


高性能計算のためのグリッド環境実現に 向けてのフィジビリティスタディ

石川裕、松葉浩也
東京大学


背景 & 動機

- 並列アプリケーションをグリッド環境で実行させたい
- 並列アプリケーションはMPI通信ライブラリを使ってプログラムされている
- 現状のMPI通信ライブラリを使ってもインターネット上で高性能通信を達成できない



背景 & 動機

- インターネット環境
 - インターネットバンド幅 \geq クラスタにおけるネットワークバンド幅
 - 10 Gbps vs. 1 Gbps



computing resource
site A

computing resource
site B


Wide-area
Network

Single (monolithic) MPI application
over the Grid environment

背景 & 動機

- インターネット環境
 - インターネットバンド幅 \geq クラスタにおけるネットワークバンド幅
 - 10 Gbps vs. 1 Gbps

• Motohiko Matsuda, Yutaka Ishikawa, and Tomohiro Kudoh, "Evaluation of MPI Implementations on Grid-connected Clusters using an Emulated WAN Environment," CCGRID2003, 2003



computing resource
site A

computing resource
site B

Wide-area
Network


Single (monolithic) MPI application
over the Grid environment

GridMPI

- グリッド上での通信バンド幅および遅延を考慮した高性能通信MPI
 - 文部科学省リーディングプロジェクト「超高速コンピュータ網形成プロジェクト (National Research Grid Initiative: 通称 NAREGI)」における産総研再委託において実施
- 課題
 - TCPプロトコル処理層
 - M Matsuda, T. Kudoh, Y. Kodama, R. Takano, and Y. Ishikawa, “TCP Adaptation for MPI on Long-and-Fat Networks,” IEEE Cluster 2005, 2005.
 - ソフトウェアによるペーシング
 - R. Takano, T. Kudoh, Y. Kodama, M. Matsuda, H. Tezuka, Y. Ishikawa, “Design and Evaluation of Precise Software Pacing Mechanisms for Fast Long-Distance Networks”, PDLFnet2005, 2005.
 - R. Takano, Y. Kodama, T. Kudoh, M. Matsuda, F. Okazaki, Y. Ishikawa, “Realtime Burstiness Measurement,” PDLFnet2006, 2006.
- ネットワークトポロジ+通信バンド幅および遅延を考慮した通信アルゴリズム
 - 現在取り組み中

今までの取り組み


- WAN Emulatorによる性能解析




- CPU: Pentium4/2.4GHz, Memory: DDR400 512MB
- NIC: Intel PRO/1000 (82547EI)
- OS: Linux-2.6.9-1.6 (Fedora Core 2)
- Socket Buffer Size: 20MB

今までの取り組み

- 実環境での評価



- NAS Parallel Benchmarks run using 8 node (2.4GHz) cluster at Tsukuba and 8 node (2.8GHz) cluster at Akihabara
 - 16 nodes
- Comparing the performance with
 - result using 16 node (2.4 GHz)
 - result using 16 node (2.8 GHz)



背景 & 動機

- 将来のインターネット環境を想定したい
 - インターネットバンド幅 \geq クラスタにおけるネットワークバンド幅
 - 10 Gbps vs. 1 Gbps
 - 100 Gbps vs. 10 Gbps

- 
- Motohiko Matsuda, Yutaka Ishikawa, Tomohiro Kudoh, Yuetsu Kodama, Ryousei Takano, "Efficient MPI Collective Operations for Clusters in Long-and-Fast Networks," IEEE International Conference on Cluster Computing, 2006
 - Motohiko Matsuda, Yutaka Ishikawa, and Tomohiro Kudoh, "Evaluation of MPI Implementations on Grid-connected Clusters using an Emulated WAN Environment," CCGRID2003, 2003

computing
site


rce

Network

Single (monolithic) MPI application
over the Grid environment

従来の考え方


- インターネットは低帯域かつ通信遅延が大きいと仮定
 - MPI通信ライブラリが提供する集団通信 (Barrier, Bcast, AlltoAll, Allreduce, ...) の実装の仮定
 - 代表ノードによる通信
 - MPICH-G2、MagPIe、PACX-MPI



すなわち、いくら高帯域ネットワークがあっても代表ノードから出て行くネットワークの性能しか出せない。

将来


- インターネットは高帯域、通信遅延に起因するホップ数は最小限と仮定
- 帯域を使うようなアルゴリズム開発
 - GridMPI




T2K Open Supercomputer

筑波大: 80 TFlops ~



2008年3月下旬稼働開始



東大: 150 TFlops ~



京大: 66 TFlops ~



ノード理論演算性能: 160GFlops以上
ノードメモリ: 32GB以上
ノードアーキテクチャ: 64bit x86
ノード間ネットワーク: 5GByte/sec以上
MPI通信性能: 5GB/sec以上、6usec(往復遅延)

まとめ

- 10 Gbps & over 10 Gbpsを利用したグリッド環境
テスト
- スパコン間をつなげたテスト

100 Gbpsの環境が欲しい