

マルチリンク Ethernet 環境における SMP クラスタの性能評価

小林 智史[†] SHAN Axida[†] 吉永 努[†]

[†]電気通信大学 大学院情報システム学研究科

1. はじめに

近年、超並列計算機に代わってパーソナルコンピュータなどの一般的に普及しているコンピュータをネットワークで繋ぎ、1つの計算機として利用する PC クラスタシステムが注目されている。また、プロセッサが複数個搭載されている SMP コンピュータも一般的となってきた。

それらのネットワークとして、Myrinet や Infiniband, 10Gigabit Ethernet 等、低レイテンシ、高バンド幅のものも登場している。しかし、これらのネットワークインターフェイスは高価である。一般的な PC 環境においては 1Gigabit(Gb) Ethernet が実装されていることが多く、安価に利用可能である。そのため、このような Ethernet を束ねマルチリンクにすることにより高いバンド幅を実現する提案や実装が行われている。

本論文ではリンク数を増設することによる計算性能への効果を測定した。また、性能の違うノードで構成されたクラスタでの実験を行った。

2. マルチリンク

Ethernetにおいて、マルチリンクを実現する実装としてボンディングを行う Link Aggregation(IEEE802.3)や OpenMPI¹⁾、Score の通信ライブラリである PM/Ethernet などがあげられる。本実験では、容易に導入することが可能な OpenMPI を使用した。

3. ベンチマーク

3.1 NetPIPE²⁾

NetPIPE (NETwork Protocol Independent Performance Evaluator) は通信性能を計測するベンチマークである。MPI を使用した計測が行え、実際の並列計算に与える影響を反映したものである。

3.2 NPB³⁾

NPB(NAS Parallel BenchMark)は NASA Ames Research Center で開発された熱流体関連の科学技術計算ためのベンチマークである。様々なベンチマークプログラムが含まれており、より総合的な判断を行うことができる。計算結果とし

Performance evaluation of SMP Clusters with multilink Ethernet

Satoshi Kobayashi[†] Shan Axida[†] Tutomu Yoshinaga[†]

[†] Graduate School of Information System, The University of Electro-Communications

て得られる Mop/s (Mega Operation per second) 値は EP と IS を除き、ほぼ MFlop/s と同値である。EP と IS での値は乱数発生数と整数の数である。

4. 実験

まず、スループット評価のため、OpenMPI の提供するマルチリンク通信で 1~4 リンクをトランкиングした際の、メッセージサイズを変化させた場合の通信性能の変化を NetPIPE を用いて測定した。次に、NBPver3.3 を用いて問題クラス A, B, C について OpenMPI の提供するマルチリンク通信を行った場合(1~4 リンク/ノード)、及び 4 リンク/ノードの設定でノード上の 4 つのプロセッサが使用するリンクを静的に割り当てた場合(static と呼ぶ)の実験を行った。

4.1 実験環境

表.1 に実験に使用した 2 組のクラスタを示す。

表 1. 測定環境

クラスタ 1	16 ノード
CPU	Intel Xeon 5160 3.00GHz
L2 キャッシュ	4MB
Memory	4GB / ノード
OS	CentOS 4.6
MPI	OpenMPI 1.2.7
コンパイラ	Intel compiler10.1.018
NIC	Gb Ethernet (PCI-X x2, PCI-E x2)

クラスタ 2	16 ノード
CPU	Intel Xeon 7030 2.8GHz
L2 キャッシュ	2MB
Memory	4GB / ノード
OS	Fedora Core 5
MPI	OpenMPI 1.2.4
コンパイラ	Intel compiler9.0
NIC	Gb Ethernet (PCI-E x4)

4.2 実験結果

図.1 にクラスタ 1 で測定した NETPIPE の測定結果を示す。リンク数増加によりバンド幅が向上している。1 リンクの最大スループット 894MB/s に対して、2 リンクで 198%、3 リンクで 221%、4 リンクで 235% の性能を示した。これより、一対一通信での性能では、1 リンクから 2 リンクにした時が最も通信性能が向上したこと

がわかる。




図1. リンク数によるスループットの測定(クラスタ1)

図2にネットワーク性能に強く依存する NPB ベンチマークコードのクラスタ1での測定結果を示す。

CGではクラスBにおいては、2リンクに増やすことにより性能が57%向上した。一方で3リンク、4リンクでは低下している。これは、コネクション確立やパケットの順序の入れ替わりによるコストが増加したためと考えられる。また、クラスCにおいては、3リンク、4リンクに増やした際も向上している。計算量が増加し、パケット処理の影響が減少したためと考えられる。

FTでは複素数型の大きな配列データを多く通信する。クラスBにおいては、リンク数を上げたことによるスループットの向上が効果的に働いたと考えられる。クラスCにおいては、スループットの向上よりも通信量が増えたことによるパケットの処理によるコストがかかっていることが考えられる。

MGではメッセージ長が非一様な通信が散発的に発生する。FT同様にリンク数の増加によってスループットの向上が効果的に働いている一方で、リンク数が増えるとコネクション確立やパケット処理のコストが増加していることが考えられる。

ISとFTでは、全ての問題サイズにおいて static が 4link よりも高い Mop/s を示している。どちらも MPI_Alltoall 通信をしており、プロセッサとネットワークが静的に接続されていることによってコストを下げることができたと考えられる。

SPとBTでは、クラスタ1とクラスタ2において異なる傾向がみられた。クラスタ2ではリンク数が増えると性能向上が見られたが、クラスタ1ではみられなかった。これは、L2キャッシュの大きさの違いによるものと考えられる。




図2. リンク数による NPB の測定(クラスタ1)

5. おわりに

本論文では、SMP クラスタにおいてリンク数を上げることによる効果を NetPIPE、NPB を用いて測定した。通信量・通信頻度の高い計算においてはリンク数を上げることにより性能を向上させることができた。一方で、コネクション確立やパケットの順序入れ替えなどのコストがリンク数を上げると共にかかり性能に影響を及ぼすことがわかった。

参考文献

- Richard L. Graham, Timothy S. Woodall, Jeffrey M. Squyers: "OpenMPI: A Flexible High Performance MPI", the 6th International Conference on Parallel Processing and Applied Mathematics, September 2005 pp228-239
- NetPIPE: <http://www.scl.ameslab.gov/netpipe/>
- NPB: <http://www.nas.nasa.gov/Resources/Sofware/npb.html>