次世代オペレーティングシステム

SSS-PC

The Scalable Operating System

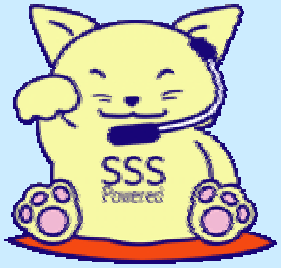

Jan 20, 2003

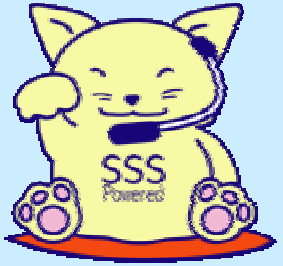

松 本 尚

国立情報学研究所
情報基盤研究系

対象となるクラスタシステム (1)

職場におけるクラスタ (計算機群)

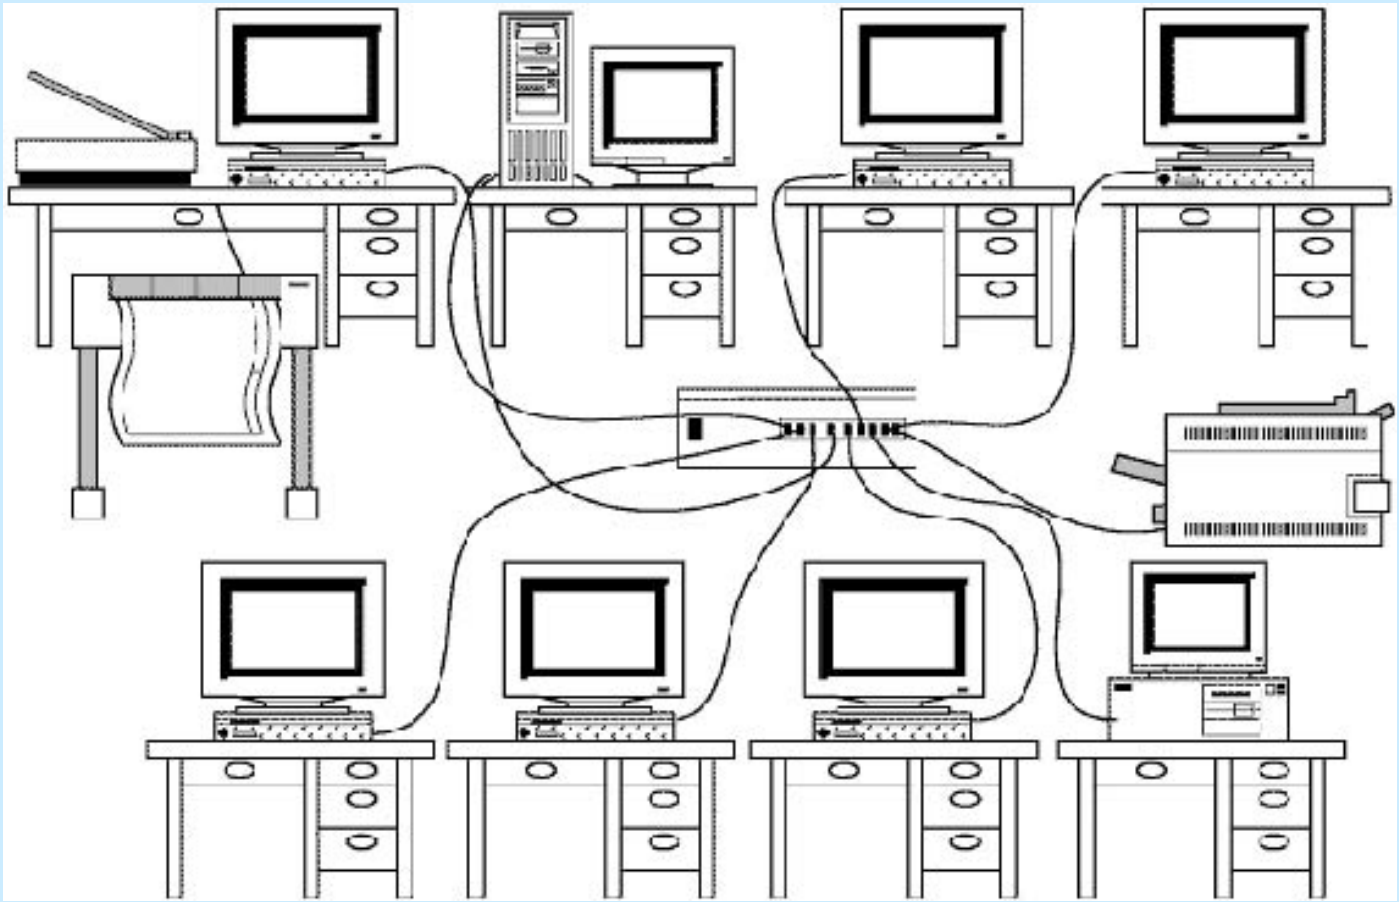

対象となるクラスタシステム (2)

PCサーバークラスタ

対象となるクラスタシステム (3)

PC＆WS 混載クラスタ

対象となるクラスタシステム (4)

SSS-PC WSクラスタ

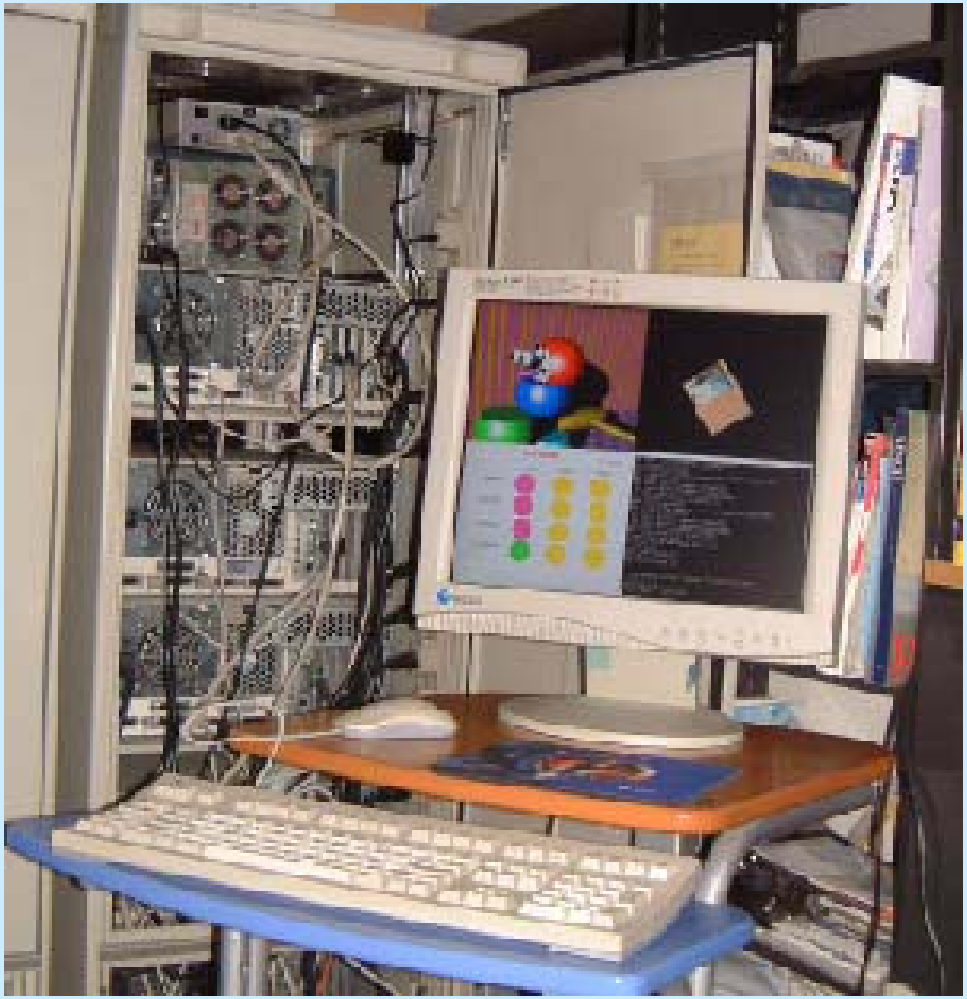

SSS-PCの特徴

1. 高機能、低遅延、低オーバヘッドの汎用通信方式: MBCF
2. タスクマイグレーション機能による無停止メンテナンス
3. 自由市場原理(FMM)に基づく負荷分散機能
4. マシン境界を越えた情報開示機構: IDM
5. LINUX・UNIXプログラムとのソースコード互換開発環境
6. 分散共有メモリサポート: ADSM/UDSM
7. 並列プログラムの多重並行処理（マルチタスク）
8. 共有メモリプログラム用最適化コンパイラ: RCOP
9. 高性能MPIライブラリ: MPI/MBCF
10. 純国産オペレーティングシステム

SSS-PC Ver.1.0の機能構成

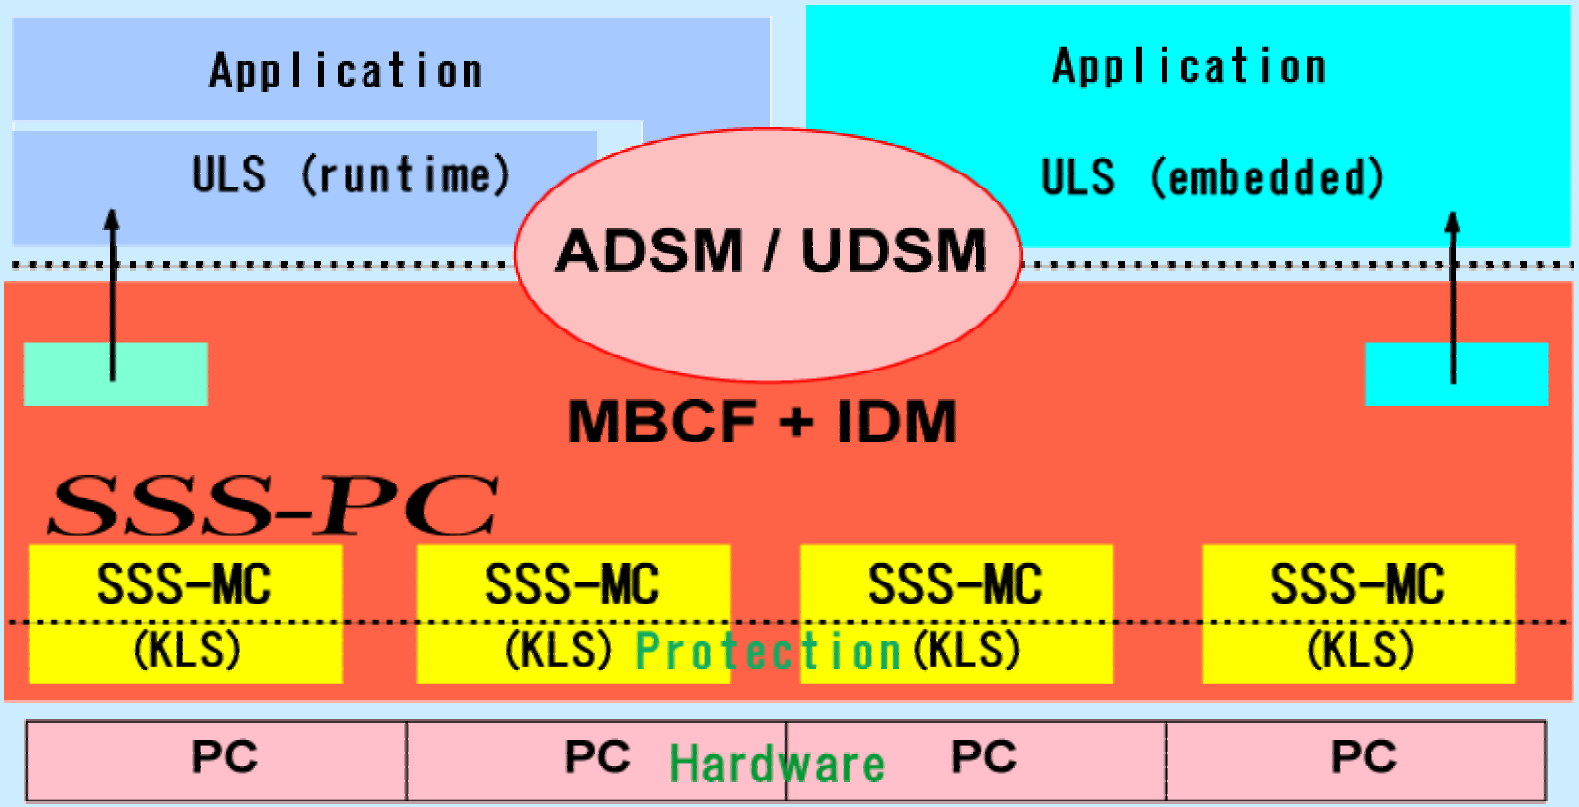

MBCF: Memory-Based Communication Facilities
ADSM: Asymmetric Distributed Shared Memory
UDSM: User-level Distributed Shared Memory
KLS: Kernel Level Scheduler
ULS: User Level Scheduler
IDM: Information Disclosure Mechanism

Gigabit Ethernetを使ったMBCFの性能(1)

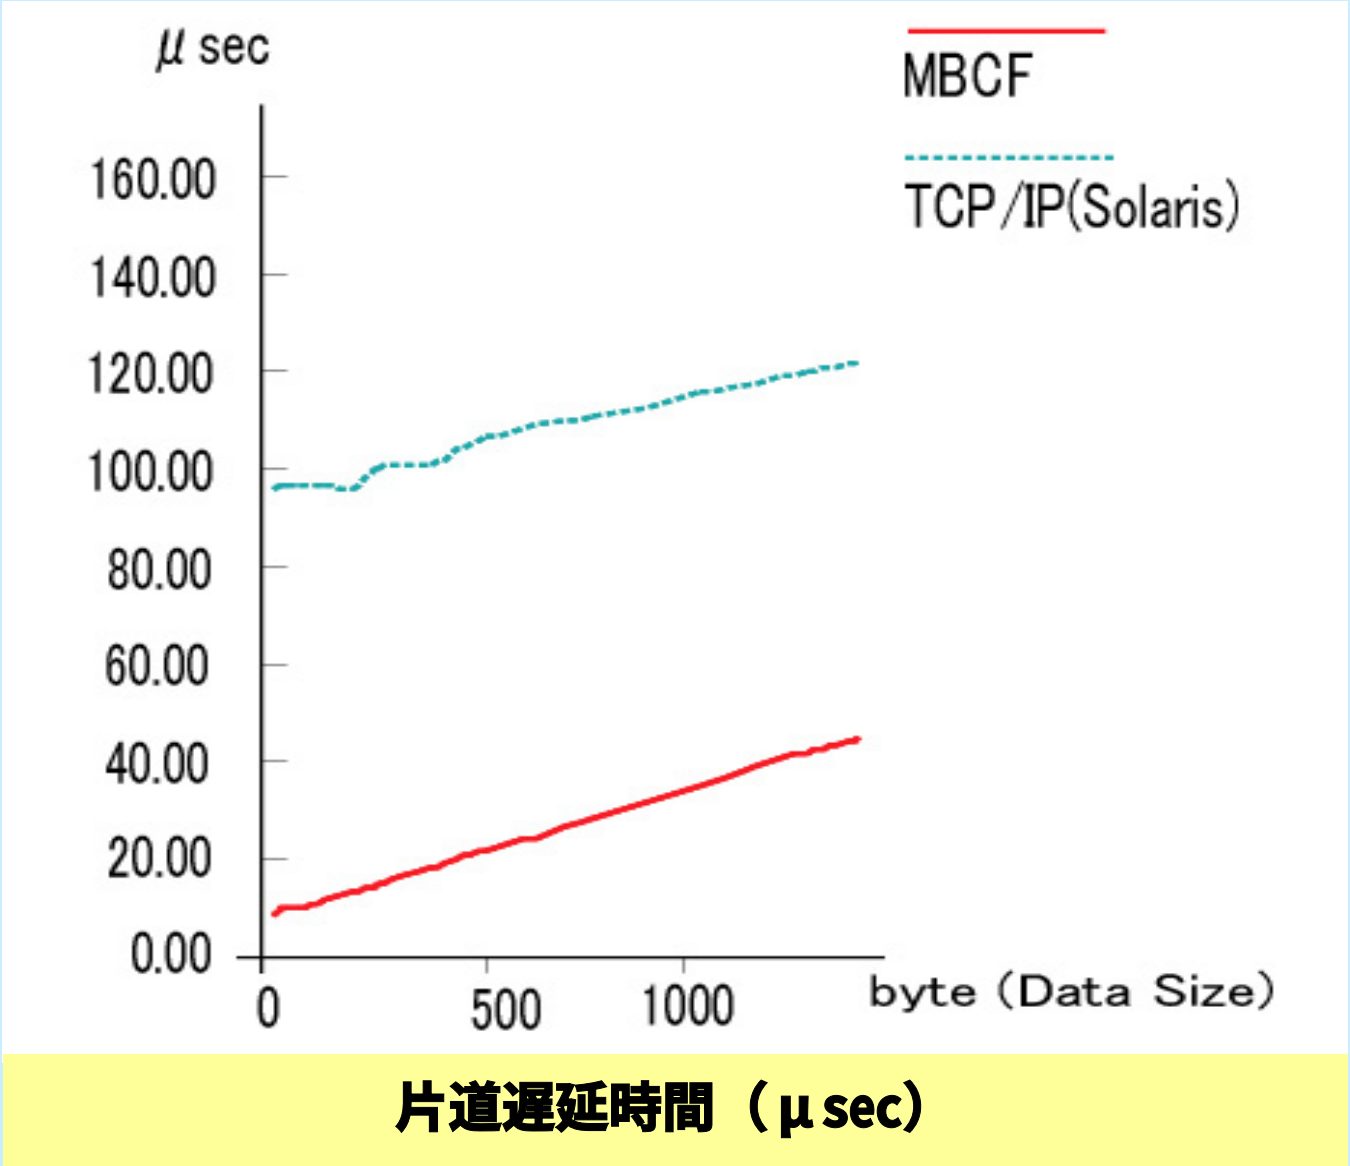

片道遅延時間（μsec）

Gigabit Ethernetを使ったMBCFの性能(2)

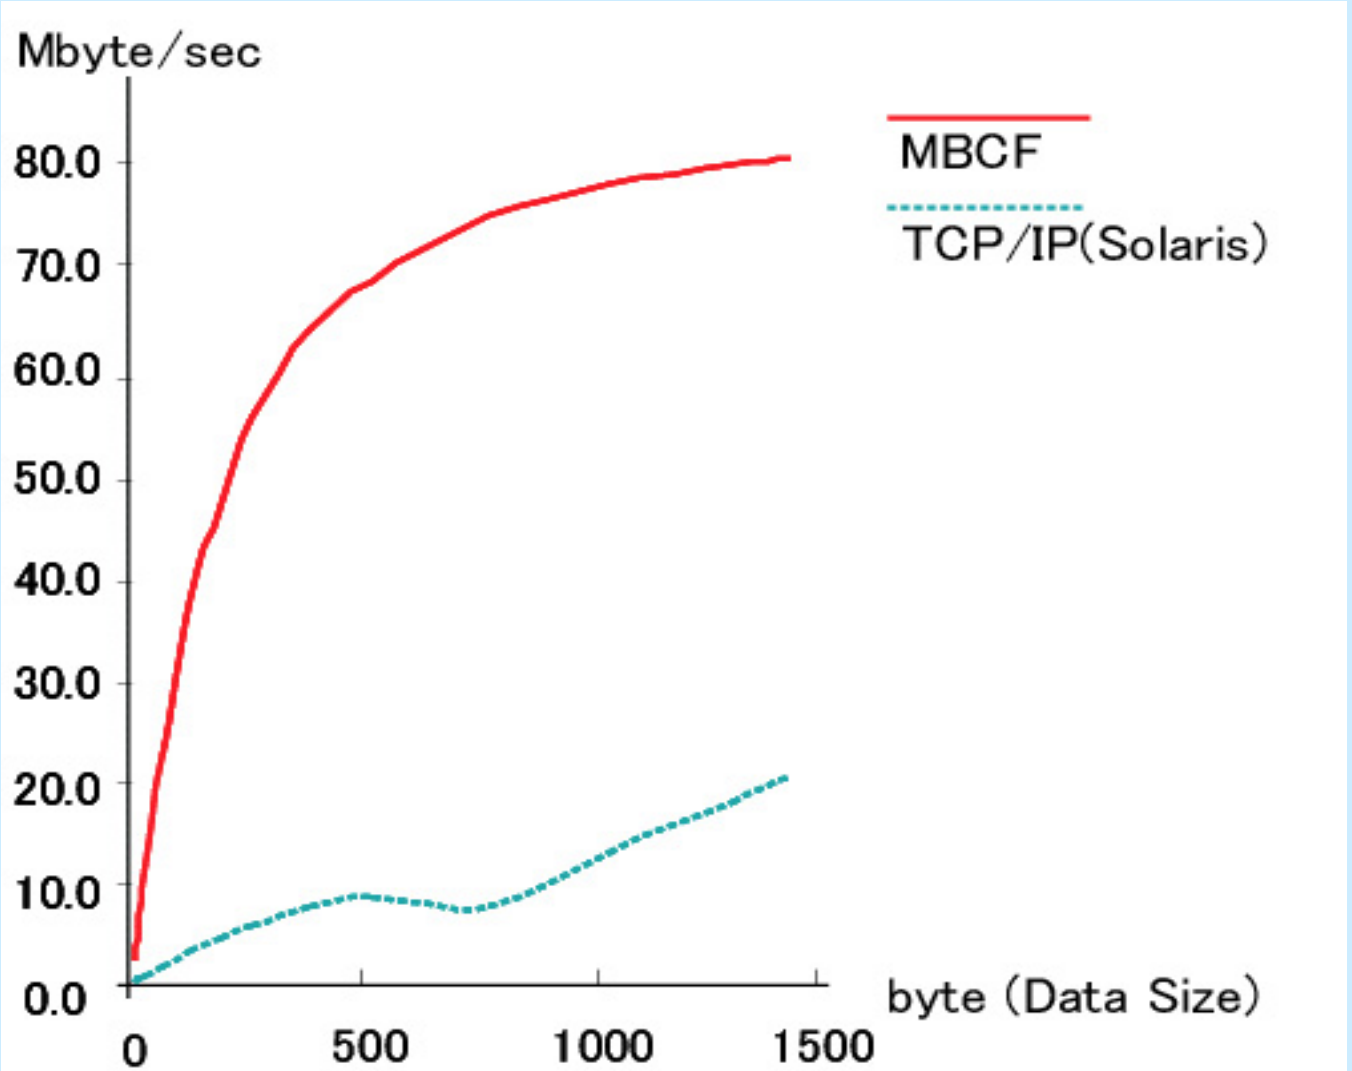

実効最大バンド幅（Mbyte/sec）

MPI/MBCF@*SSS-PC* と MPICH@SunOSの性能比較 (1)

SSS-PC におけるアプリケーション実行性能
（SunOSにおける性能を1とした。16ノード。
性能＝実行時間の逆数）

MPI/MBCF@*SSS-PC* と MPICH@SunOSの性能比較 (2)

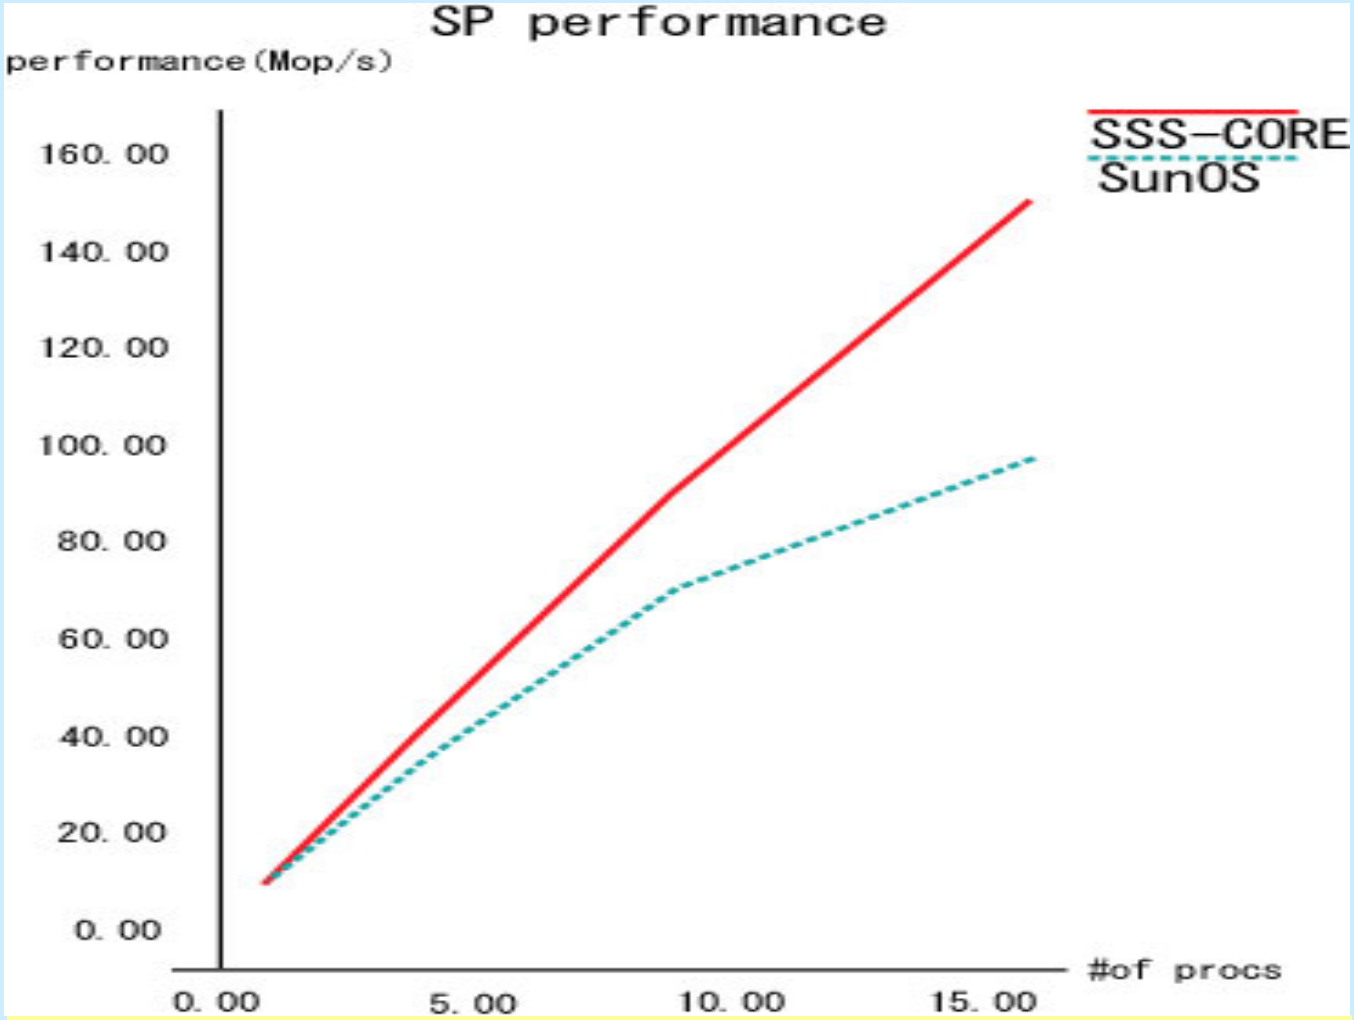

SP実行時の台数効果

タスクマイグレーション（仕事移送）機能 1

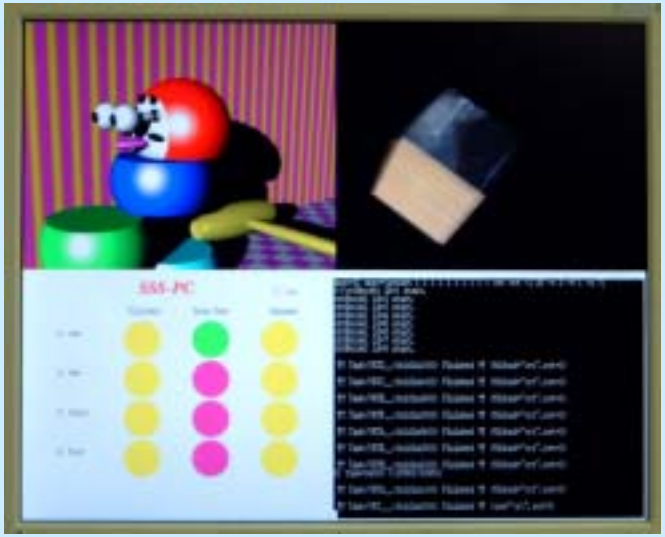

1番で仕事1個、2,3,4番仕事各3個を固定

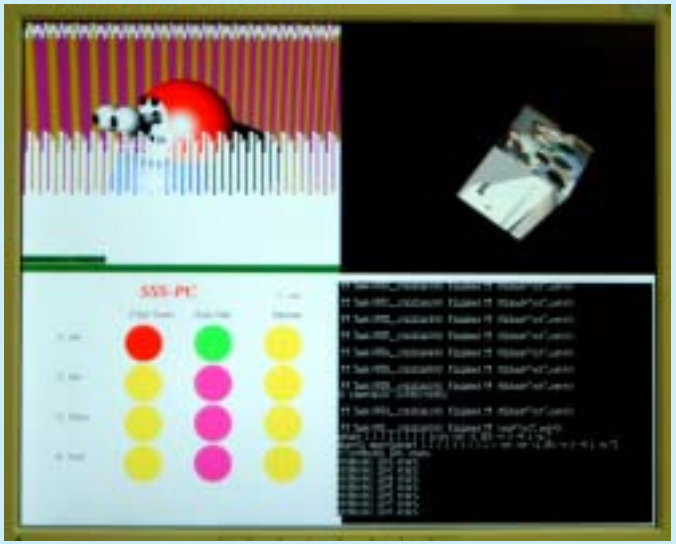

1番で仕事8個を起動

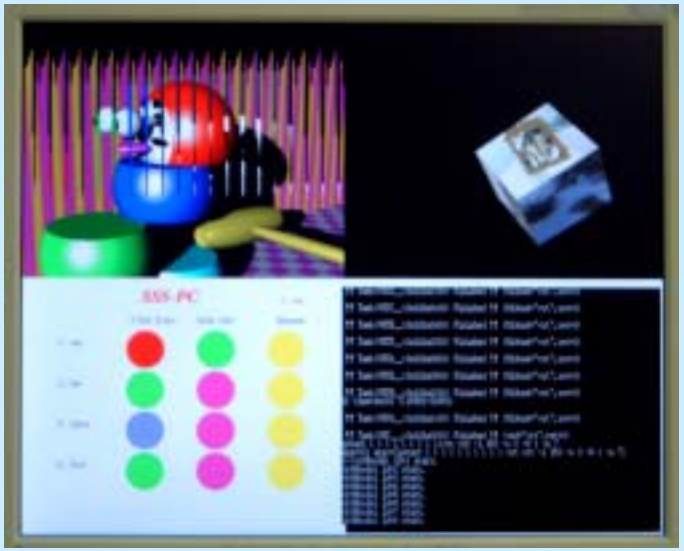

8個の仕事（左上）が他のマシンに移動中

タスクマイグレーション（仕事移送）機能 2

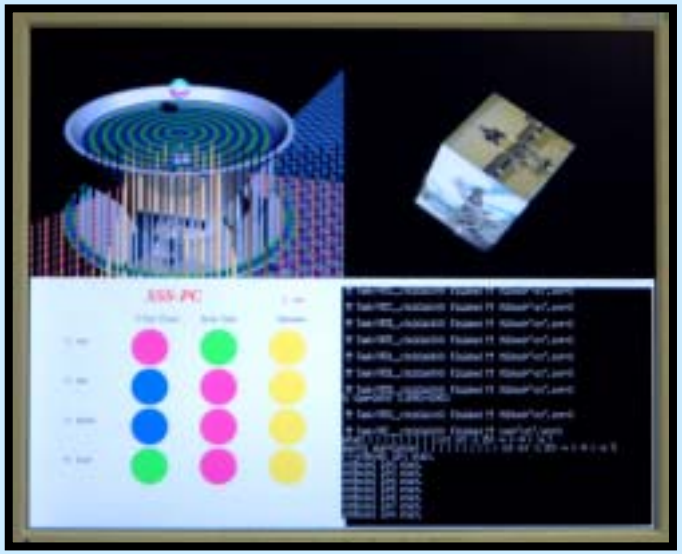

準安定状態

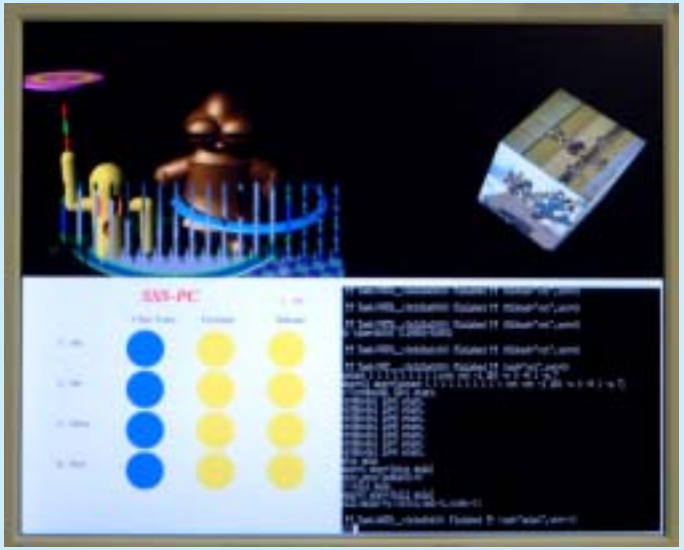

右上のアプリ停止後の安定状態（各2個の仕事）

2番に4個の固定仕事を新規投入

左上のアプリは2番から3,4番に退避

タスクマイグレーション(仕事移送)機能 3

右上の新規投入アプリ実行中(定常状態)

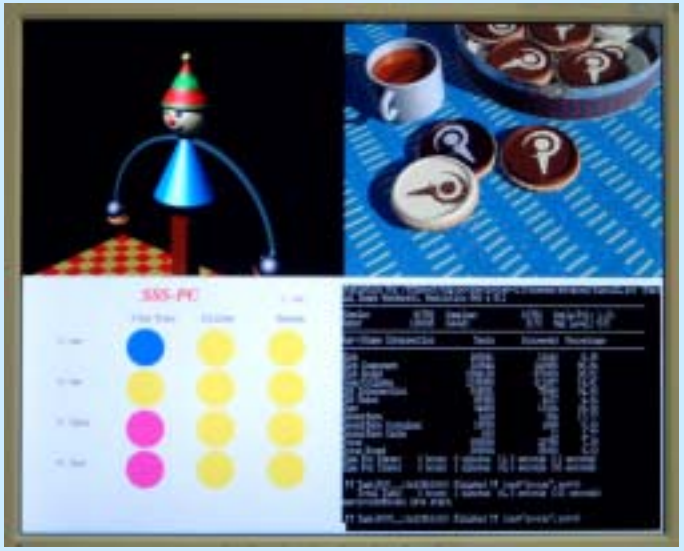

右上の新規アプリが終了

空いた2番に仕事が移動

再び仕事2個ずつの定常状態に

タスクマイグレーション（仕事移送）機能 4

3番マシンを停止、仕事は他マシンへ退避

3番マシンの停止を検出

3番マシンを再起動（3番の画面）

3番に仕事が移動し、再び定常状態に

自由市場原理に基づくスケジューリング方式

- 全知全能である必要があるグローバルスケジューリング方式を諦め、マシン間のスケジューリングはアプリケーションプログラムの自由意思に任せることにする
- 自己責任でスケジューリングの判断を下すための情報を低コストでアプリケーションプログラムが獲得できる必要がある
- 公平性は確保されねばならない、つまり他人に不合理な迷惑を掛ける自由は認めない
  「厚かましい」アプリケーションプログラムが結果的に優遇されることを避ける必要がある
- 自由市場原理に基づくスケジューリング方式
  Free Market Mechanism 方式　（**FMM**方式）
- 自由主義方式のスケジューリング
- 低コストでアクセスできる情報開示機構
- 公平性を守るための基本ルールの確立

ユーザプログラムのFMM用基本戦略

1. 適当な粒度（数百msec）で本来の仕事を実行
2. 情報開示機構に問い合わせて一番軽いマシンM1を調べる
3. M1と自マシンの負荷を比較し、移ることが得かどうか判断
4. 非移動が得である場合は1. に戻る
5. サイコロを振り、移送猶予期間 T1をランダムに決定
6. さらに T1の時間を過ぎるまでの間、本来の仕事を実行
7. 情報開示機構に問い合わせて一番軽いマシンM2を調べる
8. M2と自マシンの負荷を比較し、移ることが得かどうか判断
9. 非移動が得である場合は1. に戻る
10. M1とM2が一致の場合、移送システムコール発行、戻ったら1. へ
11. M1とM2が不一致の場合、M2を新たなM1として5. へ

並列アプリケーションの並行実行

POVRAYによる台数効果

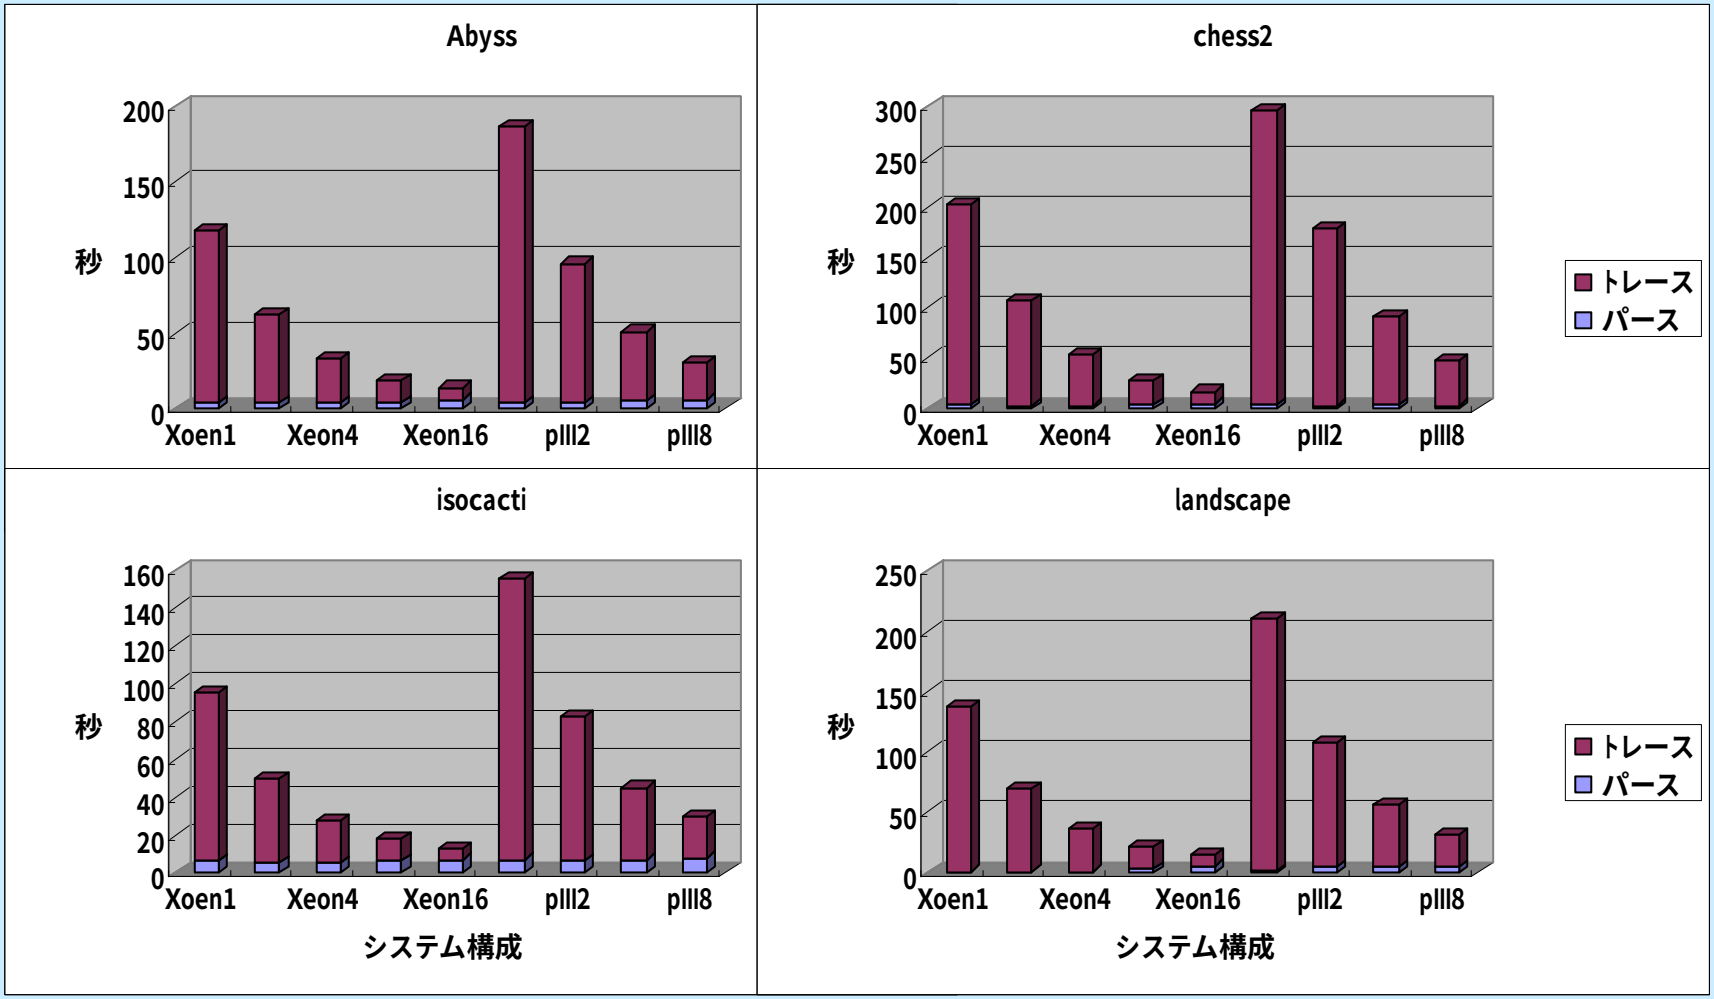

XEON 2.8GHz E7500、PIII 1．26GHz Server Set III HE-SL、640x512ピクセル

ディペンダブルコンピューティングの基盤技術へ

- 冗長多重実行による多数決実行
- 突発事故によるマシン停止でもアプリケーションの実行継続
- キラーアプリケーション（並列サーバーアプリ）の作成
- SSS-PCの完成度の向上

「マネキッコ」