グローバルコンピューティングシミュレータの概要

竹房　あつ子[†1]　合田憲人[†2]　中田秀基[†3]
松岡　聡[†2]　長嶋雲兵[†4]

グローバルコンピューティングシステムが複数提案される一方，グローバルコンピューティングシステムのスケジューリング手法に対する考察が不十分である．これは大規模かつ再現性のある評価実験が困難であることに起因する．本稿ではグローバルコンピューティングシステムのスケジューリングアルゴリズムとそのフレームワークのための評価基盤を提供するシミュレータ Bricks を提案する．Bricks では様々なシミュレーション環境やスケジュールアルゴリズムおよびスケジューリングに関するモジュールを設定可能である．また，これらのモジュールを既存グローバルコンピューティングシステムモジュールに置き換えることで，Bricks 上での既存システムの機能試験を実施することができる．他システムの Bricks への組み込み例としてリソース情報の予測システムである NWS を用いて本システムの評価実験を行ったところ，Bricks が実環境と同等の挙動を示すことを確認した．さらに，NWS が Bricks 上で正常に動作したことから，Bricks が既存の外部モジュールに対して機能試験環境を提供できることを示した．

Overview of a Global Computing Simulator

Atsuko Takefusa,[†1] Kento Aida,[†2] Hidemoto Nakada,[†3]
Satoshi Matsuoka[†2] and Umpei Nagashima [†4]

While there have been several proposals of high performance global computing systems, scheduling schemes for the systems have not been well investigated. The reason is difficulties of evaluation by large-scale benchmarks with reproducible results. This paper describes an overview of the Bricks simulator that evaluates scheduling schemes on a typical high-performance global computing system. The Bricks can simulate various behaviors of global computing systems, especially the behavior of networks and resource scheduling algorithms. Moreover, Bricks is componentalized such that not only its constituents could be replaced to simulate various different system algorithms, but also allows incorporation of existing global computing components via its foreign interface. To test the validity of the latter characteristics, we incorporated the NWS system, which monitors and forecasts global computing systems behavior. Experiments were conducted by running NWS under a real environment versus the simulated environment given the observed parameters of the real environment. Under both environments, NWS behaved similarly, making quite comparative forecasts.

1. はじめに

グローバルコンピューティングは広域ネットワーク上に分散した計算 / 情報リソースを活用して大規模計算を実現する計算技術であり，近年これを目的としたシステムが複数提案されている[1)]．各システムではグローバルコンピューティングを効率的に行うために，計算リソースの基本性能，利用状況およびリソース間のネットワークの状況をモニタし，それらの情報をもとに遠隔ユーザの要求するタスクを適切に割り当てるスケジューリングフレームワークを実装している．

グローバルコンピューティングシステムにおける各スケジューリング手法の公平な比較と，その特性の調査を行うためには，様々な

- ネットワークのトポロジ，バンド幅，混雑度，変動
- 計算リソースのアーキテクチャ，性能，負荷，変動

等を想定した再現性のある大規模環境での評価が求められる．一方，現在行われている実環境でのスケジューリング手法の評価では評価環境の規模が制約され，再現性もないことにより，他の研究者により開発されたスケジューリングアルゴリズムとの比較が困難である．また，グローバルコンピューティングリソースのモニタ・予測情報はスケジューリングに大きく影響するにも関わらず，開発されたスケジューリングに関するモジュール

†1 お茶の水女子大学
Ochanomizu University
†2 東京工業大学
Tokyo Institute of Technology
†3 電子技術総合研究所
Electrotechnical Laboratory
†4 物質工学工業技術研究所
National Institute of Materials and Chemical Research

の実環境上での機能試験の実施コストが高いという問題がある．

本稿では，グローバルコンピューティングシステムのスケジューリング手法およびそのフレームワークの評価基盤を提供するグローバルコンピューティングシミュレータ Bricks を提案する．Bricks は様々なネットワークトポロジ，計算サーバアーキテクチャ，通信モデルおよびスケジューリングフレームワークの各モジュールを設定可能にする Bricks 環境設定スクリプトをユーザに提供し，(1) スケジューリングアルゴリズムの性能評価と，(2) グローバルコンピューティングシステム開発者が開発するスケジューリングのためのプログラムモジュールの機能試験を可能にする．

他システムのスケジューリングに関するモジュールの Bricks への組み込み例として，グローバルコンピューティングのリソース予測システムである NWS[2),3)] を用いた．本システムと NWS を用いた評価実験では，通信スループットの実測値を用いた通信モデルにより Bricks が実環境とほぼ同等の挙動を示す再現性のある評価環境が提供できることを確認した．また，NWS が実環境上での運用と同様に Bricks 上で正常に動作したことから，Bricks が既存システムのスケジューリングに関するモジュールの機能試験を可能にすることを示した．

以後 **2**では Bricks の概要を説明し，**3**では Bricks のアーキテクチャについて述べる．また，**4**では NWS の Bricks への組み込みを例にした他のグローバルコンピューティングシステムの機能試験のための枠組について説明し，**5**でその評価結果を示す．

2. Bricks の概要

Bricks は Java で実装されたグローバルコンピューティングシステムのスケジューリング手法の性能評価ツールであり，スケジューリングアルゴリズムの評価とそのフレームワークの運用テストを行うための大規模かつ再現性のある評価実験環境を提供することを目的としている．Bricks の特徴は以下のようにまとめられる．

- Bricks シミュレータはグローバルコンピューティング環境とスケジューリングユニットから構成されている（図 **1**）．シミュレーションにおける
  - スケジューリングアルゴリズム
  - スケジューリングに関する各モジュール
  - クライアント，サーバ，ネットワークの構成
  - ネットワーク / サーバでの処理方法（待ち行列）
  - シミュレーションで用いられる乱数分布

  等の設定を Bricks 環境設定スクリプトにより自由に組み立てられることから Bricks と名付けた．Bricks のユーザは Bricks 環境設定スクリプトで記述した環境設定を実行時の入力として与えることにより，様々な環境下でのスケジューリングアルゴリズムの評価実験ができる．
- グローバルコンピューティングのスケジューリングにはリソースのモニタ・予測情報が必要不可欠である．Bricks ではグローバルコンピューティングシステムのスケジューリングに関する各モジュールへのインターフェイスを提供し，既存システムモジュールの Bricks 上での機能試験を可能にする．

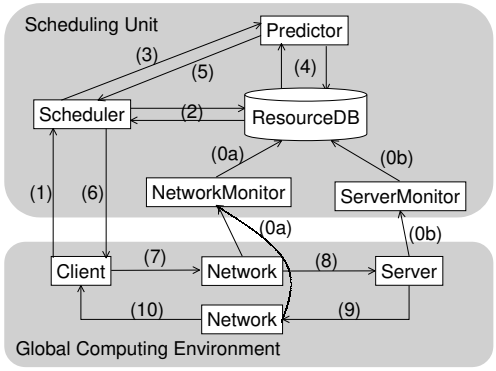

図 1 Bricks アーキテクチャ

3. Bricks のアーキテクチャ

Bricks はグローバルコンピューティング環境とスケジューリングユニットにより構成される（図 **1**）．

グローバルコンピューティング環境　グローバルコンピューティングをシミュレートする環境を提供する．

スケジューリングユニット　グローバルコンピューティングにおけるスケジューリングフレームワークを提供する．また，他のグローバルコンピューティングシステムのスケジューリングフレームワークのためのインターフェイスも提供している．

以下にその詳細な説明を行う．

3.1 グローバルコンピューティング環境

グローバルコンピューティング環境は次のモジュールにより構成される．

Client　グローバルコンピューティングにおけるユーザを表し，グローバルコンピューティングのタスクを発行する．

Network　ユーザの計算機とグローバルコンピューティングの計算リソースをつなぐネットワークを表す．Bricks ではこのネットワークを待ち行列で表現する．実際のネットワークの挙動を表すために，バンド幅，混雑度とその分散を指定するパラメータを用意している．

Server　グローバルコンピューティングの計算リソースである計算サーバを表す．ネットワーク同様にサーバも待ち行列で表す．サーバの挙動を表現するパラメータとして，サーバの性能と負荷，およびその分散がある．

Bricks におけるクライアントからのタスクのモデル，通信モデル，サーバのモデルについて以下で説明する．

3.1.1 タスクモデル

シミュレーションにおけるタスクにとって重要なことは，通信時間，計算時間がどの程度かかるかということである．現在の Bricks の実装では，これらを調べる上で必要な情報

- タスク実行に要する通信量（送信 / 受信）
- タスクの実行時の演算数

をパラメータとしてタスクを表現する．

3.1.2 通信モデル

Bricks ではシミュレーションの実行時のユーザの設定により，様々な通信モデルが実現できる．現在 Bricks で表現できる代表的な通信モデルは以下の 2 通りある．

1 つめは，ネットワークにはグローバルコンピューティングシステム以外のシステムから流されるデータ（外乱）があることを想定し，通信スループットを外乱のデータの到着率を変化させて表現するモデル[4] である．図 **2** に Bricks 環境設定スクリプトでの設定例を示す．`Network` はネットワークの設定を行う宣言であり，名前，ネットワークの待ち行列の種類，外乱のデータの設定を記述する．待ち行列は FCFS で処理されるスループット 1500[KB]，バッファ長 2 の有限バッファ待ち行列を指定している．また，外乱のデータの平均データサイズは 100.0[KB] で乱数系列の種が 88 である指数分布，到着間隔は平均 0.008 のポアソン到着で決定することを示している．

2 つめのモデルは実環境で計測された通信スループットをもとに，ネットワークの待ち行列のスループットを決定するモデルである．図 **3** にその設定例を示す．このモデルではネットワークに FCFS で処理する無限バッファ長の待ち行列を指定し，通信スループットは 1000 個のデータが含まれている `nws_throughput` ファイルを参照するように指定している．また，外乱のデータを流さないように到着間隔を ∞ に設定する．

図 **3** の設定では，時間と通信スループットの離散データから全ての時刻に対する通信スループットを算出するために，3 点の時刻と通信スループットのみで補間値を計算できる 3 次スプライン補間を採用している．補間法もまた，他のアルゴリズムを用いることができる．

3.1.3 計算サーバモデル

計算サーバは現在 FCFS で処理することを前提としている．サーバもネットワーク同様に待ち行列で表され，演算数，外乱のジョブの到着間隔を指定することによりその稼働率を決定する．サーバも負荷の変動を実環境で測定された数値により表現することができる．

3.2 スケジューリングユニット

グローバルコンピューティングシステムのスケジューリングをサポートする枠組として，Bricks ではスケジューリングユニットを提供する．スケジューリングユニットではグローバルコンピューティングのスケジューリングで必要とされる各モジュールを実装している．

NetworkMonitor グローバルコンピューティング環境におけるネットワークの通信スループット，レイテンシ等のネットワークの状況をモニタする．得られた情報は ResourceDB に格納する．

ServerMonitor グローバルコンピューティング環境における計算サーバの性能，負荷，稼働率をモニタし，得られた情報は ResouceDB に格納する．

ResourceDB グローバルコンピューティングシステムにおける総合データベースである．各モニタからリソース情報が格納され，Predictor ，Scheduler に対してその情報を提供する．

Predictor ResourceDB からリソース情報を入手し，そのリソースの可用性を予測する．この予測は，新たに投入されるタスクのスケジューリングに利用される．

Scheduler ResourceDB で管理されている情報と Predictor で予測された情報をもとに，ユーザのタスクを利用可能な計算サーバから最適なサーバに割り当てる．

スケジューリングユニットの各モジュールは容易に組み変え可能である．

3.3 Bricks の実行の流れ

Bricks によるシミュレーションの実行手順を以下に示す．この手順は図 **1**に対応している．

（**0a**） NetworkMonitor は定期的に Network にプローブパケットを流し，Network の通信スループット，レイテンシを測定する．測定結果は ResourceDB に格納する．

（**0b**） ServerMonitor は定期的に Server に問い合わせて，Server の負荷情報を調べる．結果は NetworkMonitor 同様，ResourceDB に格納する．

（**1**） Client でグローバルコンピューティングのタスクが発生すると，Client は Scheduler にタスクを投入すべき Server を問い合わせる．その際，Client は Scheduler にタスクの情報を提供する．

（**2**） Scheduler は Client のタスクに対して ResourceDB にグローバルコンピューティングシステム上で利用可能な Server を問い合わせる．

（**3**） Scheduler は（2）で問い合わせた Server とその Server への Network に関するリソース状況の予測値を Predictor に問い合わせる．

（**4**） Predictor は ResourceDB に Server およびその Server への Network のモニタ情報を問い合わせ，その情報をもとに各リソース状況を予測する．

（**5**） Predictor はリソース状況の予測が終了すると，Scheduler に予測値を返す．

（**6**） Scheduler はこの予測値をもとに，タスクを発行する Server を決定し，Client に通知する

（**7**） Client は決定した Server への Network にタスクを投入する．この際，タスクの送信データは論理

```
Network network1 QueueFiniteBuffer(FixedNumberGenerator(1500.0), 2) \
  OthersData(ExponentRandomGenerator(100.0, 88), ExponentRandomGenerator(0.008, 221))
```

図 2　外乱のデータを用いた Bricks 環境設定スクリプトによるネットワークの設定例

```
Network network1 QueueFCFS(SplineThroughputGenerator(1000, ./nws_throughput)) \
  OthersData(ExponentRandomGenerator(10.0, 9988), InfNumberGenerator())
```

図 3　実データを用いた Bricks 環境設定スクリプトによるネットワークの設定例

パケットサイズに分割する．

（8）　Client から投入されたパケットが Network の待ち行列のサーバ上で

[送信データ量] / [Network のスループット]

時間処理されると，パケットは Server に送られる．

（9）　分割されたタスクのデータがすべて Server に到着すると，Server でタスクが実行される．Server の待ち行列のサーバ上で

[タスクの演算数] / [サーバの性能]

時間処理されてタスクの実行が終了すると，Server はその結果をタスクを発行した Client への Network に投入する．ただし，Client からの送信時と同様にタスクのデータは論理パケットサイズに分割される．

（10）　Server から投入されたパケットが

[受信データ量] / [Network のスループット]

時間 Network の待ち行列のサーバ上で処理されると，Client にパケットが送られる．すべてのパケットが Client に送られると，そのタスクの実行が終了する．

4. 外部モジュール組み込みインターフェイス

Bricks ではスケジューリングユニットの各モジュールに対して様々なアルゴリズムを実現したプログラムモジュールのためのインターフェイスを提供する．これらのモジュールを既存のグローバルコンピューティングシステムに置き換えることで，既存システムの Bricks 上での機能試験を可能にする．

本稿ではその第一歩として，グローバルコンピューティングシステムのリソース状況のモニタと予測を行うシステムとして UCSD で開発された NWS (Network Weather Service) の組み込みを行った（図 4）．NWS は AppLeS，Legion，Globus，Condor 等のシステムで予測機構として利用する試みがあり，他システムへの API を提供している．Bricks への組み込みでは，我々が開発した NWS の Java API[5] を用いた．

NWS は次の 4 つのモジュールにより構成される．

Persistent State　測定された情報を格納するストレージであり，Bricks における ResourceDB に対応する．

Name Server　各モジュールの TCP/IP ポート番号や IP / ドメインアドレス等の参照に用いる．

Sensor　ネットワーク，計算サーバの情報をモニタするもので，Bricks における NetworkMonitor，ServerMonitor に対応する．

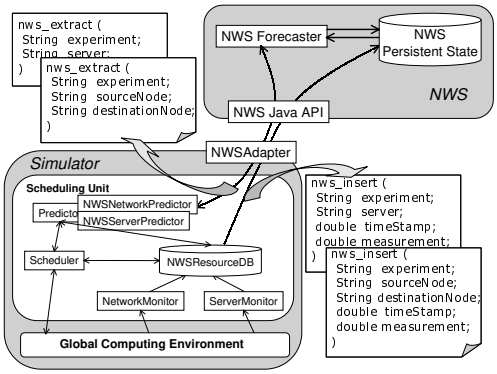

図 4　NWS の Bricks への組み込み

Forecaster　リソース情報を予測するもので，Bricks の Predictor に対応する．

Bricks に組み込む際には，NWS の Persistent State，Forecastor を用い，Bricks 内で測定された情報を Persistent State に格納し，Forecactor で予測されたデータをスケジューリングの際に利用する．これらの処理をサポートするモジュールとして NWSResourceDB，NWSNetworkPredictor，NWSServerPredictor と，NWS Java API と Bricks でのデータタイプの変換を行う NWSAdapter を用意した．

図 4 に Bricks をシミュレータに組み込んだ例を示す．Bricks 内で NetworkMonitor / ServerMonitor がモニタした情報を NWSResourceDB に格納すると，NWSResourceDB は NWSAdapter 経由で Persistent State にその情報を格納する．また，Bricks 内で予測情報が必要とされると，NWSNetworkPredictor / NWSServerPredictor が NWSAdapter 経由で NWS Forecastor から予測値を取り出すことができる．

5. Bricks の評価実験

評価では，Bricks がスケジューリングアルゴリズムを評価するための再現性のある試験環境を提供し，実際のネットワークの挙動を示す性能評価ツールであることを示す．また，スケジューリングに関する外部モジュールとして NWS を用い，NWS の Bricks 上での正常な動作を確認することで Bricks が既存システムモジュールの機能試験環境を提供できることを示す．

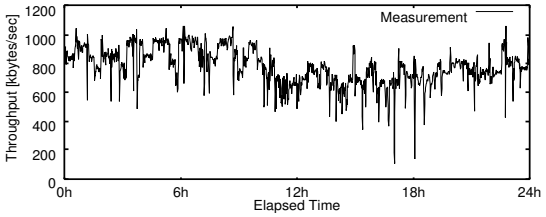

図 5　実測における通信スループット (24 時間)

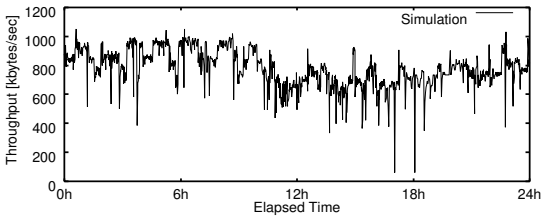

図 6　Bricks における通信スループット (24 時間)

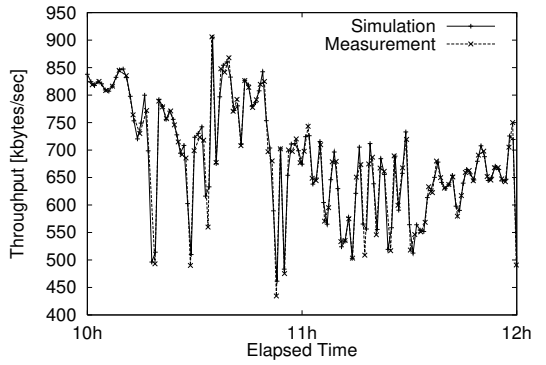

図 7　実測と Bricks の通信スループットの比較 (2 時間)

5.1　評価実験方法

評価では実環境においてグローバルコンピューティングシステムの資源予測フレームワークを提供する NWS を実行して実際のネットワークの変動の測定と予測を行い，それをシミュレータ上で再現する．

まず，東工大と電総研の 2 つの計算機に NWS Sensor を設定し，2 つのサイト間の通信スループット，レイテンシ，サーバの稼働率を測定する．NWS Forecaster には，測定されたネットワークの情報をもとに各タイムステップにおける予測を行わせる．ただし，サーバをモニタする間隔は 10[sec]，ネットワーク状況をモニタする間隔は 60[sec] とし，通信スループットを測定する際のプローブデータサイズを 300[KB] とした．

次に，実環境で NWS により測定された通信スループット値と 3 次スプライン補間法を用いた通信モデルを設定し，Bricks によるシミュレーションを行う．シミュレーションでは実際に NWS の Persistent State と Forecaster を実行し，同じモニタ間隔を設定して実測で測定された通信スループットが Bricks で得られるか，Bricks 上の NWS Forecaster が実環境同様に予測を行うかどうか調べる．

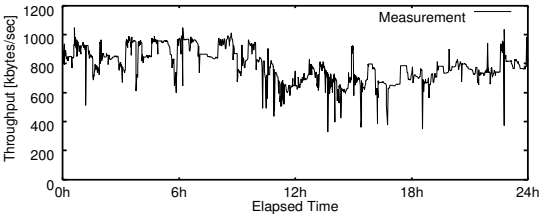

図 8　実環境における通信スループットの予測値 (24 時間)

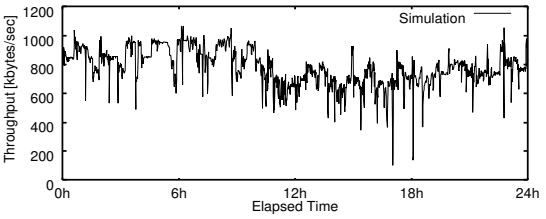

図 9　Bricks における通信スループットの予測値 (24 時間)

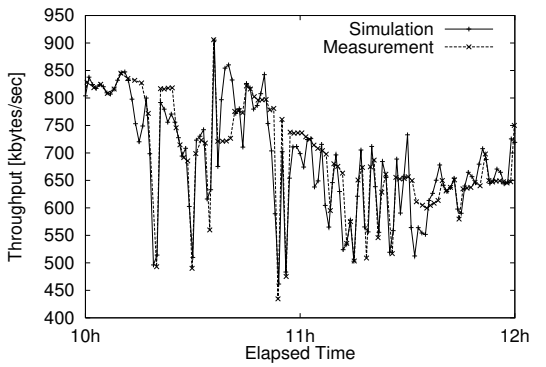

図 10　実環境と Bricks の通信スループットの予測値の比較 (2 時間)

5.1.1　評価実験結果

図 5, 6 に実測で測定された通信スループットと Bricks で算出された通信スループットを示す．横軸は実時間およびシミュレーション時間を示しており，実測は NWS の Sensor が測定した 1999 年 2 月 1 日月曜日の深夜 0 時から火曜日の深夜 0 時までの通信スループットである．縦軸は通信スループットを [KB/sec] で示している．

全体的に実測と Bricks のシミュレーション結果はほぼ同様のスループットを示していることが分かる．図 7 は 2 時間分の実測値と Bricks で算出された通信スループットの比較をしたものであり，この図からも実測値と Bricks での通信スループットの算出値の一致が確認できる．実際のネットワークでの TCP/IP による通信スループットのモデル化の試みは複数行われているが，その挙動は複雑で，特定のパケットに対するモデル化を行っているのが現状である．Bricks ではそれらのモデルを採用可能であることは勿論，実環境における通信スループットの実測値を利用することで，実環境に則したグローバルコンピューティングシステム上での通信を再現できることが分かる．

図 8, 9 に実環境と Bricks において NWS Forecaster

が予測した通信スループットを示す．また，図 10は実測と Bricks での通信スループットの予測値の 2 時間分のデータを比較をしたものである．図 8, 9から，通信スループット値と同様に実測と Bricks での予測値の傾向がほぼ一致していることが分かる．NWS Forecaster が Bricks 上で正常に動作したことから，他のスケジューリングに関する外部モジュールの機能試験が Bricks 上で実施可能であることが示された．ただし，図 10では実環境と Bricks で出した予測結果が微妙に異なっている．これは実測と Bricks でのモニタするタイミングが異なっていたことが影響したと考えられ，実通信スループットを用いたモデルにおける補間値の算出法を検討する必要があることが示唆された．

6. 関 連 研 究

分散システムにおけるスケジューリング手法の研究は以前から行われているが，未実装であったり，実装されている場合でも他のシステムで実装されたスケジューリングアルゴリズムとの比較が非常に難しい．これらの問題に着目した，シミュレーションによる評価の試みが以下のプロジェクトでなされている．

分散システムにおけるスケジューリングアルゴリズムの評価技術としては，フロリダ大で行われている Osculant[6] の Osculant Simulator があげられる．Osculant は bidding ポリシーにしたがって計算サーバの性能をあらわす bids を計算し，bids が一番高いものを選択するボトムアップリソーススケジューラである．Osculant Simulator では Bricks 同様にネットワークのトポロジや計算ノードの設定が柔軟に行える．グローバルコンピューティングシステムのスケジューリングアルゴリズムの評価基盤を提供するものではない．

WARMstones は未実装であるが，Bricks 同様スケジューリングアルゴリズムの評価基盤としてバージニア大で提案されているシステムである．シミュレーションにおけるタスクやシステムの表現形式，および複数スケジューリングアルゴリズムを柔軟に表現するための MIL (MESSIAHS Interface Language) やライブラリなど，その基礎技術は MESSIAHS[7] に基づいている．Bricks でも MESSIAHS の技術をもとにグローバルコンピューティングでのスケジューリングに適したスケジューリングアルゴリズムの表現言語を提供する予定である．ただし，WARMstones では既存のグローバルコンピューティングのスケジューリングフレームワーク技術に対する評価基盤の提供は考えられていない．

7. ま と め

本稿では，グローバルコンピューティングシステムのスケジューリング手法およびそのフレームワークの評価基盤を提供するグローバルコンピューティングシミュレータ Bricks を提案した．Bricks はネットワークトポロジ，計算サーバアーキテクチャ，通信モデルおよびスケジューリングフレームワークの各モジュールを設定するための Bricks 環境設定スクリプトを提供し，様々なスケジューリングアルゴリズムの性能評価を可能にする．また，グローバルコンピューティングのスケジューリングを行う上で不可欠なリソース状況のモニタ・予測情報の提供をサポートする既存システムモジュールの機能試験環境を提供する．

Bricks とグローバルコンピューティングのリソース情報の予測システムである NWS を用いた評価実験では，実測通信スループットを用いた通信モデルを採用することで Bricks が実際の環境に則したグローバルコンピューティング上での通信を再現できることを確認した．また，Bricks 上で NWS の Persistent State，Forecaster が実環境上と同様に動作したことから，Bricks は既存のスケジューリングに関する各モジュールの機能試験環境を提供できることを実証した．

今後はタスク / 通信 / サーバモデルをより洗練していく．Bricks ではグローバルコンピューティングシステムで実行される様々なアプリケーションに対応する必要があるため，並列タスクの表現等のタスクモデリングが必要である．サーバのモデリングに対しては，タイムシェアリングなどの異なるタスクの処理方式や，マルチプロセッサ等のアーキテクチャへの対応を行う．また，Bricks を用いてグローバルコンピューティングシステムにおける適切なスケジューリングアルゴリズムの調査，考案を行う．

参 考 文 献

1) Foster, I. and Kesselman, C.(eds.): *The Grid: Blueprint for a New Computing Infrastructure*, Morgan Kaufmann (1998).
2) NWS. `http://nws.npaci.edu/NWS/`.
3) Wolski, R., Spring, N. T. and Hayes, J.: The Network Weather Service: A Distributed Resource Performance Forecasting Service for Metacomputing, Technical Report TR-CS98-599, UCSD (1998).
4) 竹房あつ子, 合田憲人, 小川宏高, 中田秀基, 松岡聡, 佐藤三久, 関口智嗣, 長嶋雲兵: 広域計算システムのシミュレーションによる評価 – Ninf システムの広域分散環境でのジョブスケジューリング実現に向けて –, 並列処理シンポジウム JSPP'98 論文集, pp. 127–134 (1998).
5) NWS Java API. `http://ninf.etl.go.jp/~nakada/nwsjava/`.
6) Osculant. `http://beta.ee.ufl.edu/Projects/Osculant/`.
7) Chapin, S. J. and Spafford, E. H.: Support for Implementing Scheduling Algorithms Using MESSIAHS, *Scientific Programming*, Vol. 3, pp. 325–340 (1994).