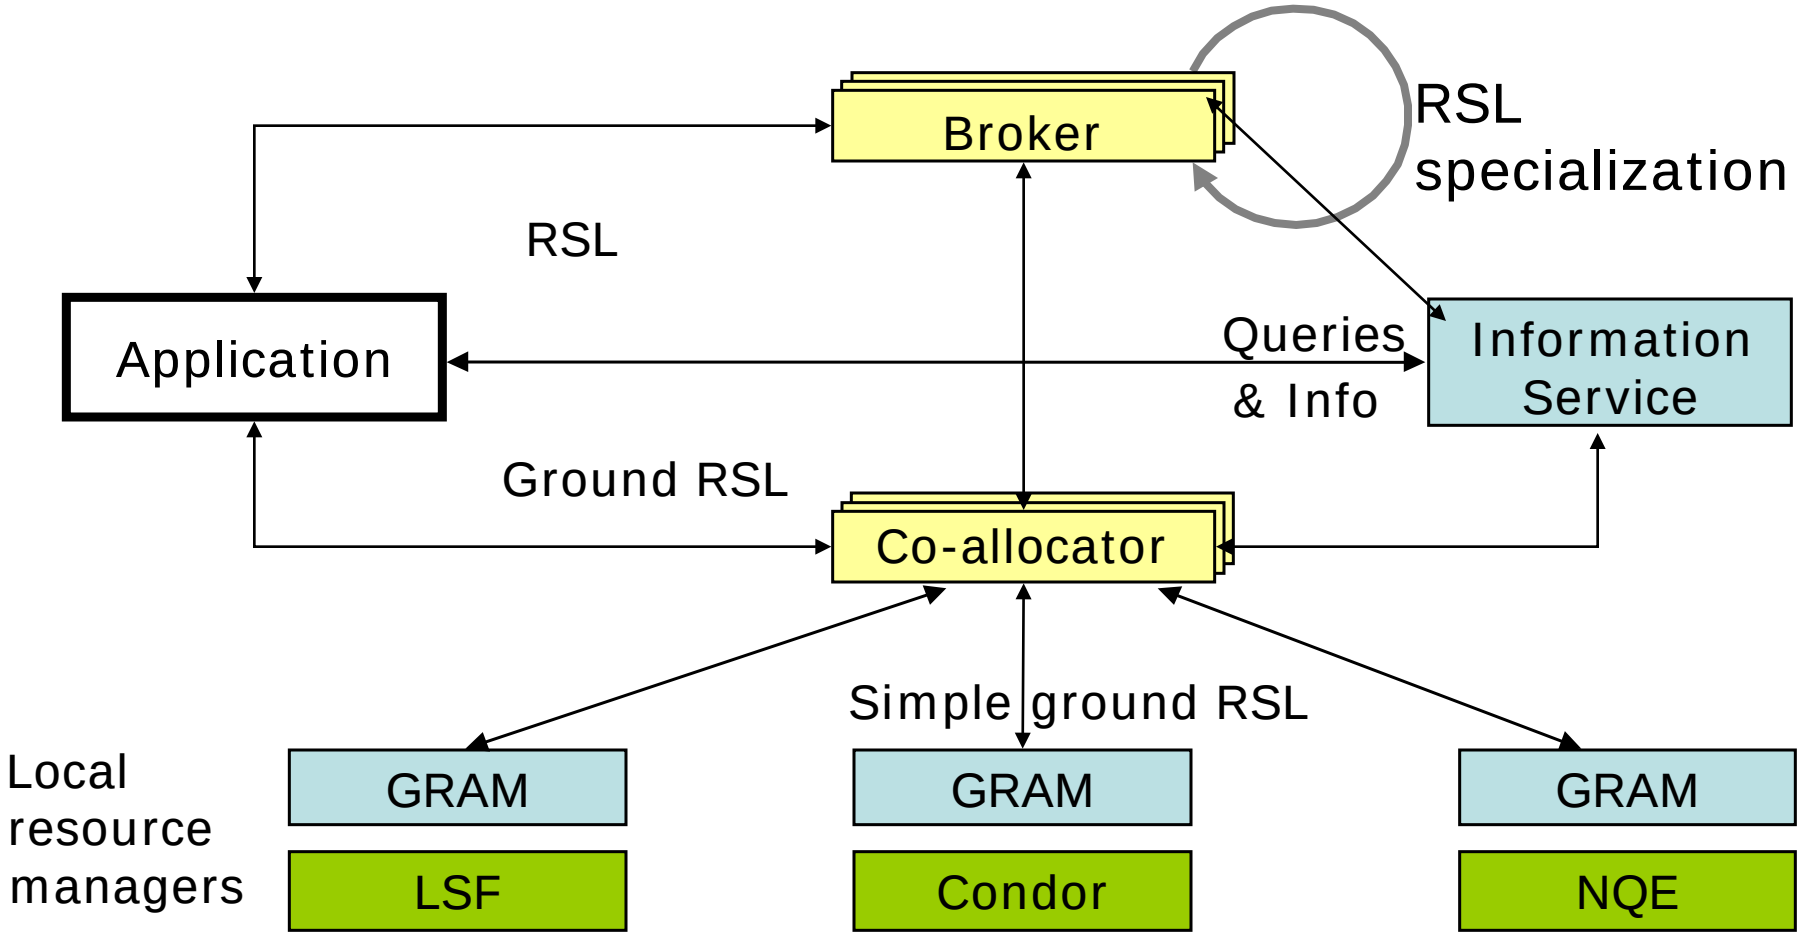

参考文献:資源管理、資源割当

- Rajesh Raman, Miron Livny, and Marvin Solomon, Resource Management through Multilateral Matchmaking, Proc. Ninth IEEE Symposium on High Performance Distributed Computing (HPDC9), August 2000, pp 290-291. http://www.cs.wisc.edu/condor/doc/gangmatching.ps
- Fabio Kon, Roy Campbell, M. Dennis Mickunas, Klara Nahrstedt, and Francisco J. Ballesteros. 2K: A Distributed Operating System for Dynamic Heterogeneous Environments. Proc. Ninth IEEE Symposium on High Performance Distributed Computing (HPDC9), August 2000. http://choices.cs.uiuc.edu/2k/papers/hpdc2000.pdf