

次世代メニーコア型スパコンのための システムソフトウェア

堀 敦史

システムソフトウェア技術部会 部会長(理研 AICS)

清水 正明

システムソフトウェア技術部会 副部会長(日立)

2017/12/15



- IHK/McKernel
 - 最新情報
- Process in Process (PiP)
 - 新しい並列実行環境の紹介

McKernel

背景

- HPCシステムの複雑化への対応

- 並列性の増大

- コア数とノード数



少数のコアをOS専用としても、そのオーバヘッドは無視できる(1/32コアで3パーセント)

- メモリ階層数の増大

- 電力制約



スケーラブルで安定した性能の提供と新ハードウェアへの迅速な対応がカギ

- アプリケーションの複雑化

- 新しいプログラミングモデルの導入

- 例: In-situデータアナリティクス、ワークフロー

- 周辺ソフトの複雑化



Linux API で開発されることが多いため、Linux との ABI 互換性が重要



既存の膨大なツールチェーンがそのまま使えることが重要


 これらの要件を同時に満たせるか？

Linuxカーネルの問題点

- **Linux はこころこ変わる**
 - 頻繁かつ大胆に変わる
 - Linux カーネルを改変し, かつ, catch-up するのは非常に大変
 - 多様なハードウェア
 - 次々に現れるデバイスハードウェア
 - デバイスドライバの作成にはH/Wの詳細な情報が不可欠
- **Linux カーネルを改造するのは非常に大変**
 - プロダクトとしては不可能に近い
- **しかしながら, 言語環境, 実行環境は Linux を継承したい**
 - 環境も作るのは大変
 - Linux API/ABI との互換性をどのように実現するか？


McKernel のアーキテクチャ

- Interface for Heterogeneous Kernels (IHK): 複数の異種OSを持つためのフレームワーク
 - ノード資源のパーティショニング
 - LWKの管理(例:カーネルの起動、停止)
 - LWKとLinuxの間の通信機構(Inter-kernel communication, IKC)の提供
- McKernel: スクラッチから開発されたHPC向けLWK
 - ノイズレス
 - 性能クリティカルなシステムコールのみMcKernelで動作、他はLinuxにオフロード



CCS-QCD (Hiroshima University)


- Lattice quantum chromodynamics code – weak scaling
- Up to 38% improvement



OFP上で計測


miniFE (CORAL benchmark suite)

- Conjugate gradient - strong scaling
- Up to 3.5X improvement (Linux falls over..)



OFP上で計測

Single node: McKernel outperforms Linux across the board → multi-node Lammps suffers from network offloading..



- lammps, HACC, QBOX ~4% better, as opposed to being slower than Linux on 8 nodes
- OmniPath offload overhead??

IHK/McKernel - まとめ

- **Xeon Phi 上でも動作**
 - Knights Landing (KNL) 最新メニーコアCPU
- **Linux+IHK/McKernel**
 - LinuxコアでMapReduce, IHK/McKernelコアで並列アプリという動作でも, Linux だけよりも性能独立性が高い
 - Linuxよりはるかに単純なので, 変更, 機能追加が容易
 - IHK/McKernel : 約 8 万行
 - Linux : 2100万行！！
(<http://news.mynavi.jp/news/2016/04/11/130/>)
- **より高いLinuxコンパチビリティ**
 - Procfs および numa 機能の実装など
- **実用性**
 - Linux を reboot せずに IHK/McKernel を boot できる
- **実戦配備**
 - Oakforest-PACS (東大・筑波大) で採用
 - ポスト京コンピュータでも採用される予定

Process in Process (PIP)



背景

● メニーコアの台頭

- これまでのノード内並列モデルのままで良いのか？
- マルチプロセス（MPI）、マルチスレッド（OpenMP）

		Address Space	
		Isolated	Shared
Variables	Privatized	Multi-Process (MPI)	3rd Exec. Model
	Shared	??	Multi-Thread (OpenMP)

アイデア


- プロセス間でデータを互いに直接アクセスできるようにしよう！
- 既存研究
 - Smartmap (米SNL)
 - **Kitten OS**
 - X86 アーキテクチャに依存
 - Xpmem (SGI ?)
 - **Linux カーネルモジュール**
 - 直接アクセスするためにシステムコールが必要
 - PVAS (理研)
 - **Linux カーネルに約 5,000 行のパッチ**
 - MPC (CEA@仏)
 - **独自のコンパイラが必要**
- **PiP はユーザレベルの普通のライブラリ**

HPDC'18 で採択



MPICHでの評価


- Current Eager/Rndv. 2 Copies
- PiP Rndv. 1 Copy



(Xeon/Linux)

SNAPでの評価

- (MPI + OpenMP) $\Rightarrow$ (MPI + PiP)



PiP V.S. threads in hybrid MPI+X SNAP
strong scaling on OFP (1-16 nodes, flat mode).

PiP – まとめ

- 従来の2つのノード内並列実行方式、プロセス並列とスレッド並列のいいとこ取り
- これまでに提案された方式と異なり、ユーザレベルで実装される
- PiP により、以下の利点が期待される
 - より高速なノード内通信
 - より低メモリ消費な並列実行環境
- オープンソース
 - MPICH、Open MPI の PiP による実装
- 共同研究
 - アルゴンヌ研究所、テネシー大学、イリノイ大学、仏CEA など