筑波大学計算科学研究センター HPCサマーセミナー 「最適化2」(通信最適化)

建部修見
tatebe@cs.tsukuba.ac.jp
筑波大学システム情報系
計算科学研究センター

講義内容

- 基本通信性能
  - 1対1通信
  - 集団通信
- プロファイラ
- 通信最適化
  - 通信の削減
  - 通信遅延隠蔽
  - 通信ブロック
  - 負荷分散

基本通信性能

- 通信最適化のためには基本通信性能を押さえておくことが重要！
  - 各種通信パターンにおける通信性能の把握
  - 通信ブロッキングのブロックサイズの決定
  - ネットワーク性能と比較して、通信ライブラリ自体の性能改善

基本通信性能評価環境(1)

- 4クラスタノード
  - 2.6GHz Dualcore Opteron x 2 sockets (4 cores)
  - 4GB memory
  - Linux 2.6.18-1.2798.fc6
  - OpenMPI 1.1-7.fc6
- Gigabit Ethernetで接続
  - TCPでの理論ピーク性能は949Mbps(=113.1MB/sec)

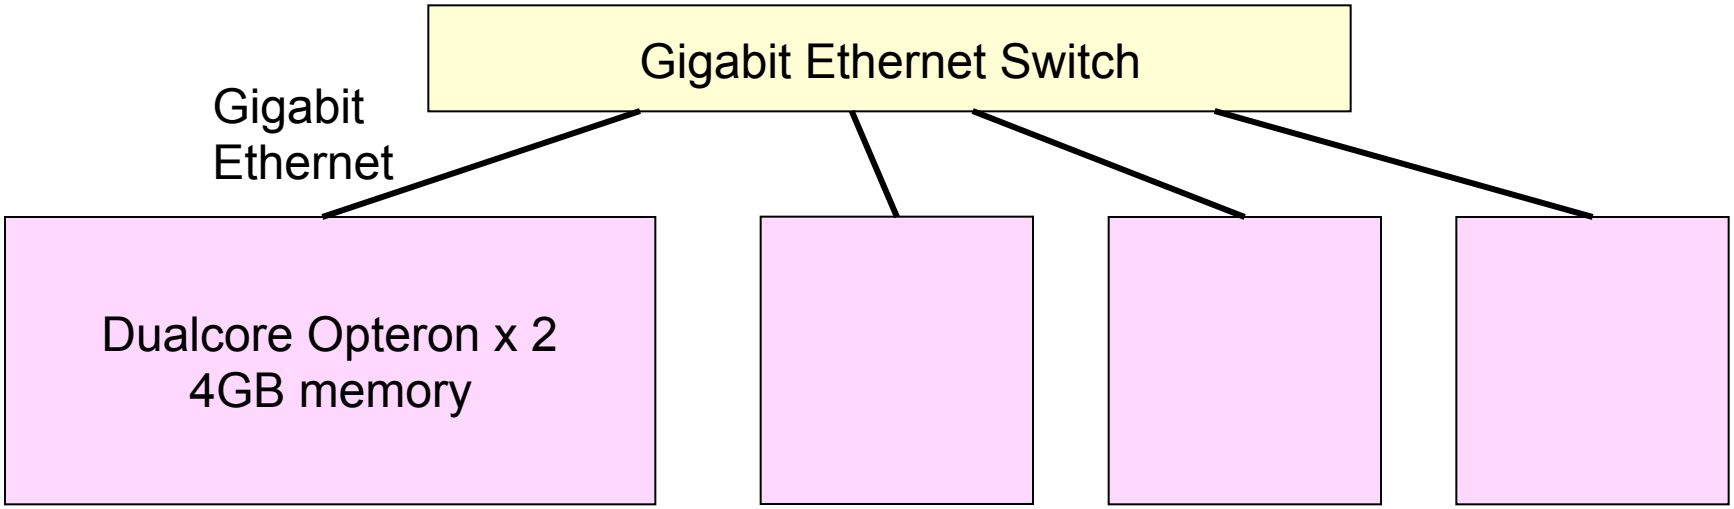

基本通信性能評価環境(2)

- T2K筑波4ノード
  - 2.3GHz Quadcore Opteron x 4 sockets (16 cores)
  - 32GB memory
  - MVAPICH2
- 4xDDR Infinibandで接続
  - 理論ピーク性能は8GB/sec (= 64Gbps)
- メモリ配置などの最適化は施さず

1対1通信の性能

- 1対1通信はMPIにおける基本通信

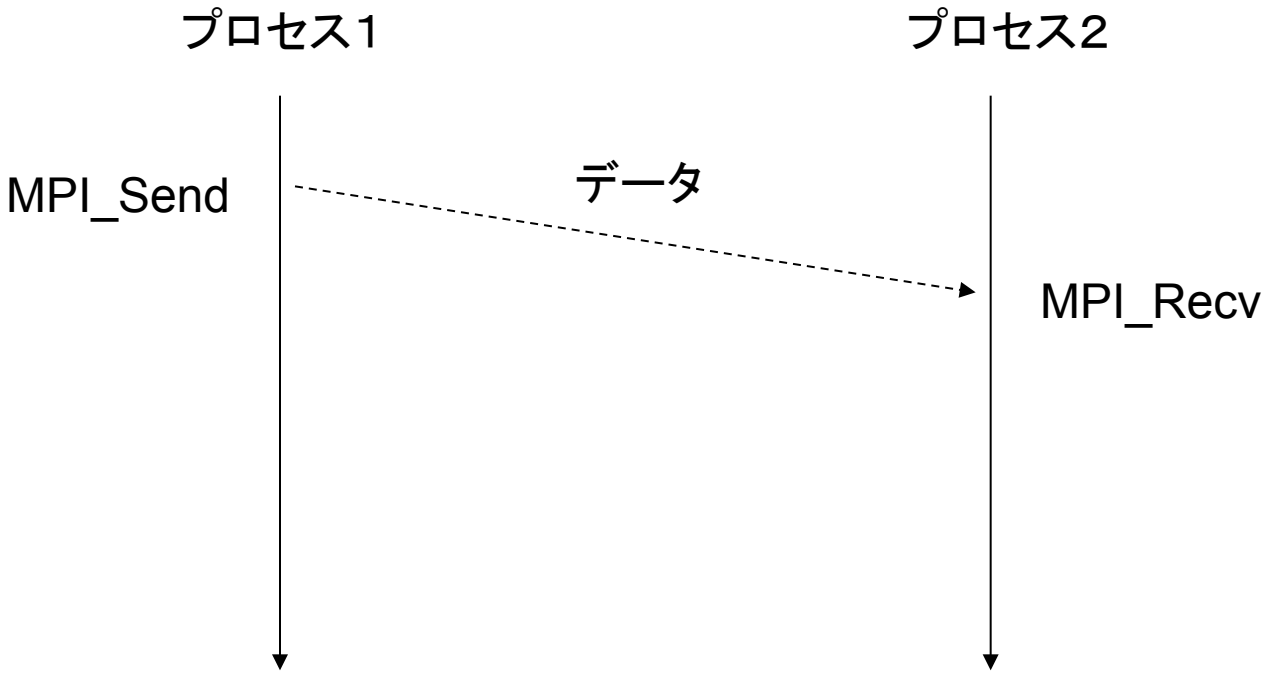

PingPongベンチマーク

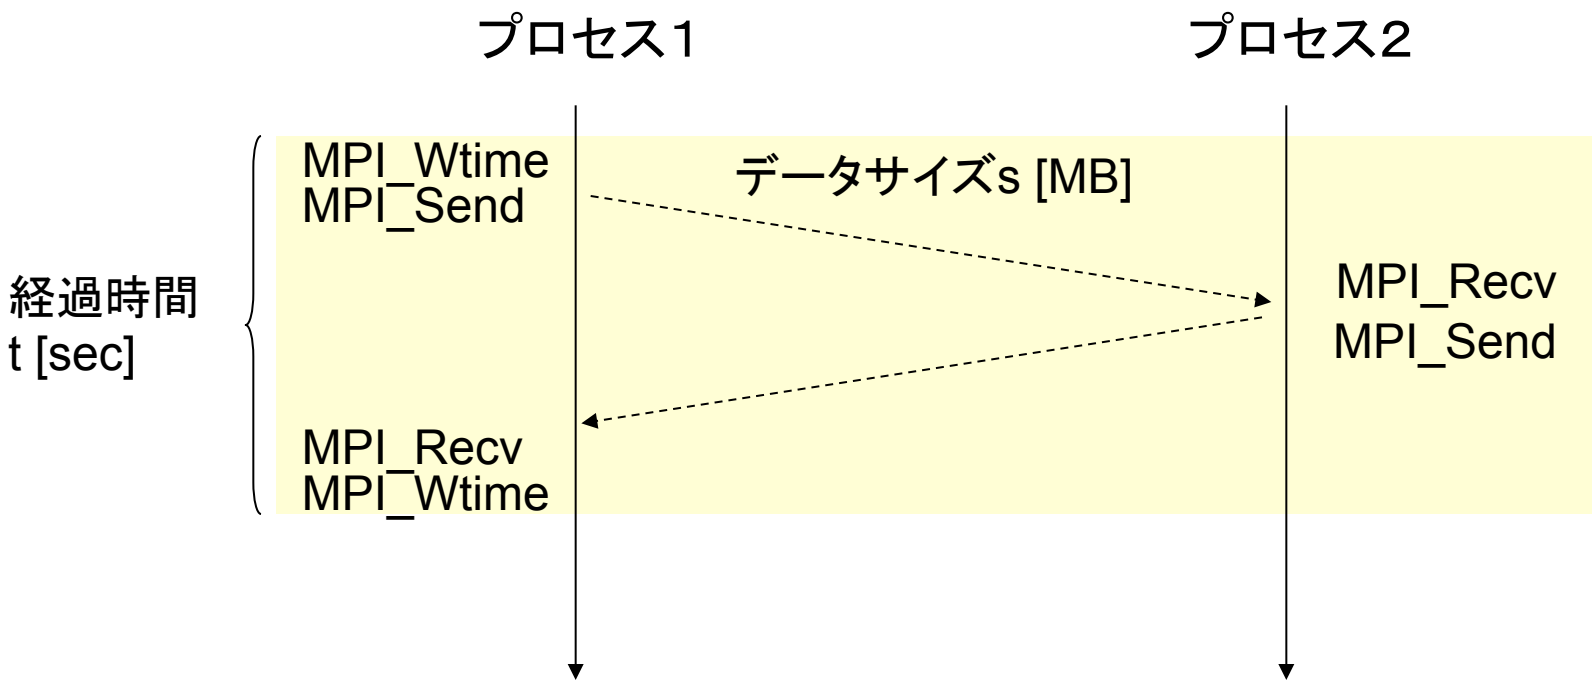

通信バンド幅 $s/t/2$ [MByte/sec]

PingPongベンチマークの例

```
for (s = 1; s <=P MAX_MSGSIZE; s <<= 1) {
    t = MPI_Wtime();
    for (i = 0; i < ITER; ++i)
        if (rank == 0) {
            MPI_Send(BUF, s, MPI_BYTE, 1, TAG1, COMM);
            MPI_Recv(BUF, s, MPI_BYTE, 1, TAG2, COMM, &status);
        } else if (rank == 1) {
            MPI_Recv(BUF, s, MPI_BYTE, 0, TAG1, COMM, &status);
            MPI_Send(BUF, s, MPI_BYTE, 0, TAG2, COMM);
        }
    t = (MPI_Wtime() – t) / 2 / ITER;
    if (rank == 0)
        printf(“%d %g %g\n”, s, t, s / t); // サイズ、時間、バンド幅
}
```

[環境1] PingPongベンチマーク

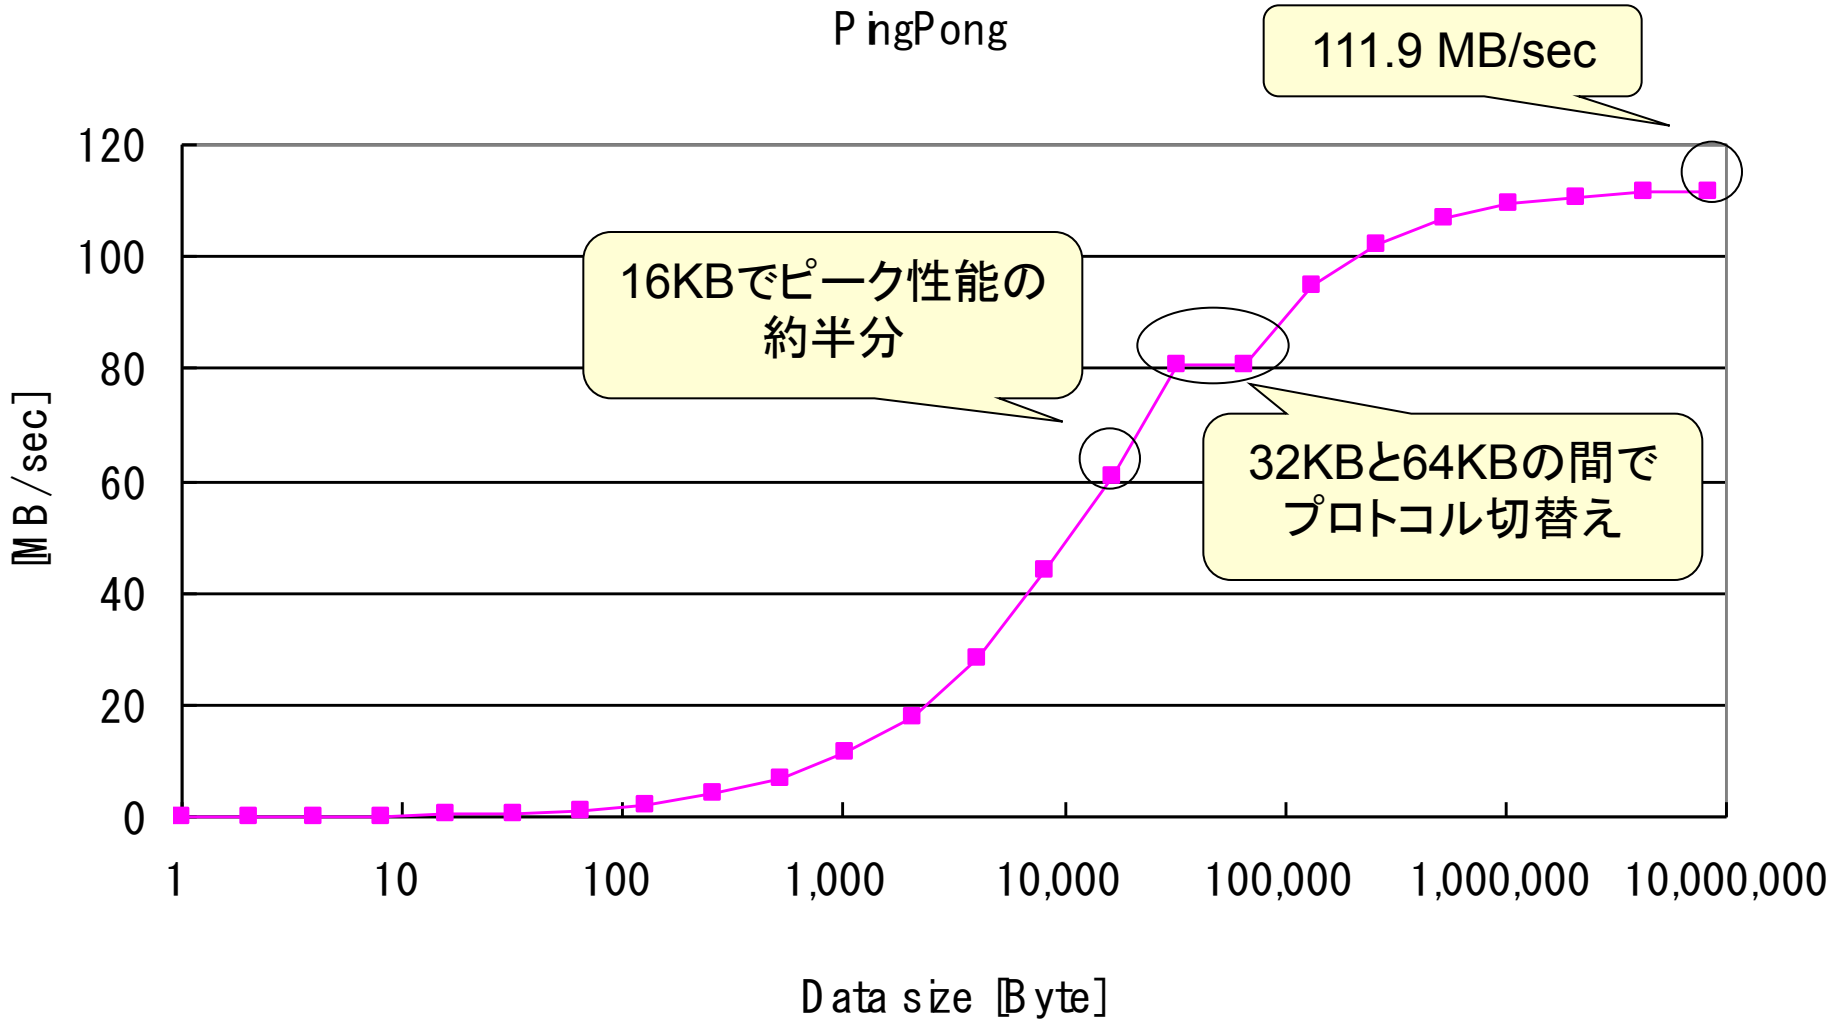

1対1通信プロトコル

- Eagerプロトコル（1-wayプロトコル）
  - 短メッセージ
  - メッセージヘッダとデータ（ペイロード）を同時に送信
  - 低遅延だが受信側でコピーのオーバヘッドが発生
- ランデブ（Rendezvous）プロトコル（3-wayプロトコル）
  - 長メッセージ
  - メッセージヘッダを送信し、完了通知を待ち、データを送信
  - 高バンド幅だがeagerプロトコルに比べ高遅延

1対1通信プロトコル（続き）

- MPI処理系は、メッセージ長によりプロトコルを選択
- メッセージ長を変えて計測することにより明らかに
- プロトコル切替のメッセージ長は、通信性能最適化のために指定可能なことが多い

[環境1] 遅延、バンド幅での曲線との比較

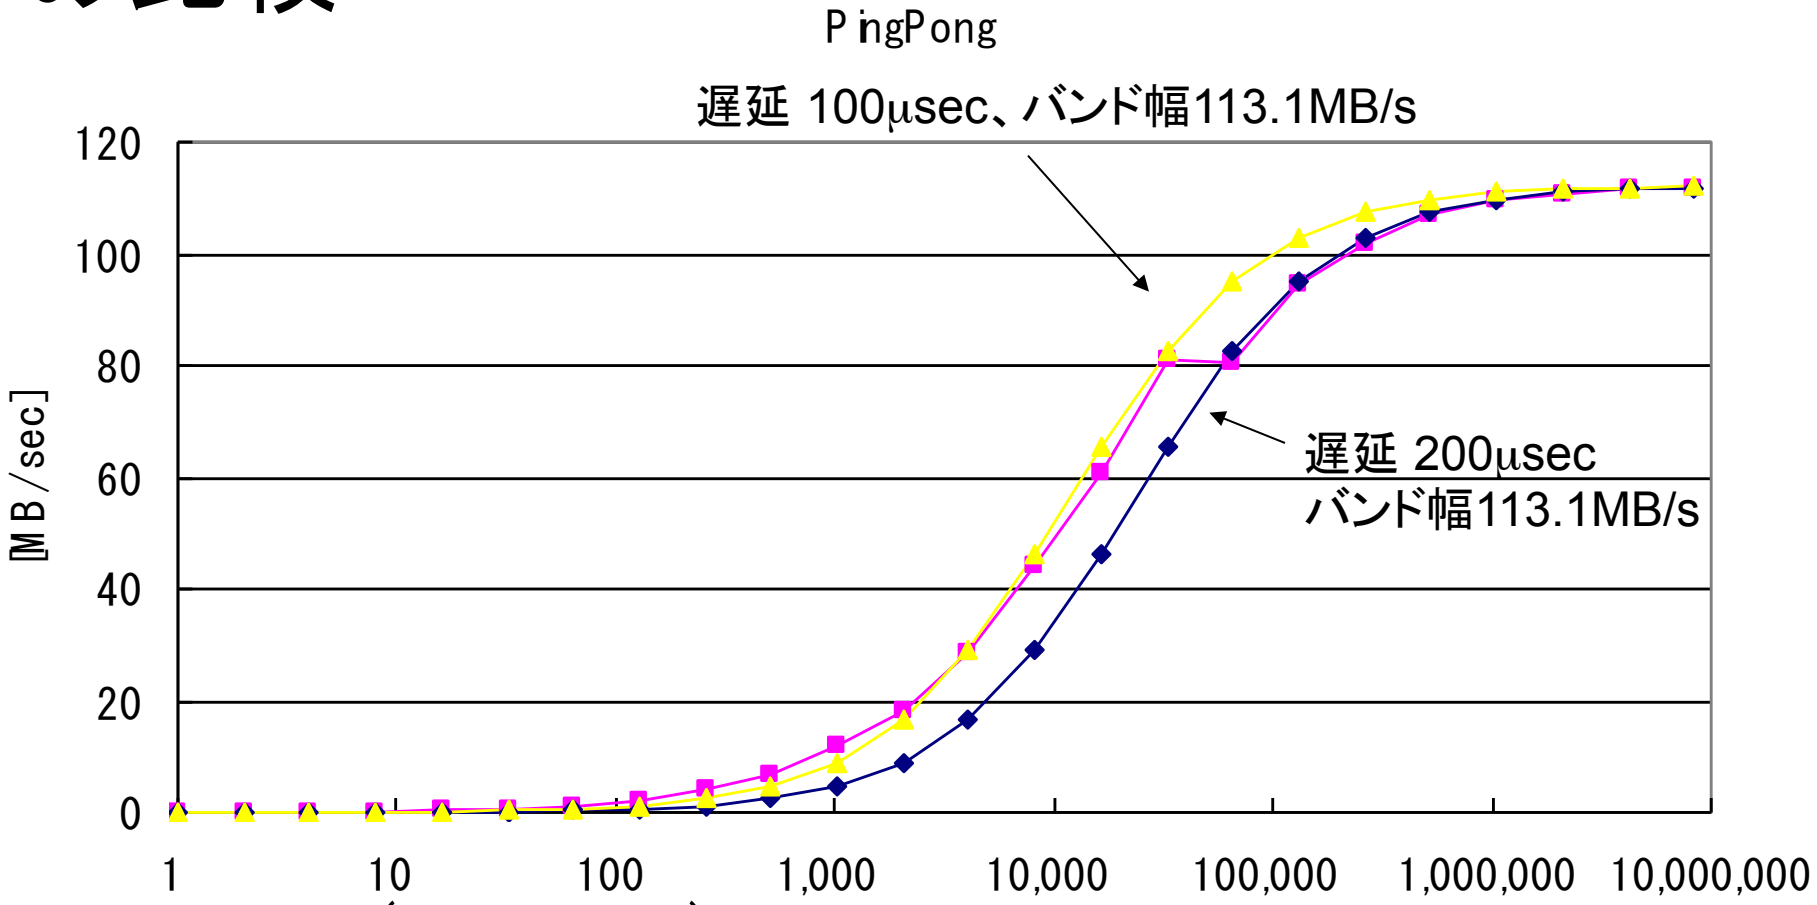

理論曲線 $s/(L+s/B)$

$N_{half} = BL$

L遅延時間　Bバンド幅

[環境1] PingPongベンチマークの考察

- データサイズは大きい方が高性能
- 参考：理論ピーク性能は113.1MB/sec
- ピークの半分以上→データサイズ16KB以上
- ピークの9割以上→データサイズ512KB以上

- 1バイトのPingPongベンチマークの遅延時間は563μsecであったが、ショートメッセージは100μsec、ロングメッセージは200μsecの遅延時間の曲線に従う

[環境2] PingPongベンチマーク

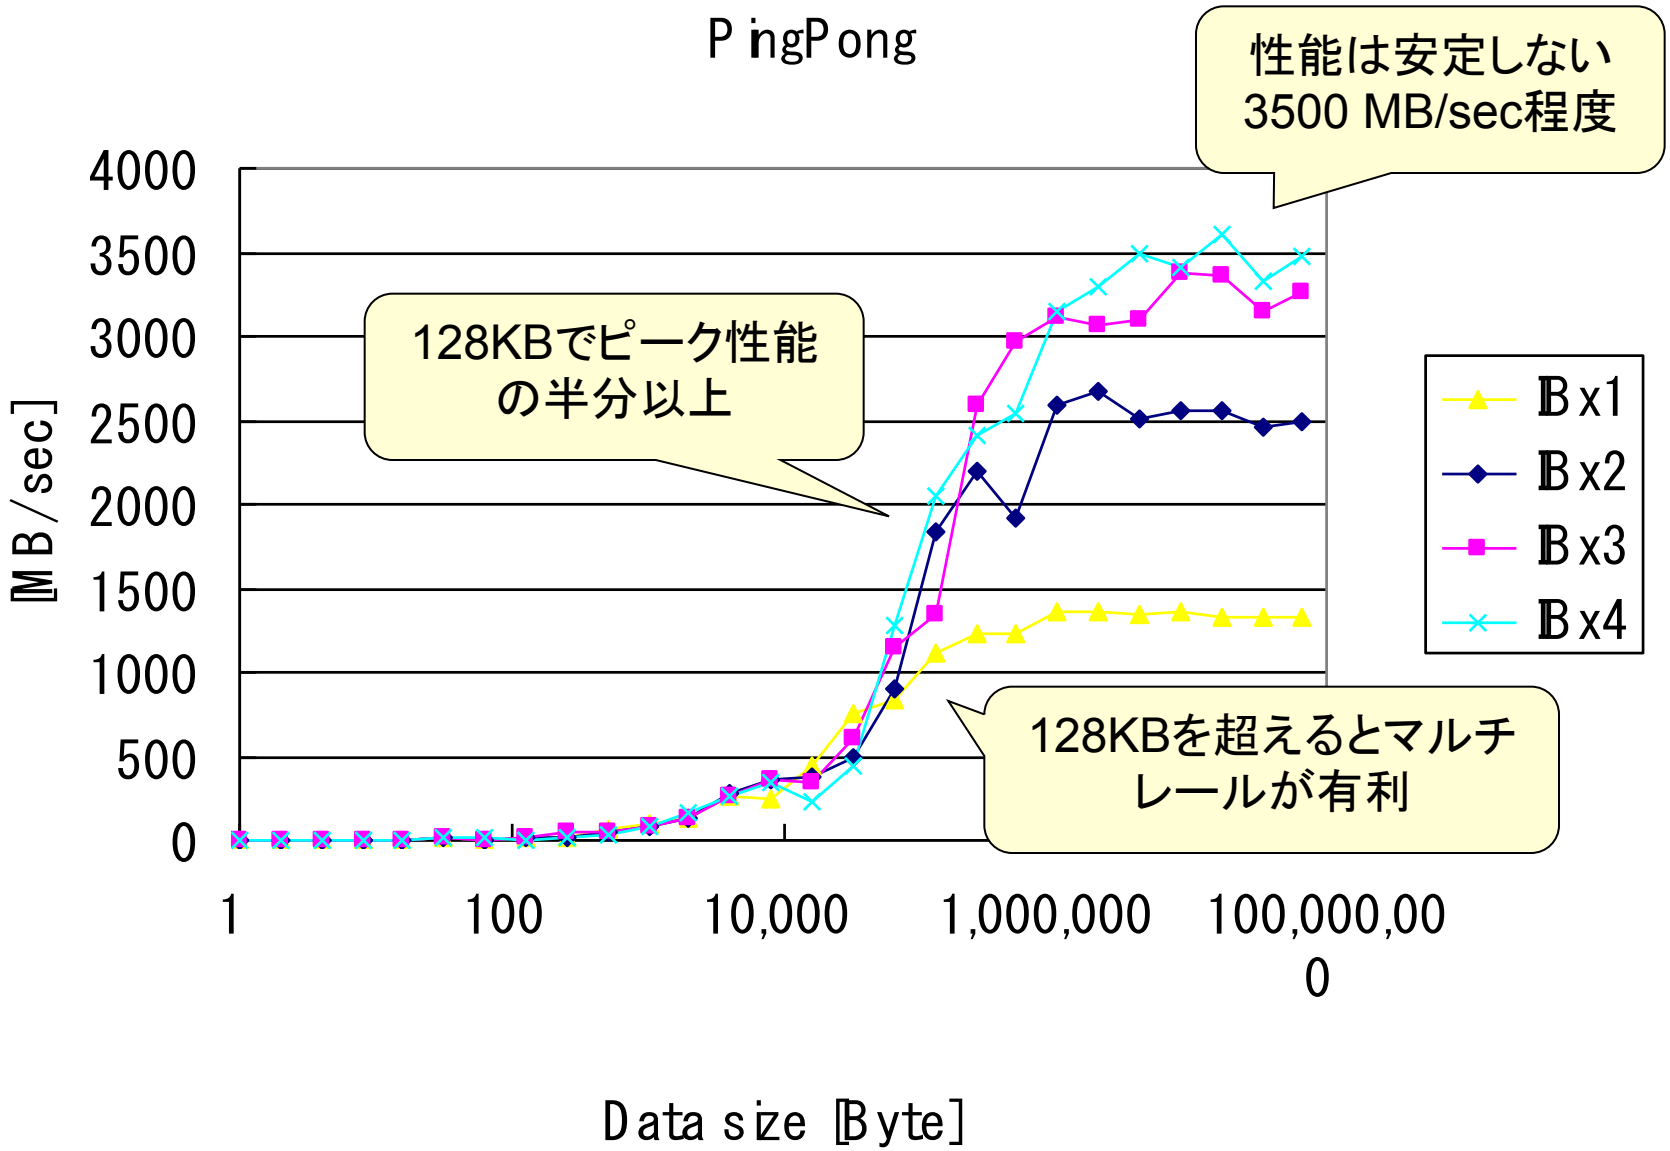

[環境2] 遅延、バンド幅での曲線との比較

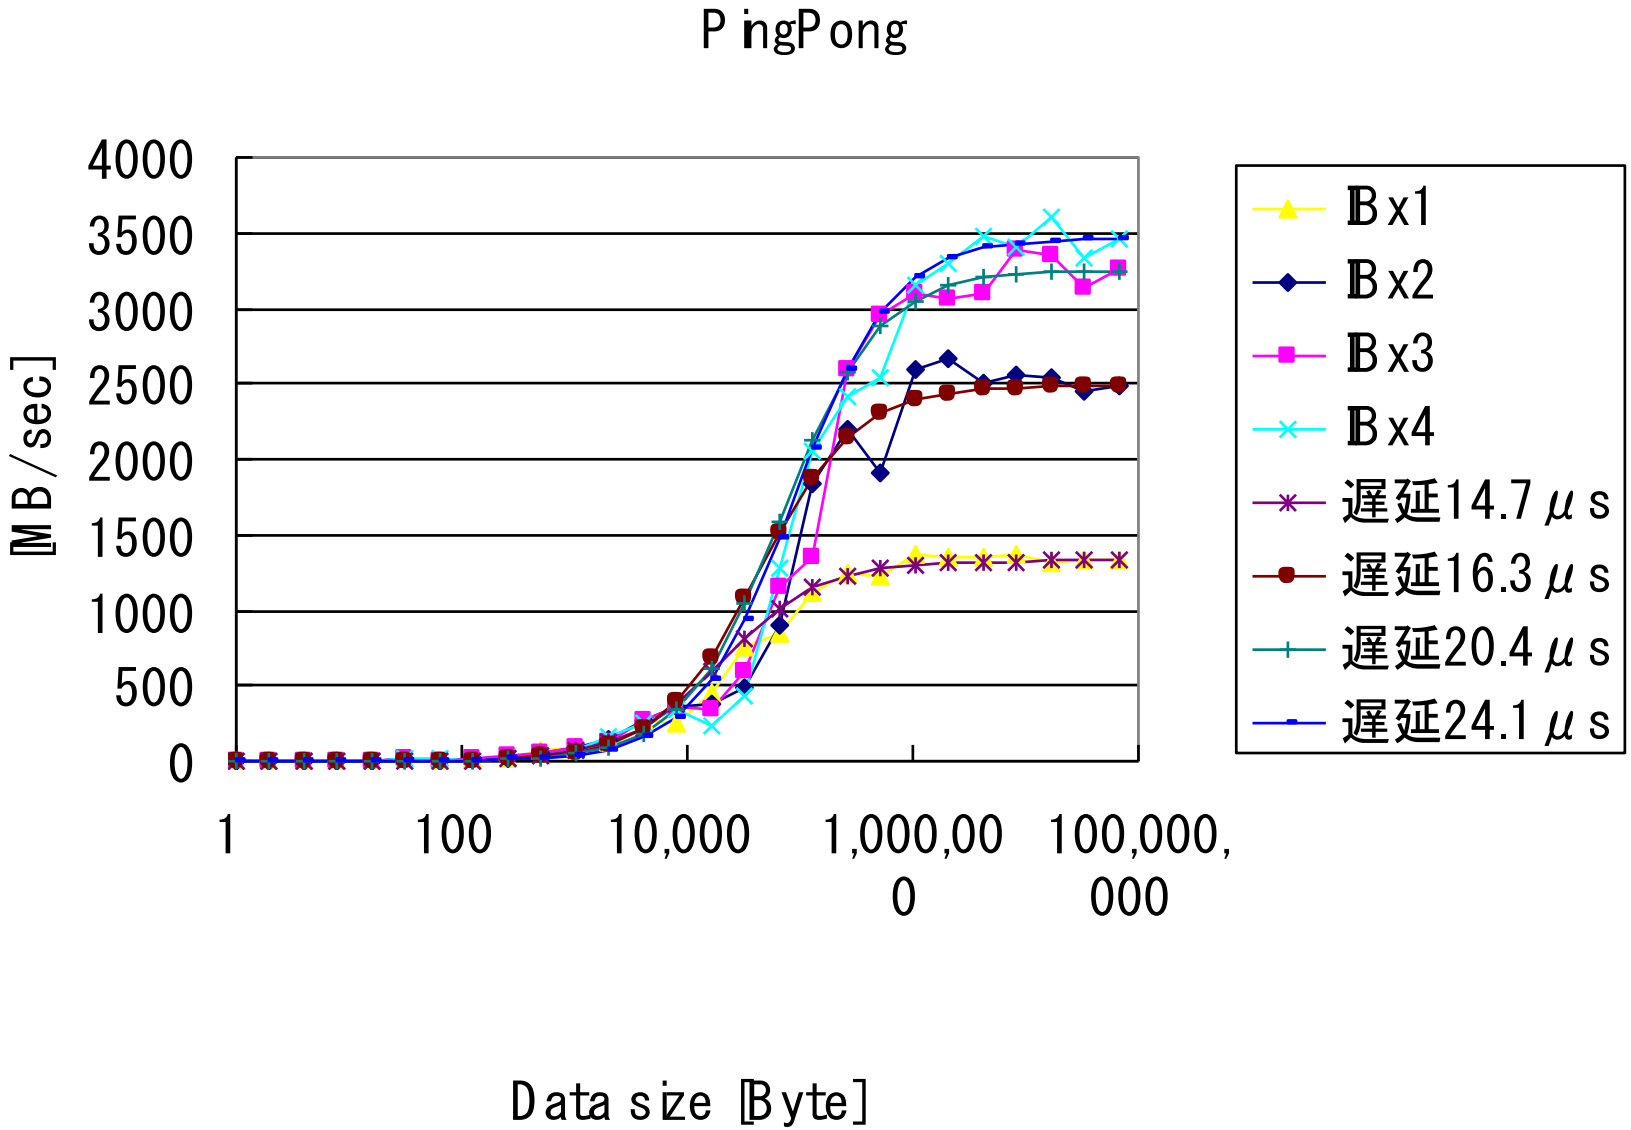

[環境2] PingPongベンチマークの考察

- データサイズは大きい方が高性能

IBの数	1	2	3	4
バンド幅[MB/s]	1366	2674	3256	3468
遅延[μ秒]	14.7	16.3	20.4	24.1
N_{half}[KB]	20	42	68	86

- ショートメッセージとロングメッセージで遅延は変わらない

Intel® MPI Benchmark

- 基本MPIベンチマークカーネル
- MPI1
  - PingPong — **Single Transfer**
  - PingPing — **Single Transfer**
  - Sendrecv — **Parallel Transfer**
  - Exchange* — **Parallel Transfer**
  - Bcast — **Collective**
  - Allgather — **Collective**
  - Allgatherv — **Collective**
  - Alltoall* — **Collective**
  - Alltoallv* — **Collective**
  - Reduce — **Collective**
  - Reduce_scatter — **Collective**
  - Allreduce* — **Collective**
  - Barrier — **Collective**
  - 上記を複数一斉に行うMulti版
- EXT
  - Window
  - Unidir_Put
  - Unidir_Get
  - Bidir_Get
  - Bidir_Put
  - Accumulate
- IO
  - S_{Write,Read}_{indv,expl}
  - P_{Write,Read}_{indv,expl,shared,priv}
  - C_{Write,Read}_{indv,expl,shared}

Exchangeパターン

- 境界の要素を交換する通信パターン

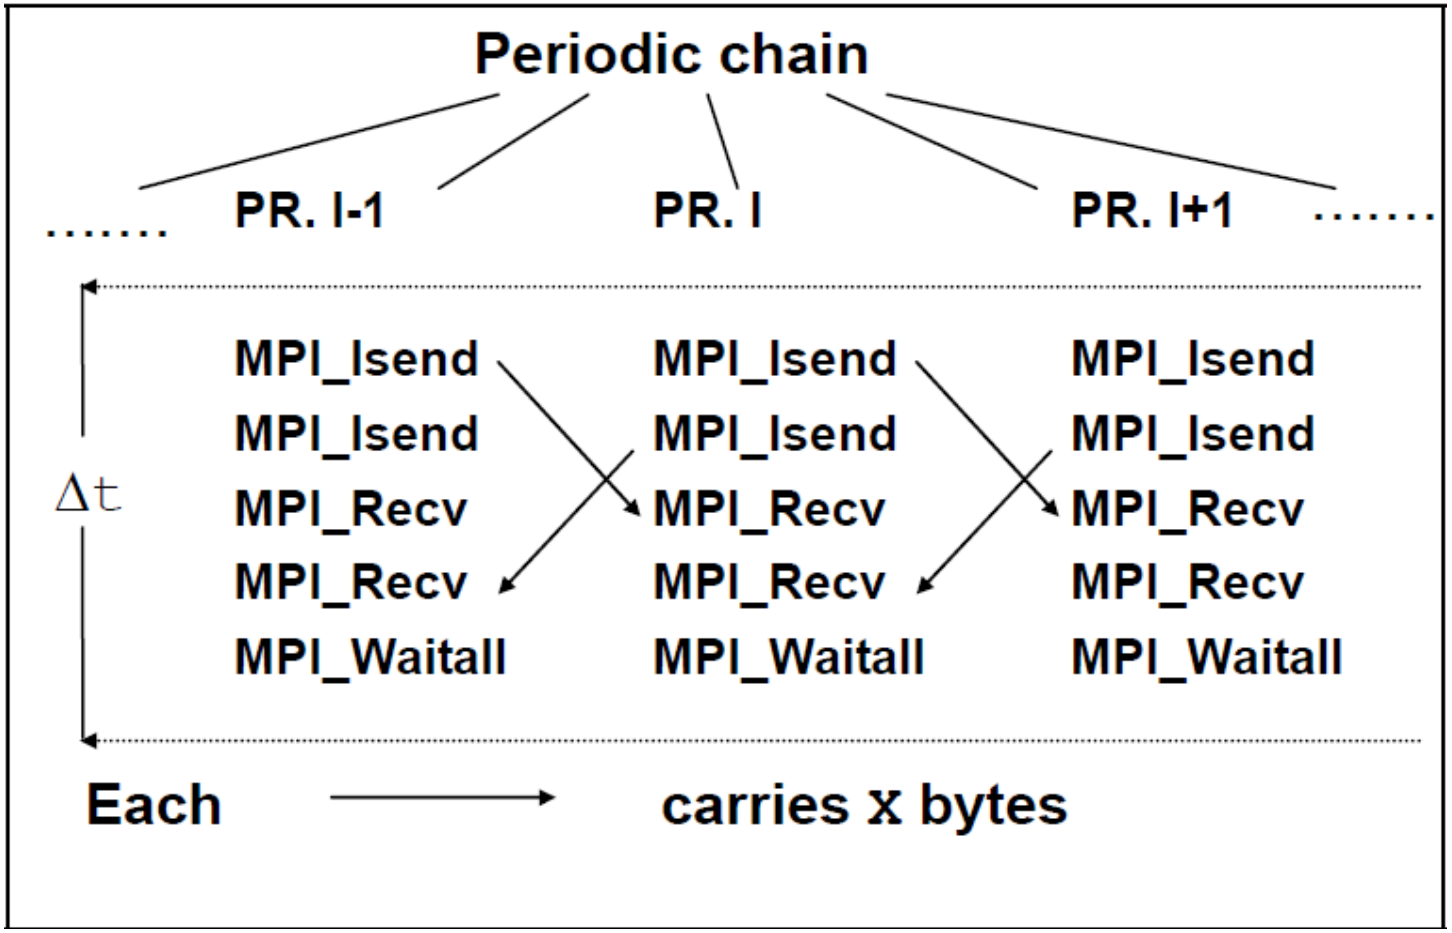

*Intel MPI Benchmarks Users Guide and Methodology Descriptionより

[環境1] Exchange（4ノード）[試行3回]

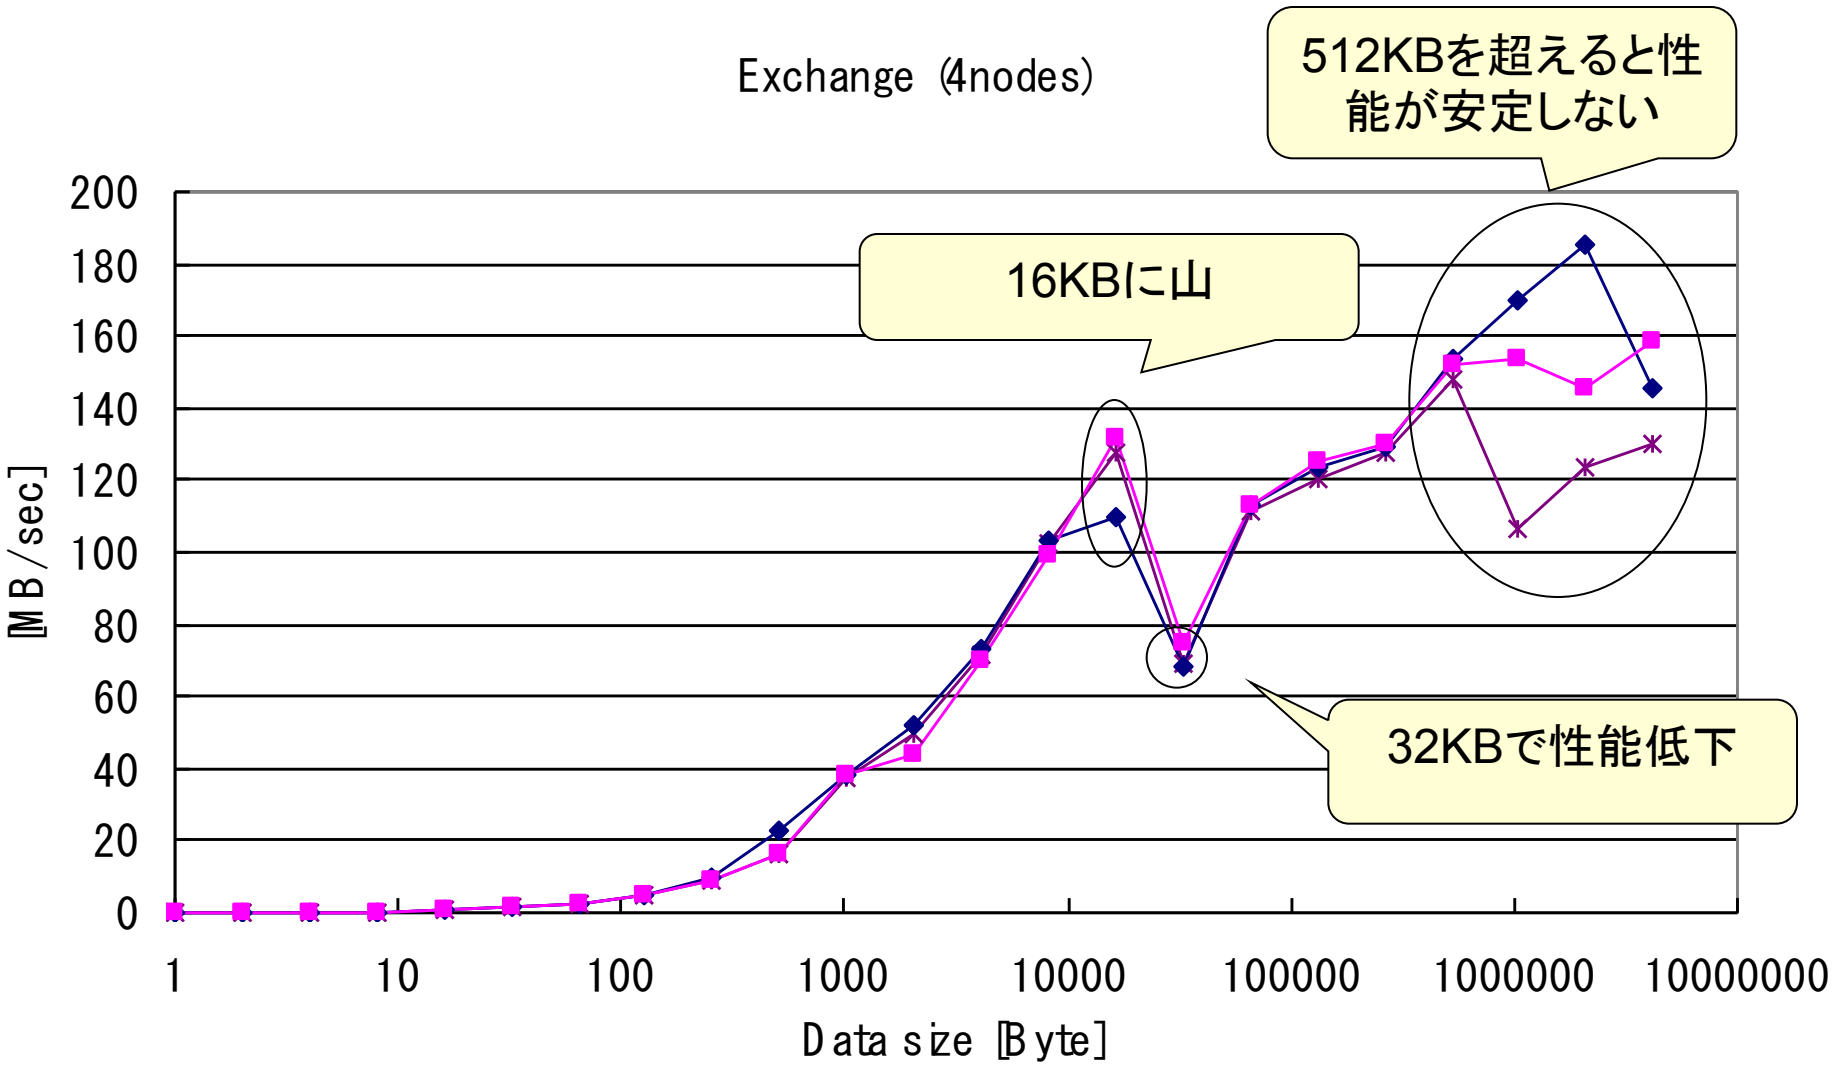

[環境1] Exchange(4ノード)の考察

- データサイズは基本的には大きい方が高性能だが、32KB付近で落ちる
- 参考:理論ピーク性能は2*113.1=226.2MB/sec
- ピークの半分以上→データサイズ16KBと128KB以上
  - 32KB、64KBはピークの半分以下
- 512KB超では性能が安定しない

[環境2] Exchange（4ノード）

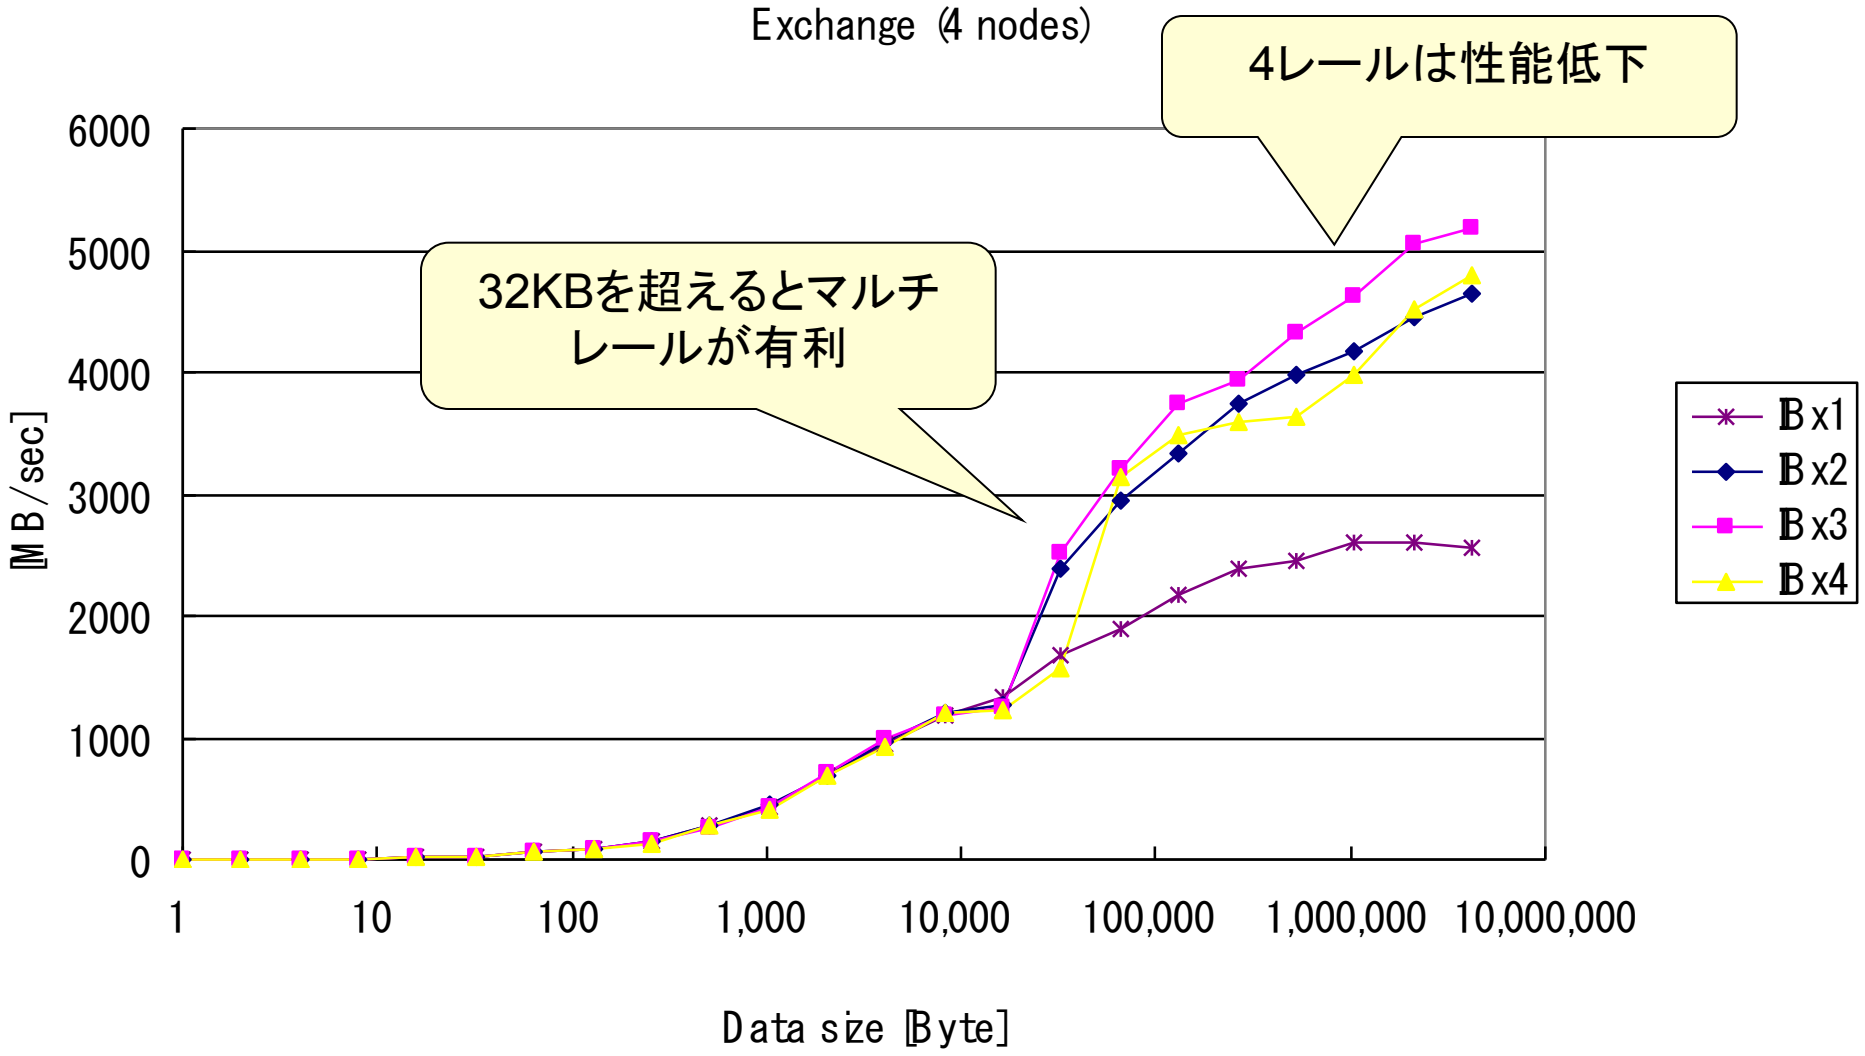

[環境2] Exchangeの考察

- データサイズは基本的には大きい方が高性能
- 32KBを超えるとマルチレールが有利
- 4レールでは性能低下
- 性能は安定している（IBなのでパケットが落ちないことが影響？）

Allreduce

- 各プロセスの配列間で指定された演算（加算、AND/OR演算など）を施し結果は全プロセスで保持
- MPI_SUMの例

$$x_1 + x_2 + x_3 + x_4 = \sum_{i=1}^{4} x_i$$

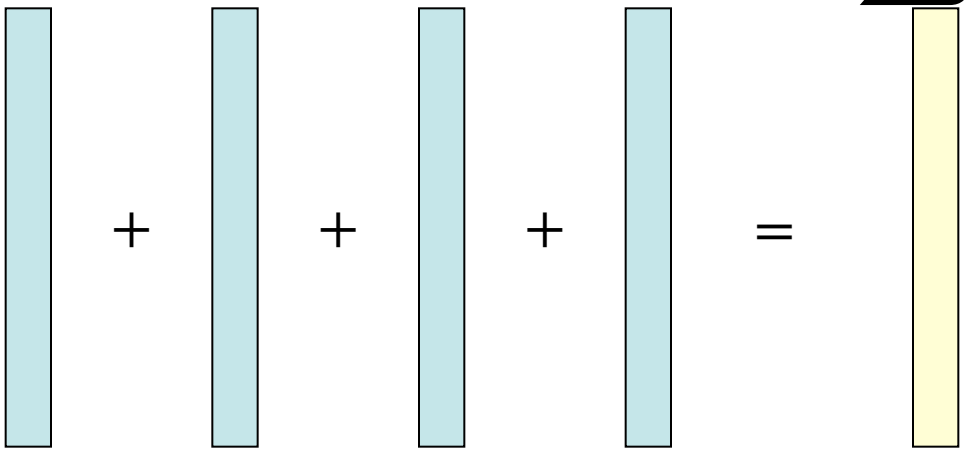

プロセス1の配列　プロセス2の配列　プロセス3の配列　プロセス4の配列　計算結果を全プロセスで保持

[環境1] Allreduce（4ノード）
[サイズ/時間]

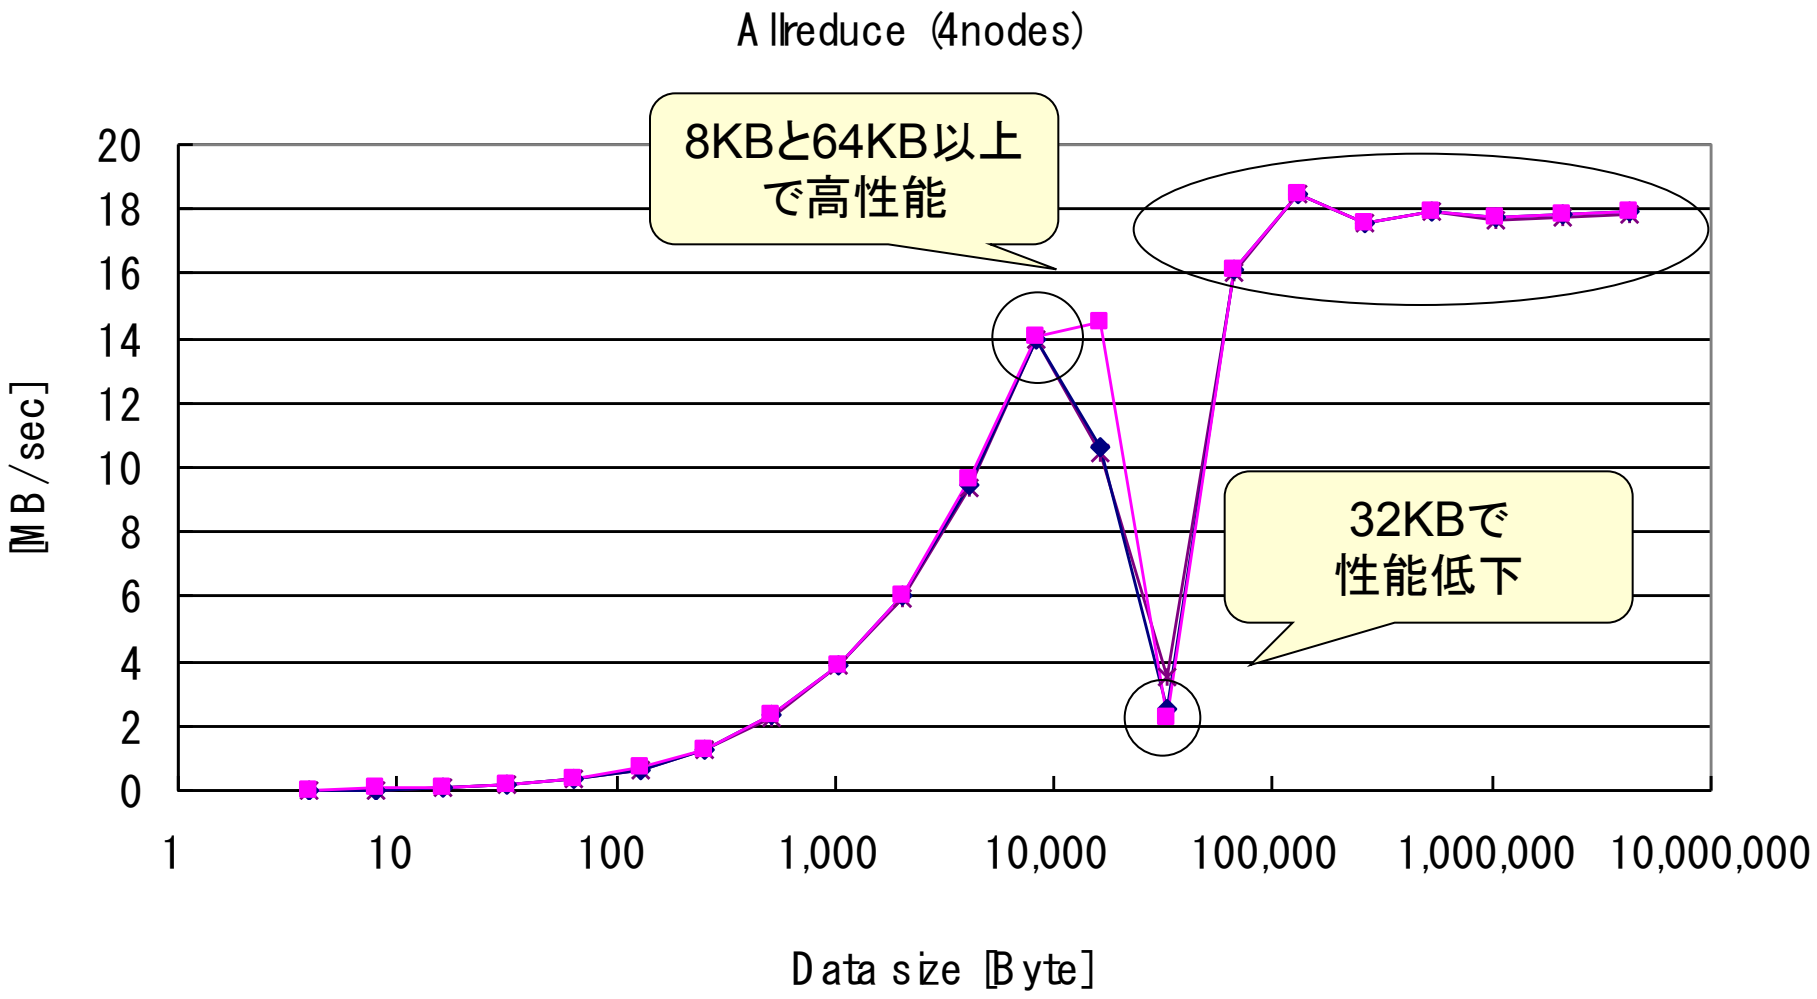

[環境1] Allreduceの考察

- データサイズは基本的には大きい方が高性能だが、32KBで性能低下
- 8KB、64KB以上では高性能

[環境2] Allreduce（4ノード）
[サイズ/時間]

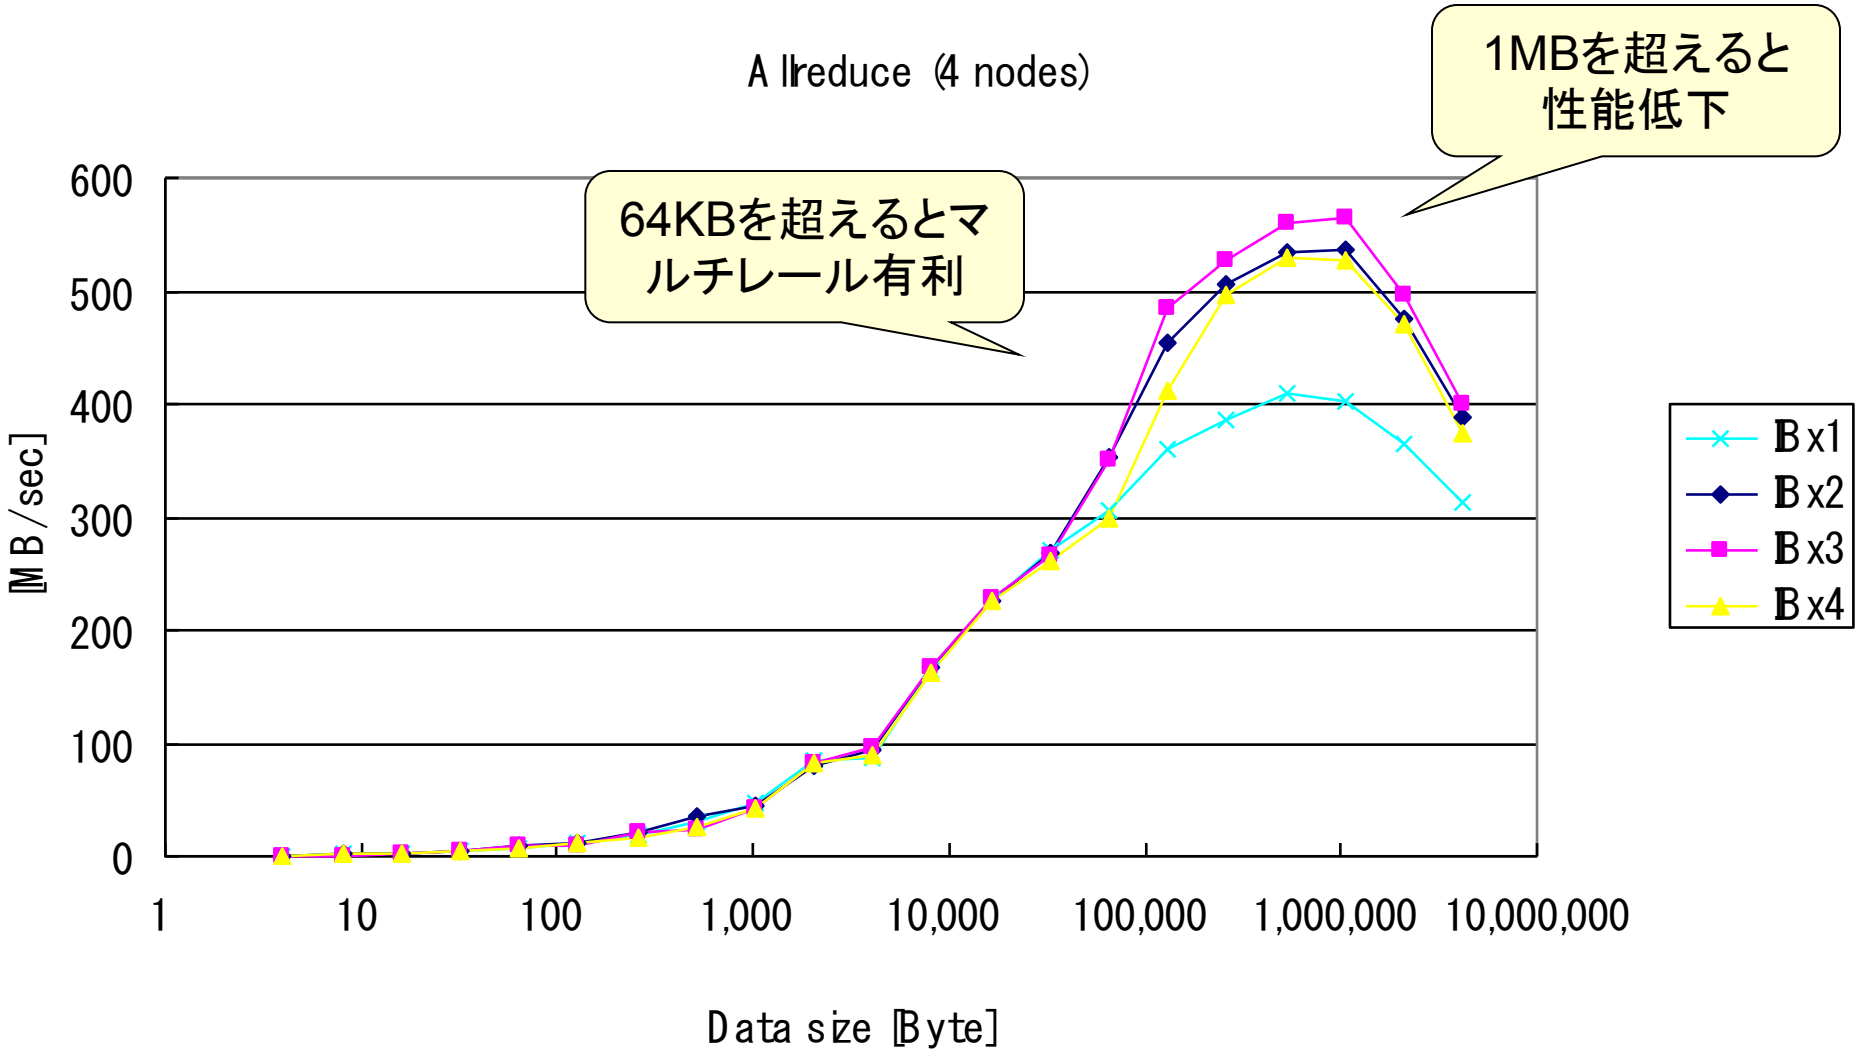

[環境2] Allreduceの考察

- データサイズは基本的には大きい方が高性能だが、1MBを超えると性能低下
- 64KBを超えるとマルチレールが有利
- 4レールは性能低下

Alltoall

- 行列の転置に相当する集団通信

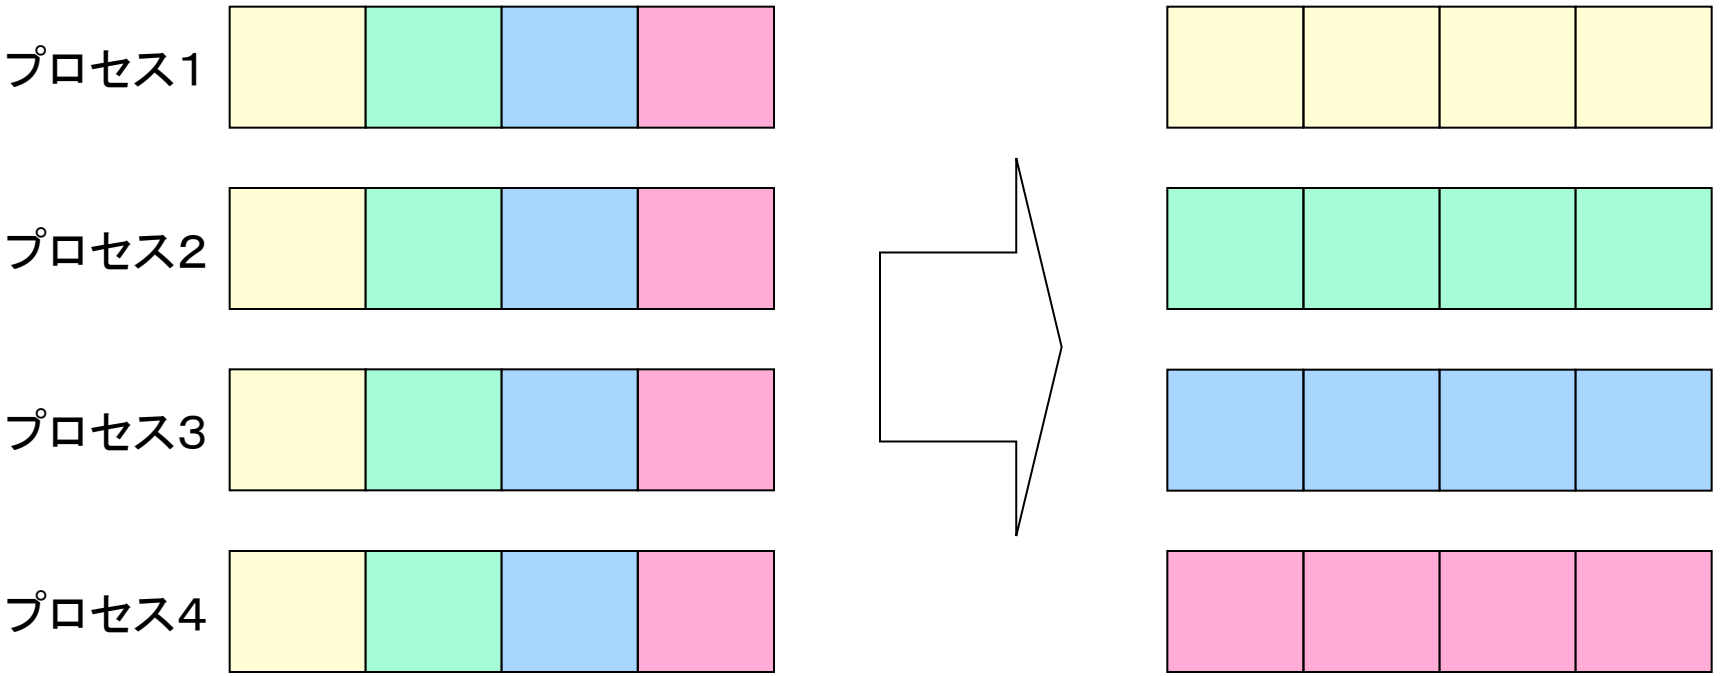

[環境1] Alltoall [サイズ/時間]

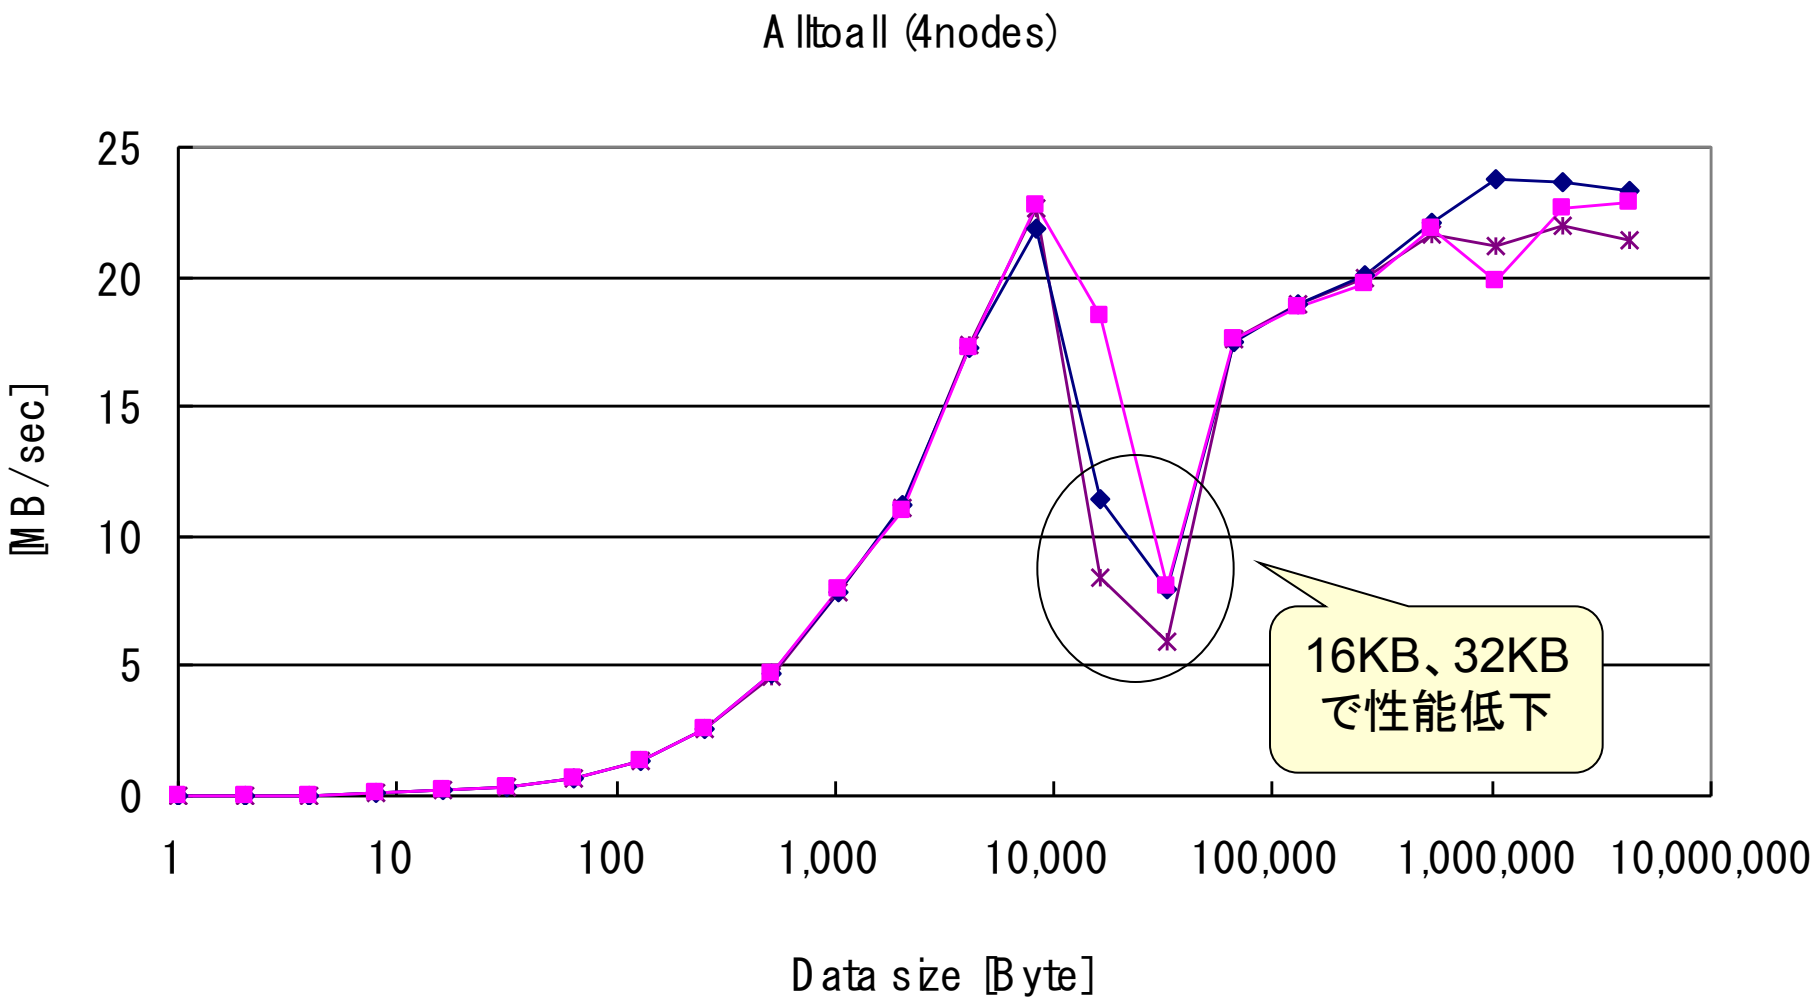

[環境1] Alltoallv [サイズ/時間]

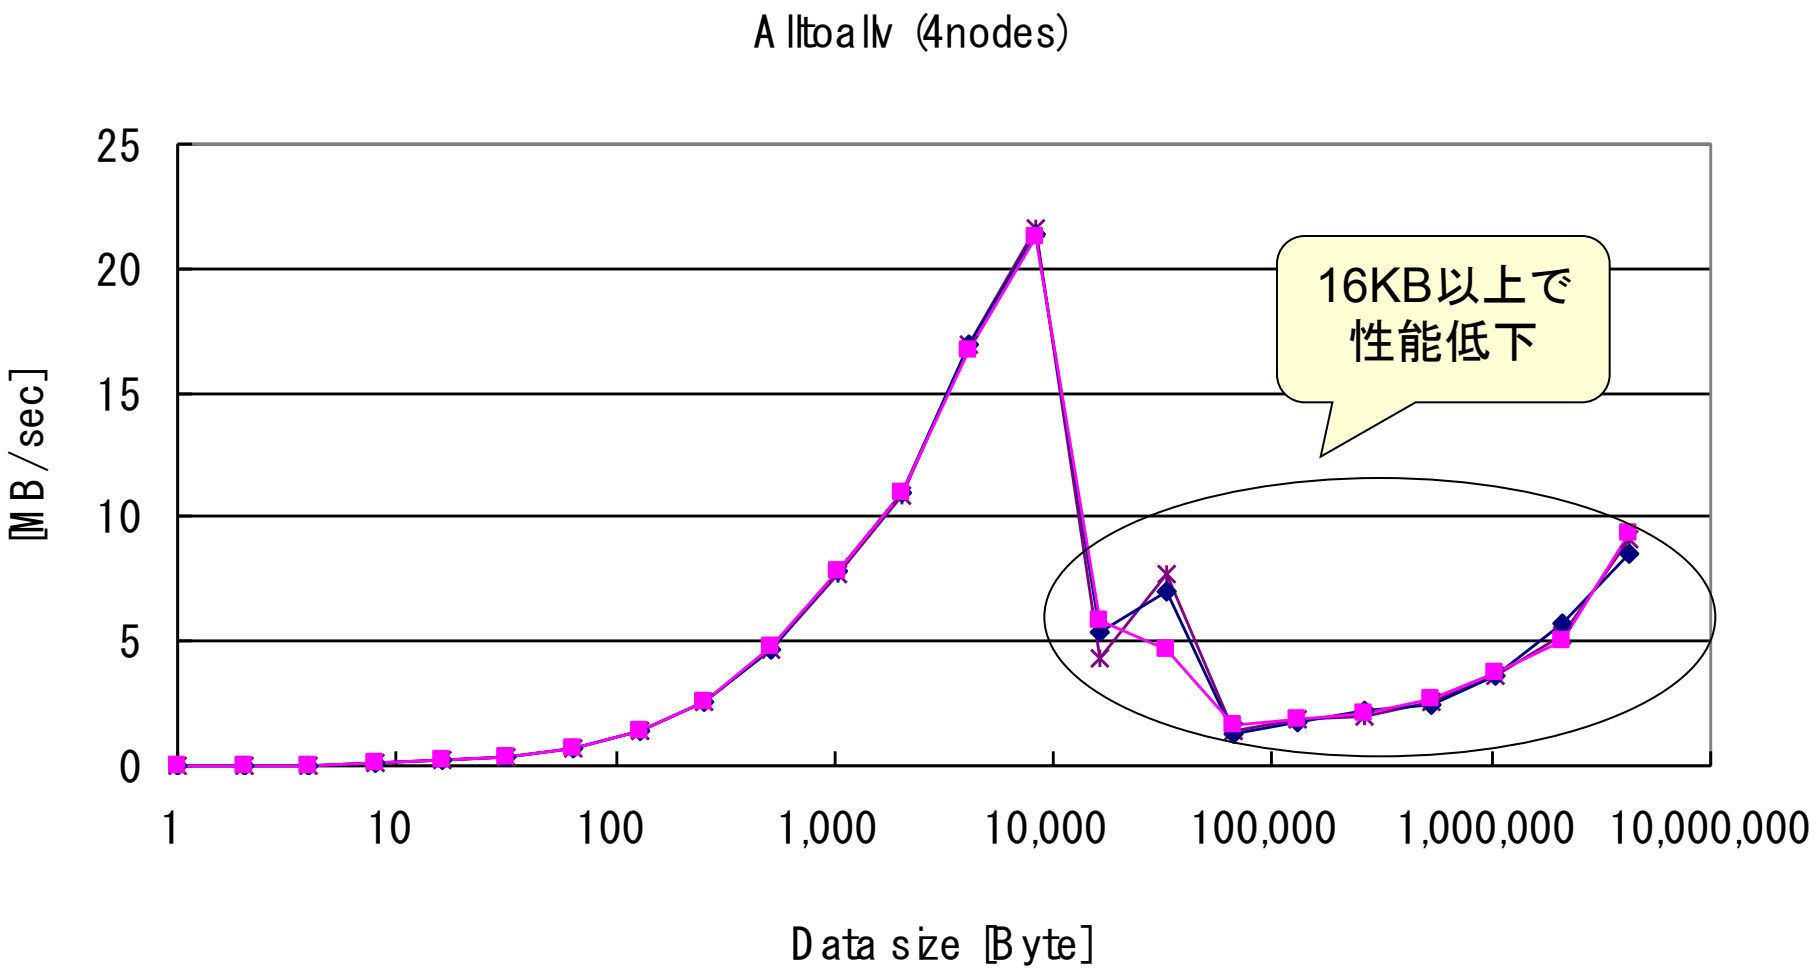

[環境1] Alltoall(v)の考察

- Alltoallは、データサイズは基本的には大きい方が高性能だが、16KB～32KBで性能低下
  - 8KB、64KB以上では高性能
  - Allreduceと同様
- Alltoallvは、16KBを超えると極端に性能低下
  - 不必要なメモリコピーのためと思われる
  - 性能最適化がなされていない

[環境2] Alltoall [サイズ/時間]

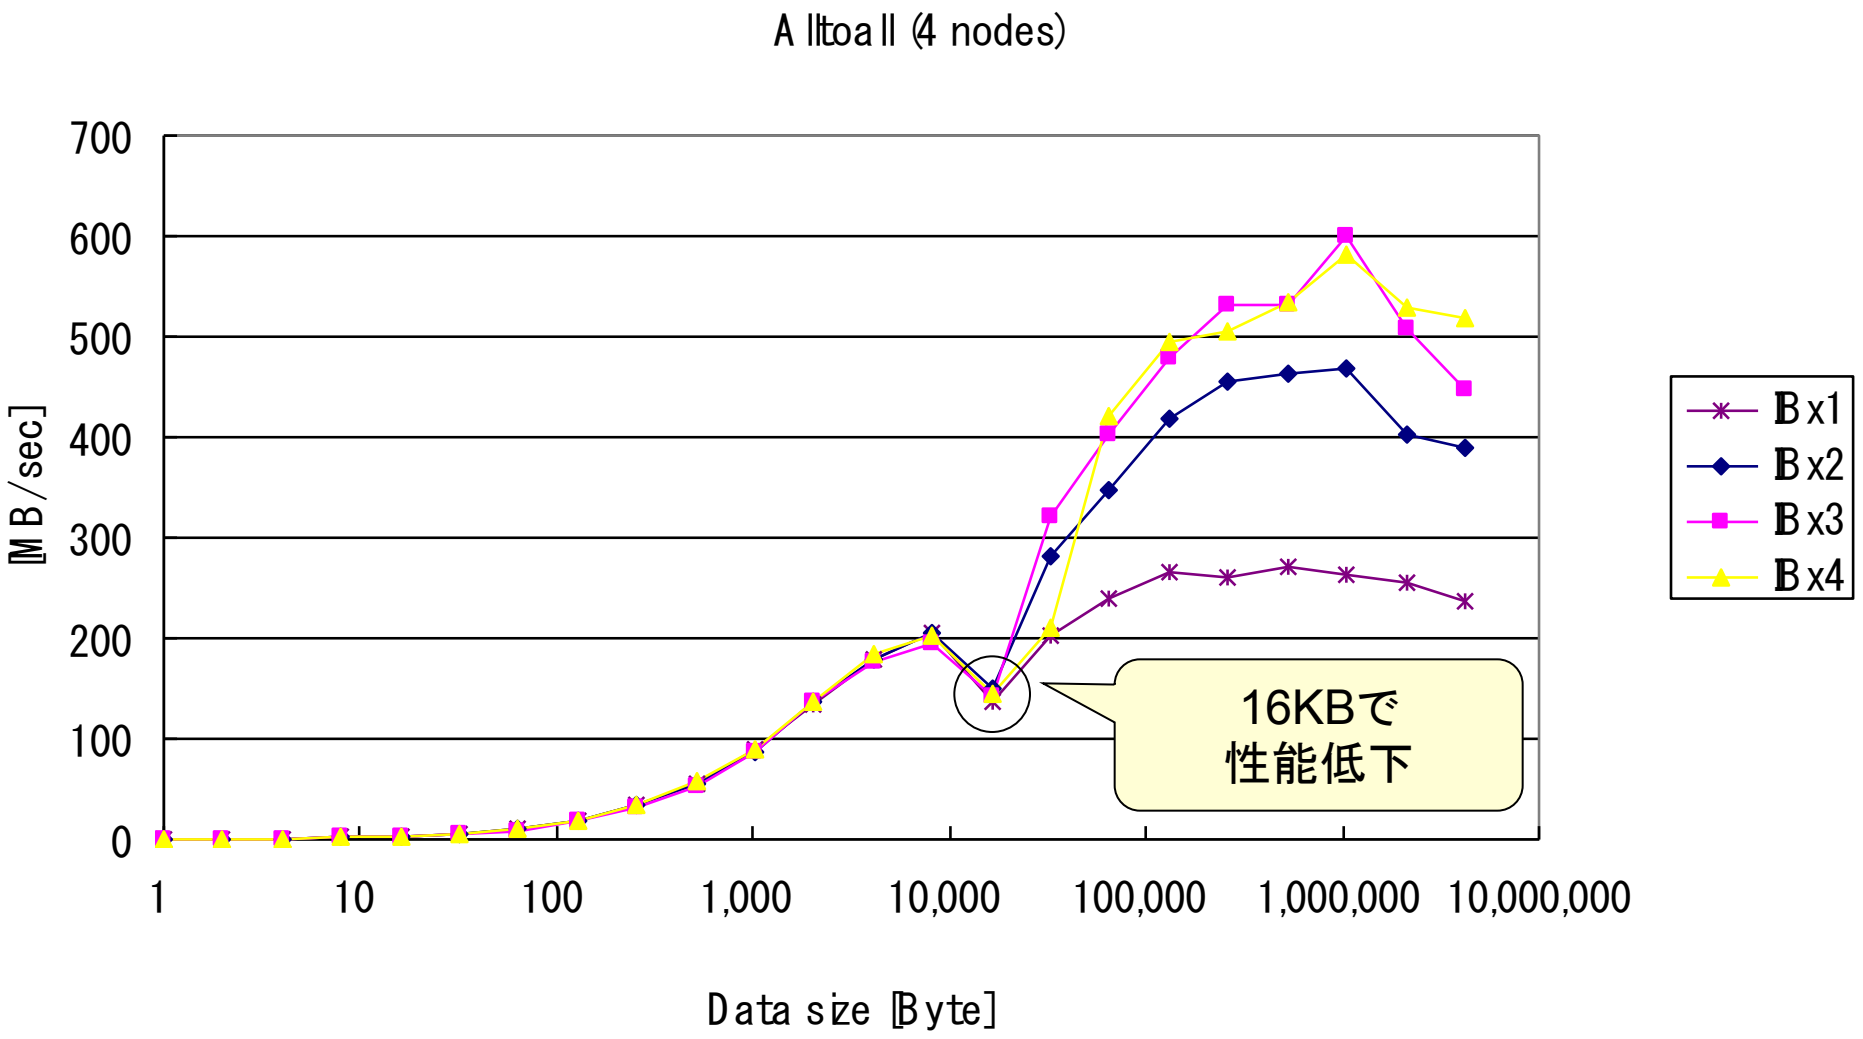

[環境2] Alltoallv [サイズ/時間]

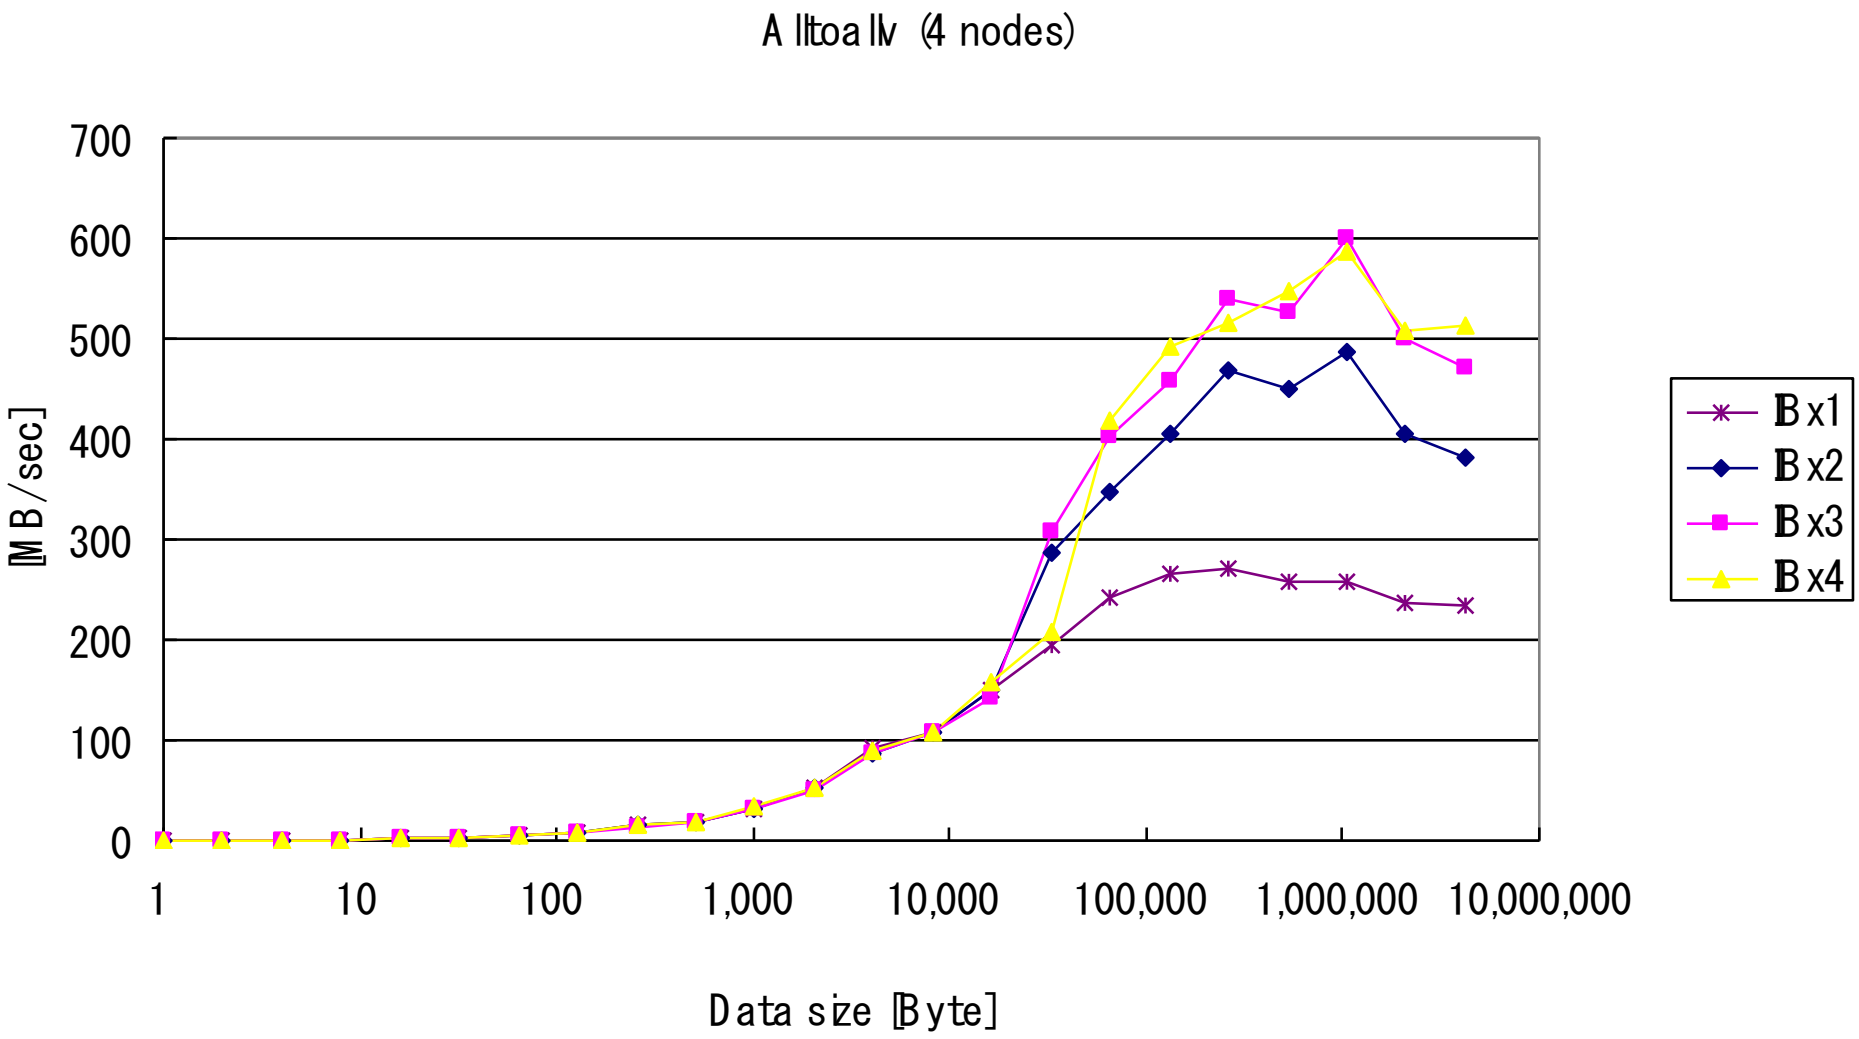

[環境2] Alltoall(v)の考察

- Alltoall, Alltoallvは、データサイズは基本的には大きい方が高性能
- Alltoallは16KBで性能低下
- 32KBを超えるとマルチレールが有利

マルチレールについて

- マルチレール(ボンディング)はバンド幅を向上させるが、遅延は短くならない
- メッセージ長が長いと有効となる
- マルチレールの数が多くなると効率は下がる
- マルチレールの使い方はいくつかあり、4レールの場合以下の方法がある
  - 4レールを束ね1チャンネルで利用
  - 2レールを束ね2チャンネルで利用
  - 4チャンネルで利用
- 多くのMPI処理系は束ねるレール数を指定可能
- 全てのケースで有効な方法はなく、有効な使い方はアプリケーションの通信パターンによる

プロファイラ

- プログラムの挙動を把握する
  - 呼び出し回数の多い関数
  - 処理に時間がかかっている関数
  - 関数の呼び出し関係
  - 関数のメモリ使用量など
- 実行時間の多くが費やされているコードの特定
- 並列プログラムにおける同期待ち、負荷不均衡の把握
  - プログラムの実行に影響しないことが望ましい
  - 軽量のプロファイラが必須

計時コード挿入によるプロファイリング

- 計時したい箇所（MPI関数、特定ブロック）に計時コードを挿入

```
double t;

t = MPI_Wtime();
MPI_Allgather(....);
t = MPI_Wtime() – t;
```

- 時間精度はシステム依存

tlog – time log

- 実行プロファイルをとるための軽量ライブラリ（佐藤センター長@筑波大）
  - 1イベントあたり16バイト
  - 各プロセスのメモリに保持
- 単発イベント、区間イベント各９種類のログ
  - イベント番号は8ビットなので拡張可能
- tlog_initializeからの経過時間（秒）を記録
  - tlog_initializeでノード間の時刻差を測定し補正
  - 並列プロセスにおける「絶対」相対時間
- 暫定ダウンロードURL
  - http://www.ccs.tsukuba.ac.jp/workshop/HPCseminar/2011/software/tlog-0.9.tar.gz

tlog - 主要API

void tlog_initialize(void)
　初期化。MPI_Initの後で呼ぶこと
void tlog_log(int event)
　eventで指定されたイベントを記録する
void tlog_finalize(void)
　ログをtrace.logに出力。MPI_Finalize()の前に呼ぶこと

```
tlog_initialize();
…
tlog_log(TLOG_EVENT_1_IN);
/* EVENT 1 */
tlog_log(TLOG_EVENT_1_OUT);
…
tlog_finalize();
```

例 - cpi.c

- πを計算するテストプログラム

```
MPI_Init(&argc, &argv);
tlog_initialize();
tlog_log(TLOG_EVENT_1_IN);
MPI_Bcast(&n, 1, MPI_INT, 0, MPI_COMM_WORLD);
tlog_log(TLOG_EVENT_1_OUT);
/* mypiの部分計算 */
tlog_log(TLOG_EVENT_2_IN);
MPI_Reduce(&mypi, &pi, 1, MPI_DOUBLE, MPI_SUM, 0, MPI_COMM_WORLD);
tlog_log(TLOG_EVENT_2_OUT);
if (rank == 0) /* 結果表示 */
tlog_log(TLOG_EVENT_1_IN);
MPI_Bcast(&n, 1, MPI_INT, 0, MPI_COMM_WORLD);
tlog_log(TLOG_EVENT_1_OUT);
tlog_finalize();
MPI_Finalize();
```

例 - cpiのコンパイル

- tlogライブラリをリンク

```
% mpicc -O -o cpi cpi.c -ltlog
```

- tlogライブラリ，tlogviewのインストール

```
% ./configure
% make
% sudo make install
```

/usr/localにインストールする例

例 - cpiの実行結果

```
$ mpiexec -hostfile hosts -n 4 cpi
adjust i=1,t1=0.011781,t2=0.011886,t0=0.011769,diff=6.7e-05
adjust i=2,t1=0.012911,t2=0.013015,t0=0.012877,diff=8.8e-05
adjust i=3,t1=0.014441,t2=0.014548,t0=0.014392,diff=0.000115
adjust i=1,t1=0.01623,t2=0.016335,t0=0.016285,diff=-2e-06
adjust i=2,t1=0.017314,t2=0.017418,t0=0.017367,diff=-2e-06
adjust i=3,t1=0.018401,t2=0.018504,t0=0.018454,diff=2.5e-06
tlog on ...
Process 0 on exp0.omni.hpcc.jp
pi is approximately 3.1416009869231249, Error is 0.0000083333333318
wall clock time = 0.000213
tlog finalizing ...
Process 3 on exp3.omni.hpcc.jp
Process 1 on exp1.omni.hpcc.jp
Process 2 on exp2.omni.hpcc.jp
tlog dump done ...
```

ノード間の時間差測定(デバッグ時に出力)

デバッグ時の出力

プログラムの出力

デバッグ時の出力

cpiのプロファイル結果(1)

- tlogview – tlogの可視化ツール

```
% tlogview trace.log
```

- 4プロセス(4ノード)での実行プロファイル

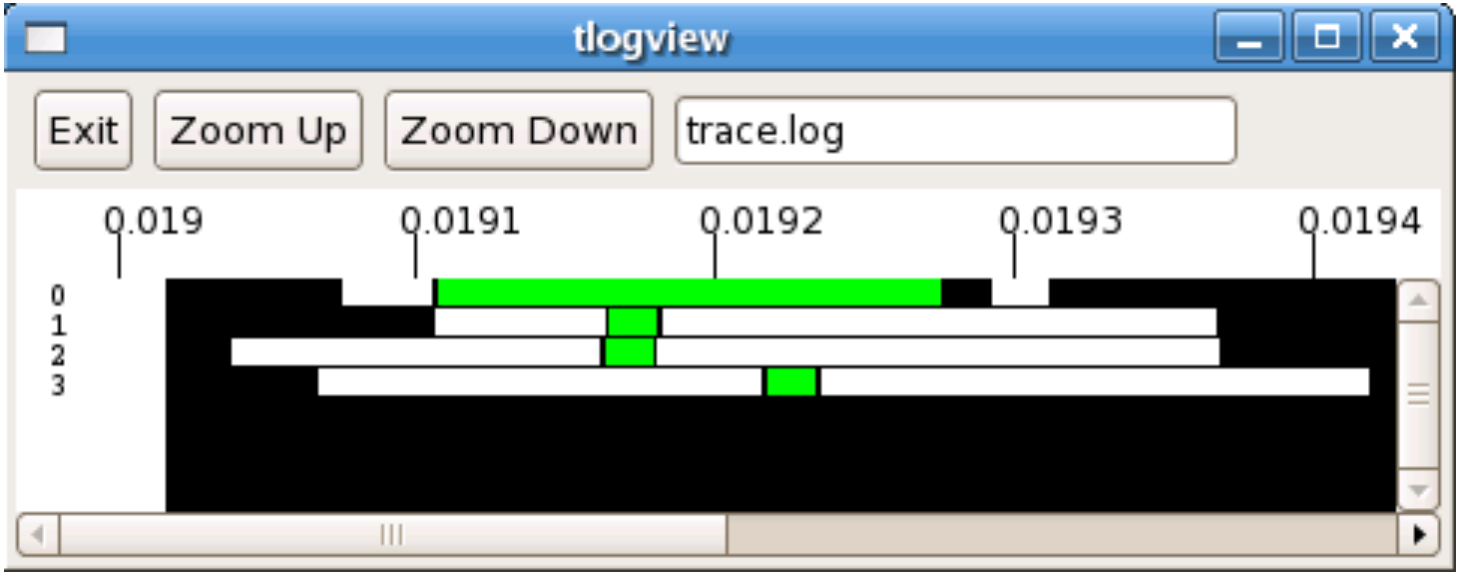

tlog_initializeからの経過時間(秒)。ノード間の時刻差修正済。

cpiのプロファイル結果（2）

- 16プロセス（4ノード×4プロセス）のプロファイル

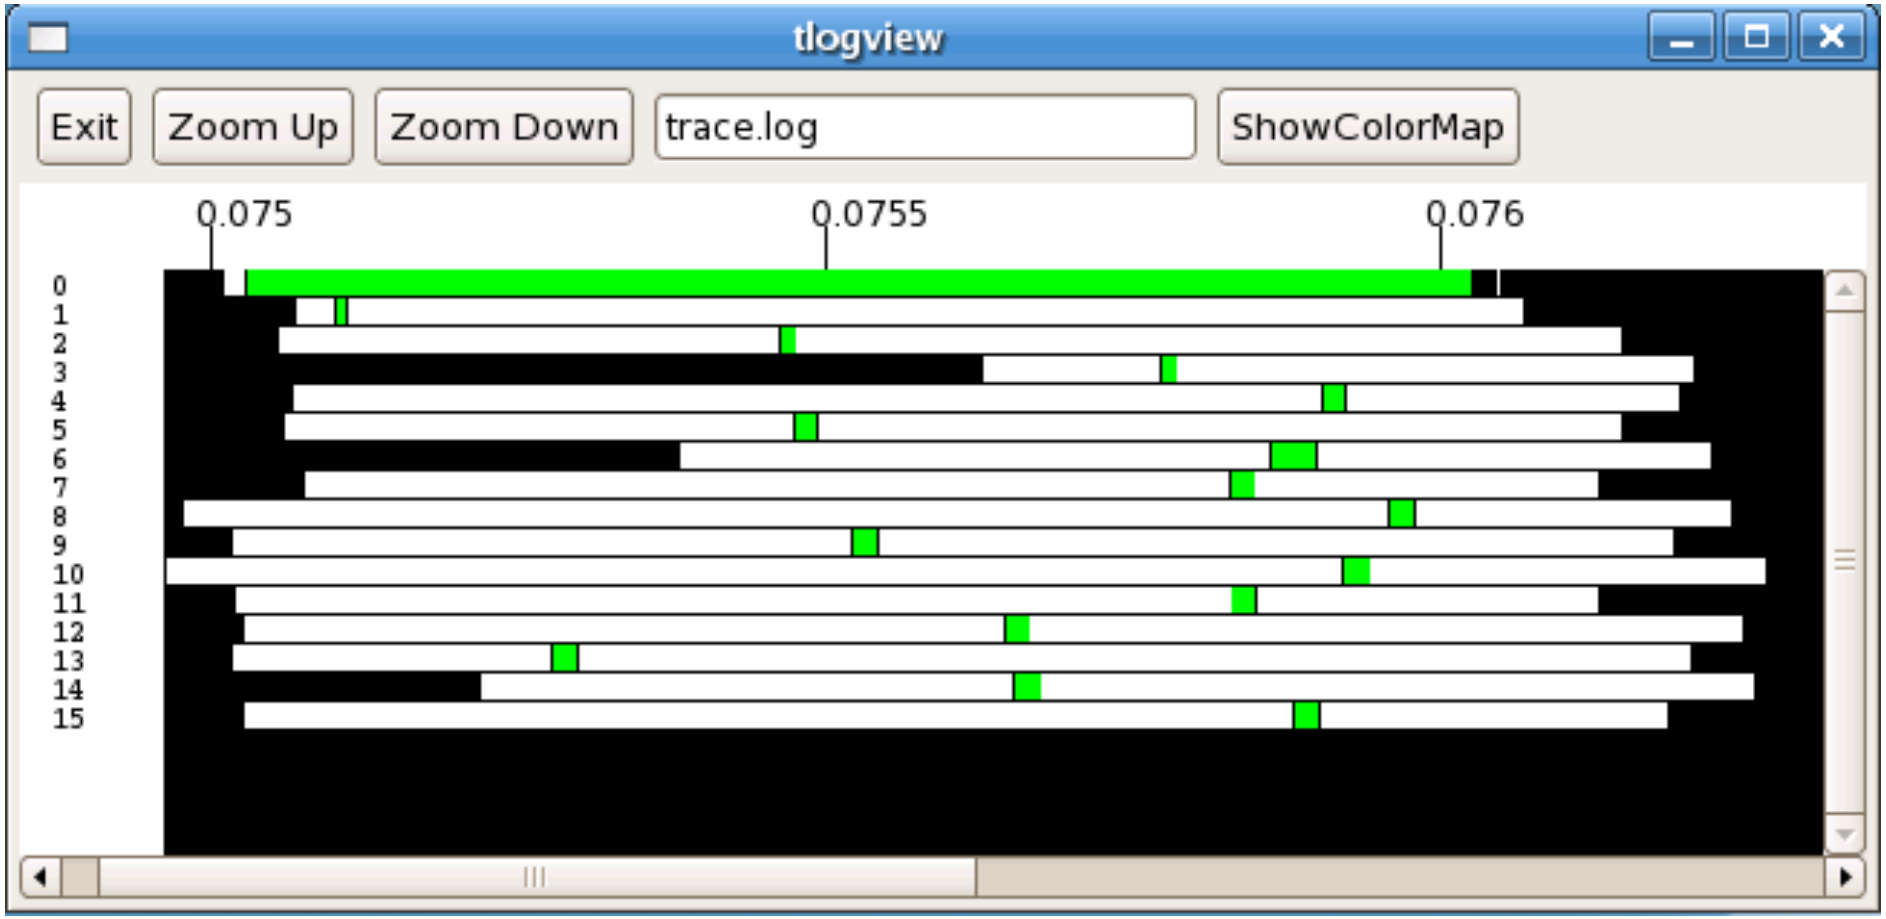

通信最適化

- 通信の削減*
- 負荷分散*
- 基本的には通信データサイズを大きく
  - 通信ブロック
  - 複数反復をまとめる
- データサイズが小さいものは通信遅延隠蔽
  - 通信と計算のオーバラップ
  - パイプライン実行

通信ブロッキング

- 1対1通信、集団通信はデータサイズによって通信性能が大きく変化する
- 通信ブロッキングは、通信データをまとめてデータサイズを変更する（大きくする）手法
  - データのブロック分散
  - 複数反復をまとめる

通信ブロッキングの例：ヤコビ法

- 二次元ポアソン方程式を5点差分で離散化した連立一次方程式の解法

```
jacobi() {
  while (!converge) {
    for(i = 1; i < N - 1; ++i)
      for(j = 1; j < N - 1; ++j)
        b[i][j] = .25 *
              (a[i - 1][j] + a[i][j - 1]
               + a[i][j + 1] + a[i + 1][j]);
    /* 収束テスト */
    /* bをaにコピー */
  }
}
```

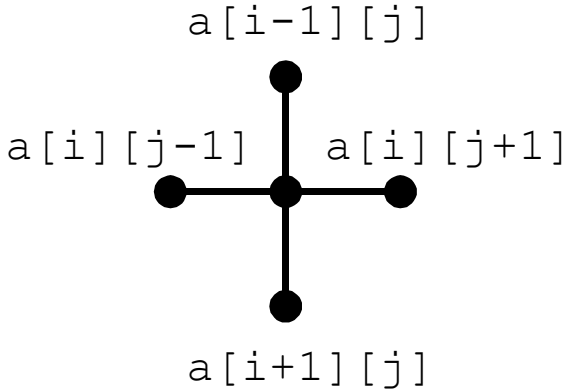

データ依存関係

*本当はヤコビ法ではなくRB-SOR法などを使って欲しい

データのブロック分散

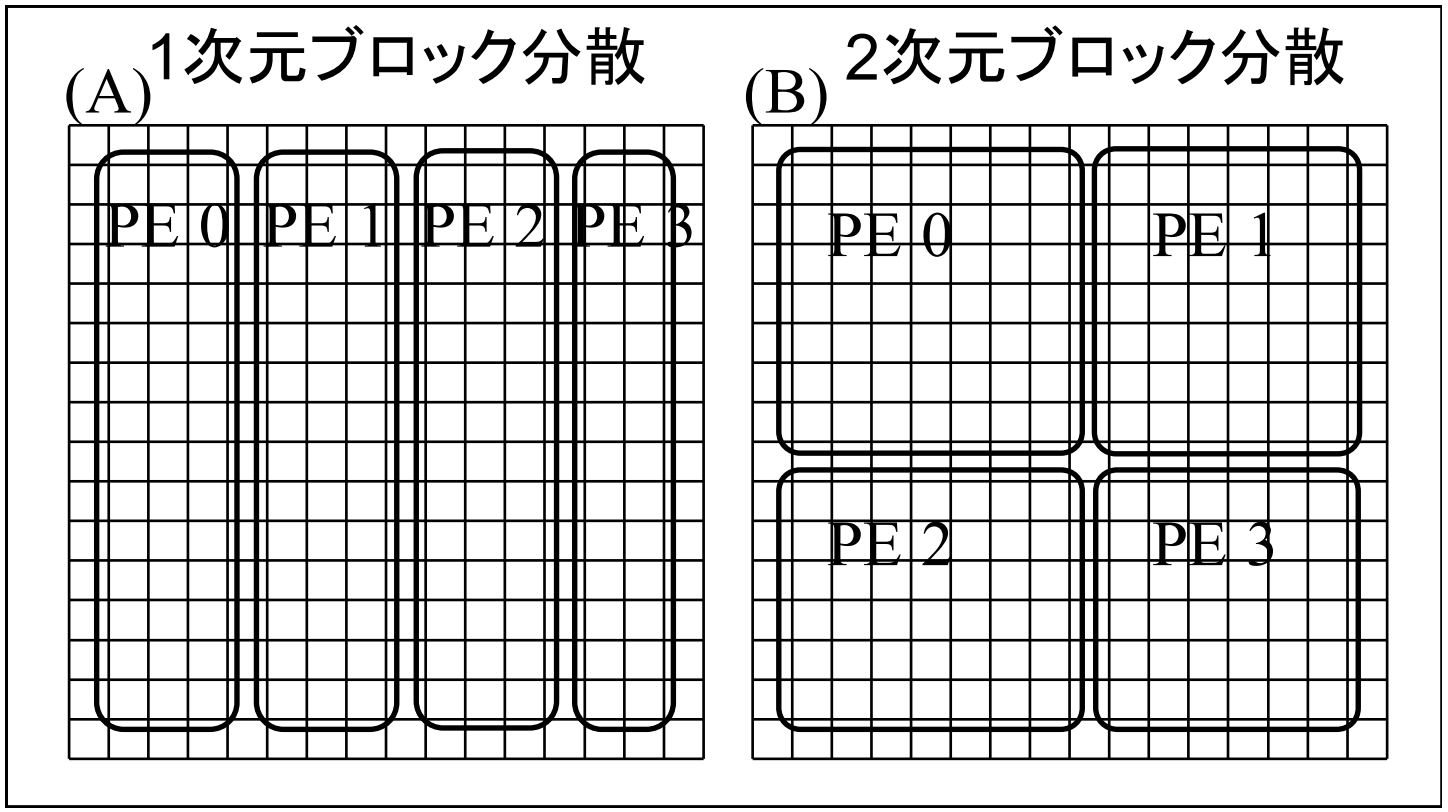

- データをブロック分割することにより通信データサイズを大きくできる
  - 1次元ブロック分散では　n
  - 2次元ブロック分散では　$n/\sqrt{p}$

シャドー領域(袖領域)の通信

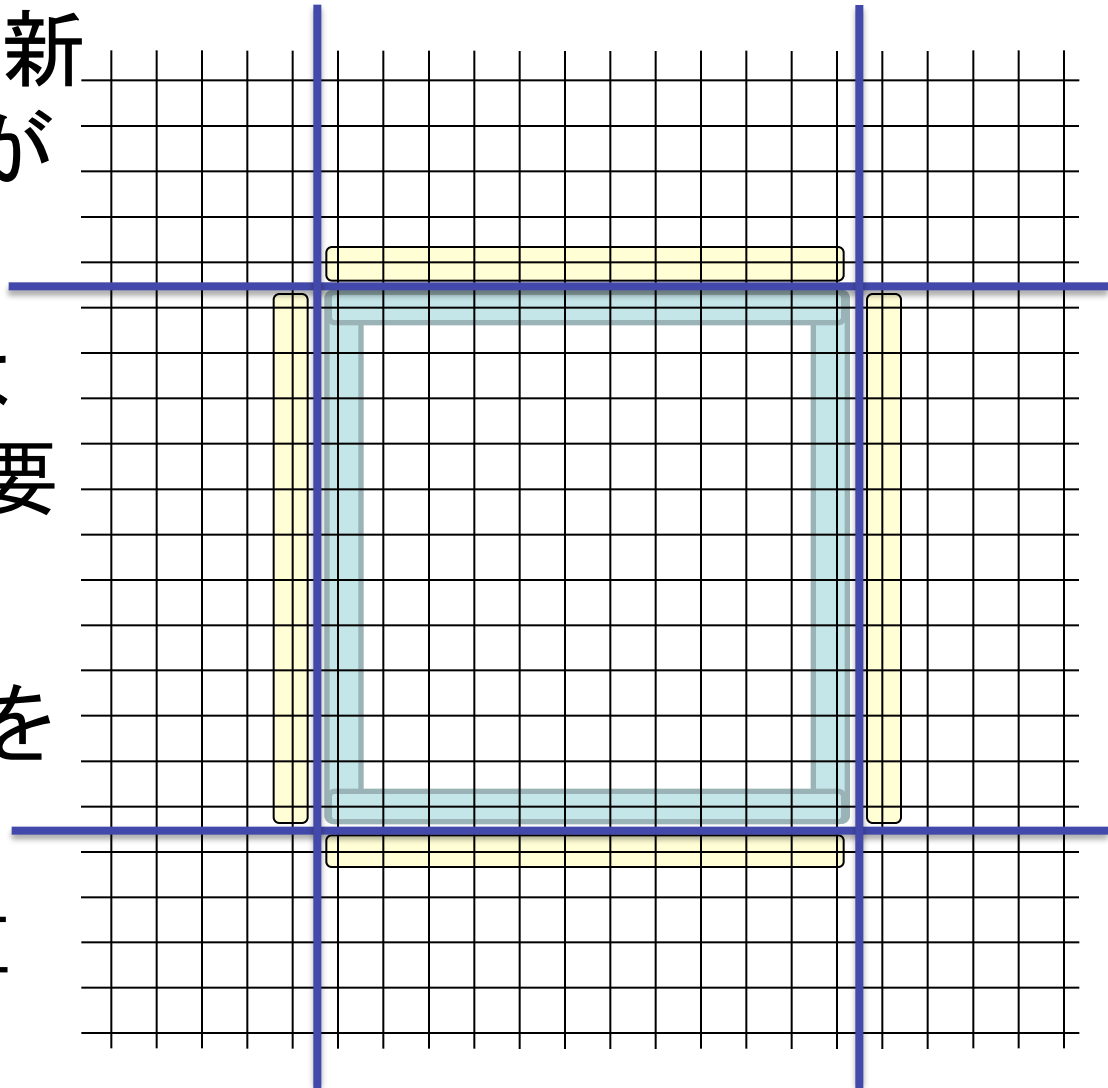

- 境界領域 の更新には のデータが必要
- 他のプロセスでは のデータが必要

1. と のデータを一括して交換
2. 各プロセスで計算

計算と通信のオーバラップ

- 内部領域の更新には □ のデータは不要

1. □のデータを送信
2. 内部領域の計算
3. □のデータの受信
4. 境界領域 □ の計算

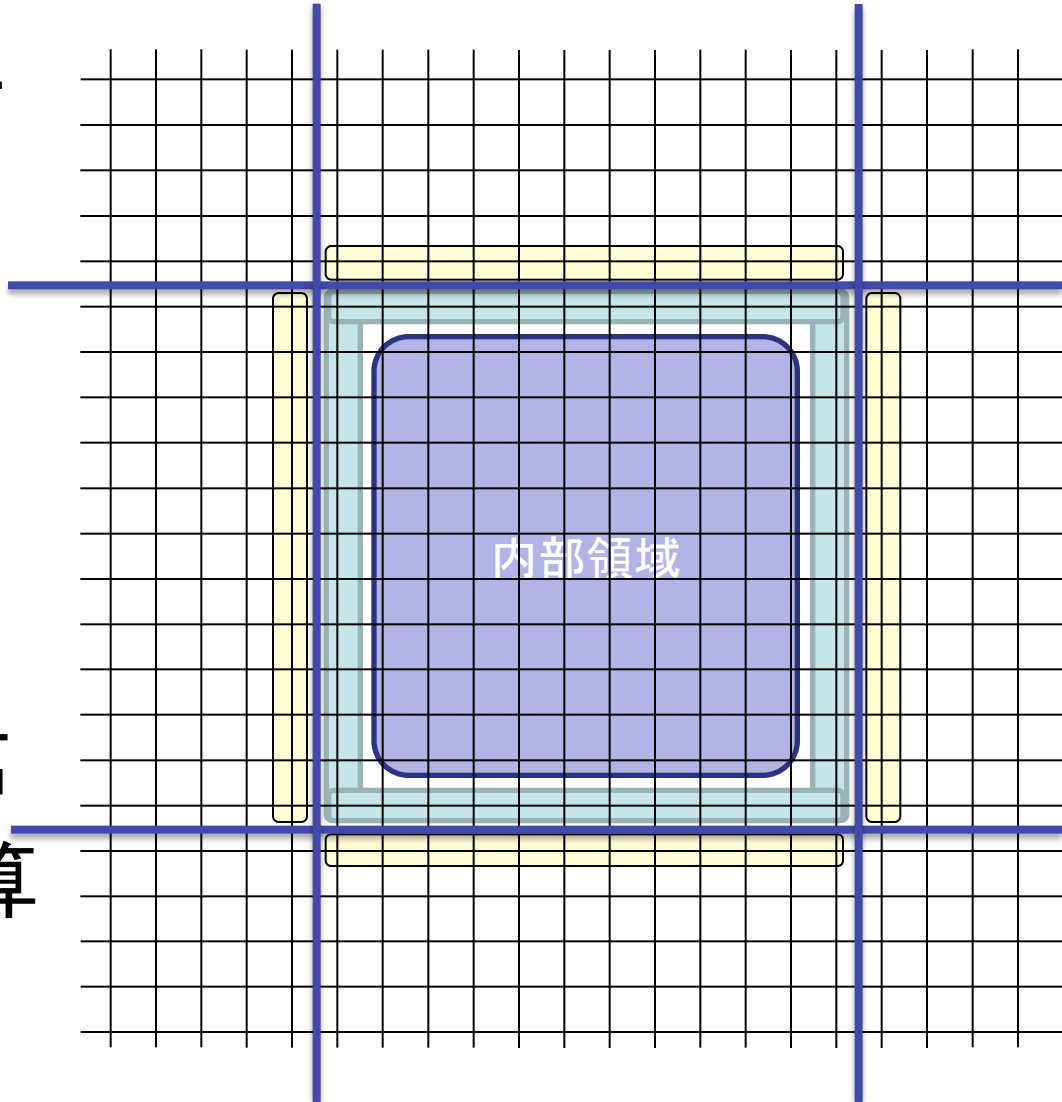

計算と通信のオーバラップ（2）

- MPI_Isend( , …, &req[0])
- MPI_Irecv( , …, &req[1])
- 内部領域計算
- MPI_Waitall(2, req, status)
- 境界領域計算

複数反復をまとめる

- ヤコビ法二反復をまとめる
- 一反復目では □ のデータが必要
- 二反復目では □ のデータが必要
- □ と □ のデータを転送することにより二反復をまとめられる
  - 1次元　$2n$
  - 2次元　$2n/\sqrt{p}$

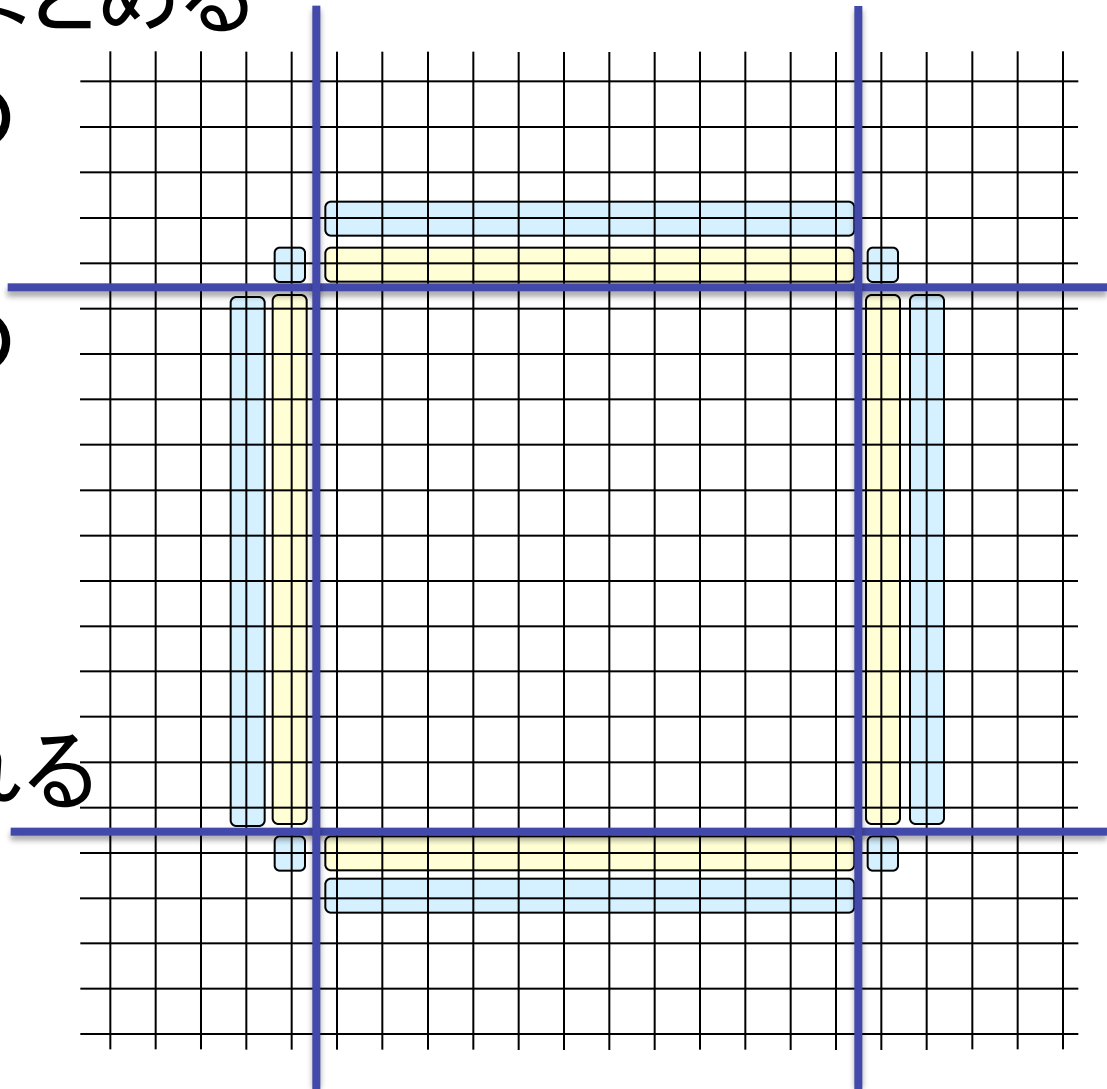

複数反復をまとめる(2)

-  と  のデータを転送する
- [一反復目]袖領域を含めた赤領域を計算
- [二反復目]袖領域は既に最新データを持っているため通信なしに計算可能

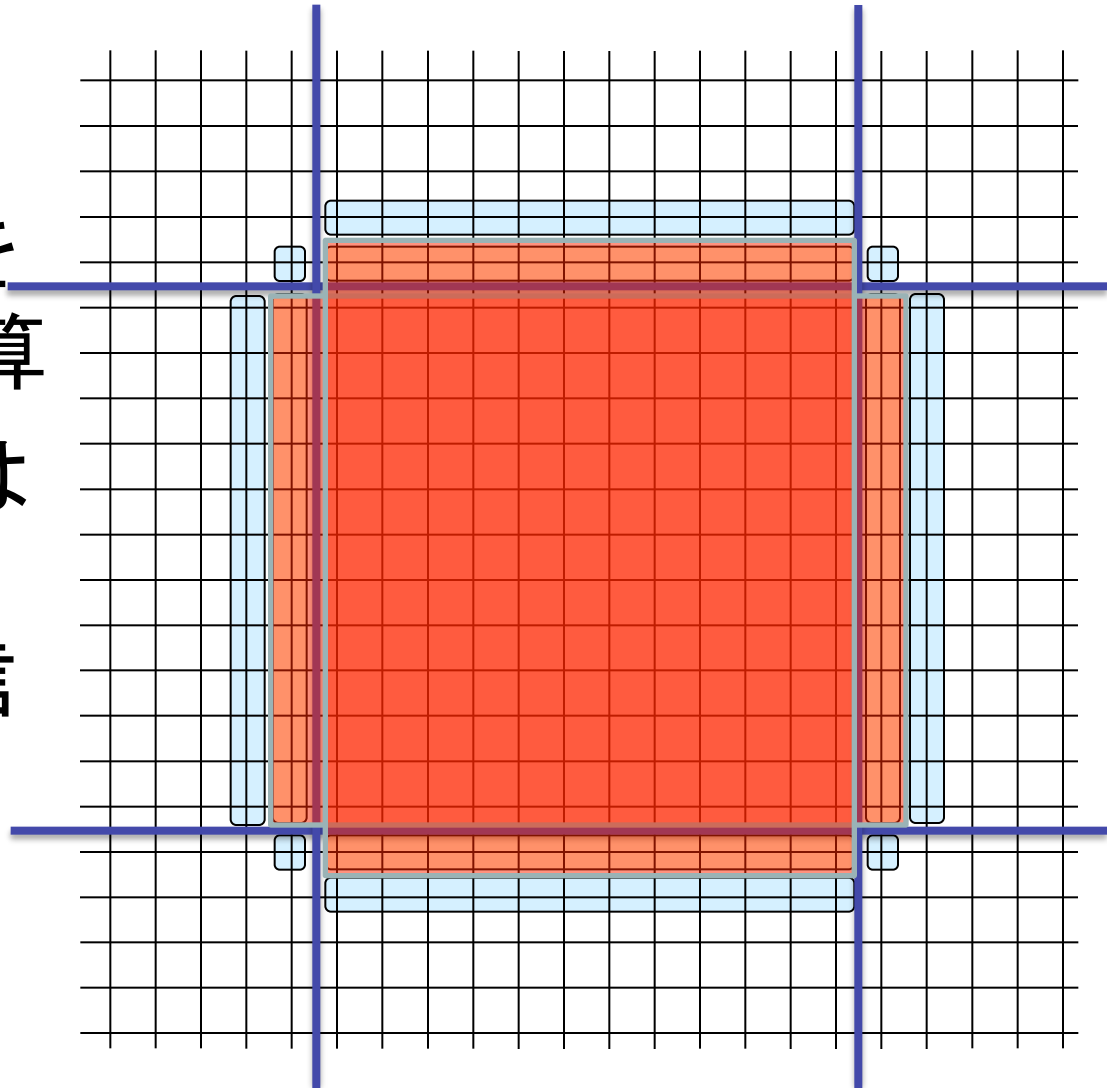

まとめ

- 基本通信性能
  - 1対1通信
  - 集団通信
- プロファイラ
- 通信最適化
  - 通信の削減
  - 通信遅延隠蔽
  - 通信ブロック
  - 負荷分散

「最適化2」レポート課題

- 2次元ラプラス方程式をヤコビ法で解くMPIプログラム（参考：「MPI」で紹介したlaplace）を作成し，複数反復をまとめる最適化を行いなさい。最適化前後でtlogによるプロファイルを行い，考察を行いなさい。