LKSTによるLinuxカーネルの評価とボトルネック解析

(株)日立製作所
システム開発研究所

平松　雅巳, 杉田　由美子

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

目次

- カーネル性能評価手法
- LKSTとは
- LKST Log Toolsとは
  - 性能解析ツール
  - 可視化ツール
  - 使い方
- IOボトルネック解析例
  - Iozoneによるボトルネック例
  - リクエストキュー長解析
  - スピンロック解析
- LKSTのオーバヘッド

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

カーネル性能評価手法

- 性能評価手法
  - ベンチマーク
    - アプリケーションレベルの情報のみ
  - サンプリング
    - 実行頻度のみ（前後情報なし）
    - サンプリングに漏れる場合が存在

  →カーネル内部の詳細な情報が欲しい
- カーネルトレーサを利用
  - 主な処理を確実に記録可能

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

LKST(Linux Kernel State Tracer)とは

- Linuxカーネル向けイベントトレーサ
  - カーネルドライバ(本体と組込みイベントハンドラ)
  - カーネルコードに埋め込まれたフックポイント
  - ユーザコマンド群
  - 拡張イベントハンドラ
- 特徴
  - イベントトレース時の柔軟な**カスタマイズ設定**
    - 記録するイベントの種類
    - イベント記録時の処理内容
    - イベントの記録内容
    - 記録領域

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

LKSTの動作図

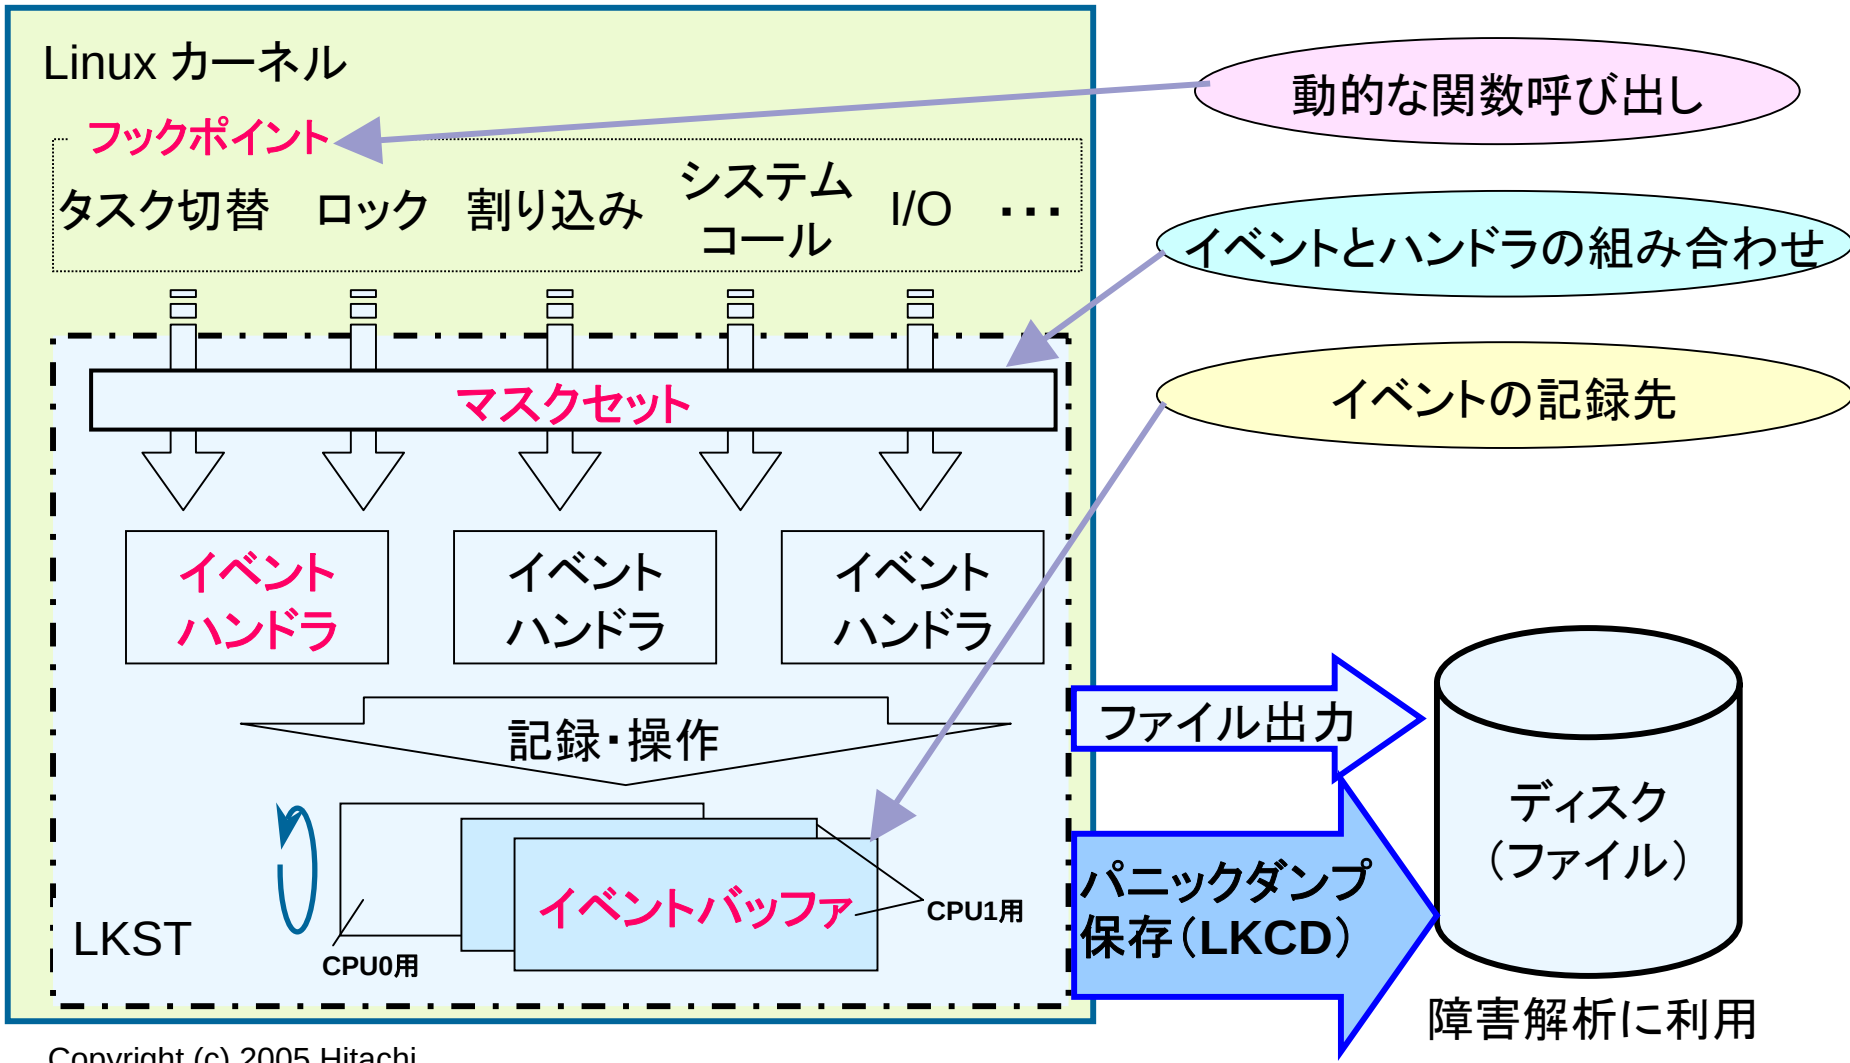

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

LKST Log Toolsとは

- LKSTによるカーネル性能評価機能
  - LKSTの機能拡張部分
  - 性能データの解析ツール
  - 解析結果のプロットツール
- 特徴
  - 性能情報ごとに個別の性能指標値を算出
    - 単一の情報だけではない
  - データの切り出し・表示形式の変更が可能
    - フィルタ・フォーマッタの切り替え
  - 解析結果をプロット可能
    - PS/PDF形式でプロットデータを保存

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

LKSTによる性能評価機能

- 性能評価ポイントで情報を取得する「LKST機能拡張」
- 取得した情報を解析する「性能解析ツール」
- 解析した情報を可視化する「可視化ツール」

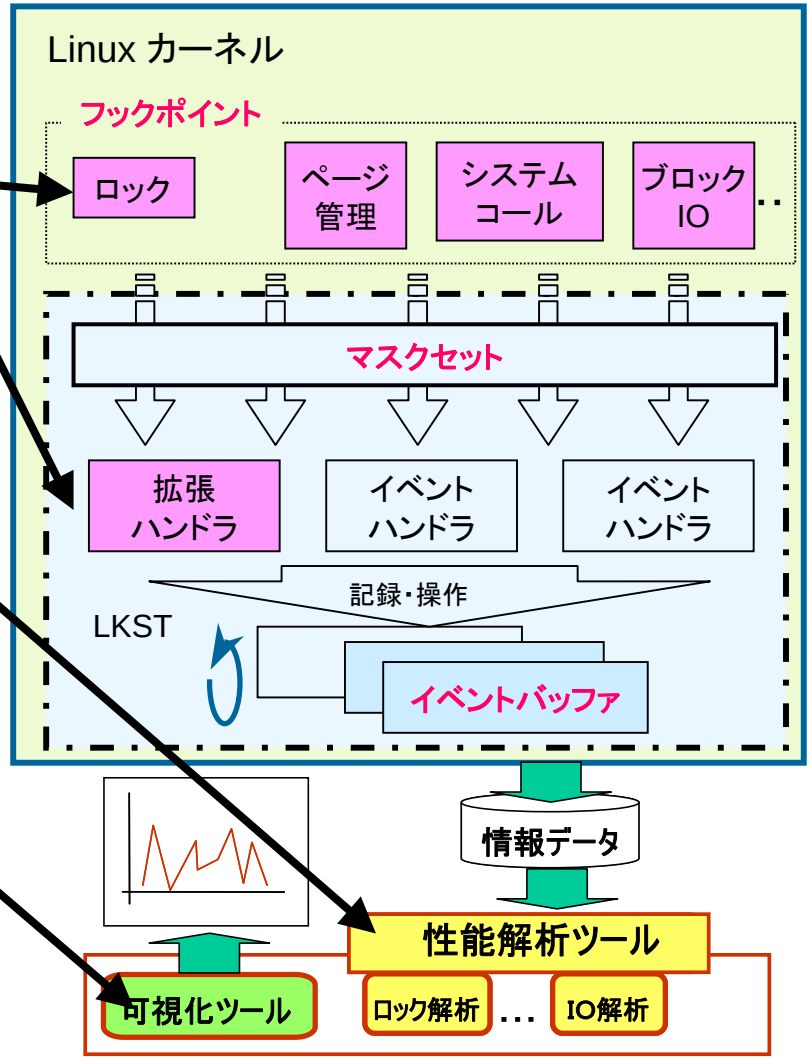

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

性能解析ツール(lkstla)

- 3つの機能を持っている
  - アナライザ
    - LKSTのログファイルを解析して、性能を示す値を抽出する。
  - フィルタ
    - いくつかの条件によって、結果を選り分ける。
  - フォーマッタ
    - 解析結果の統計や分布などを表示する。

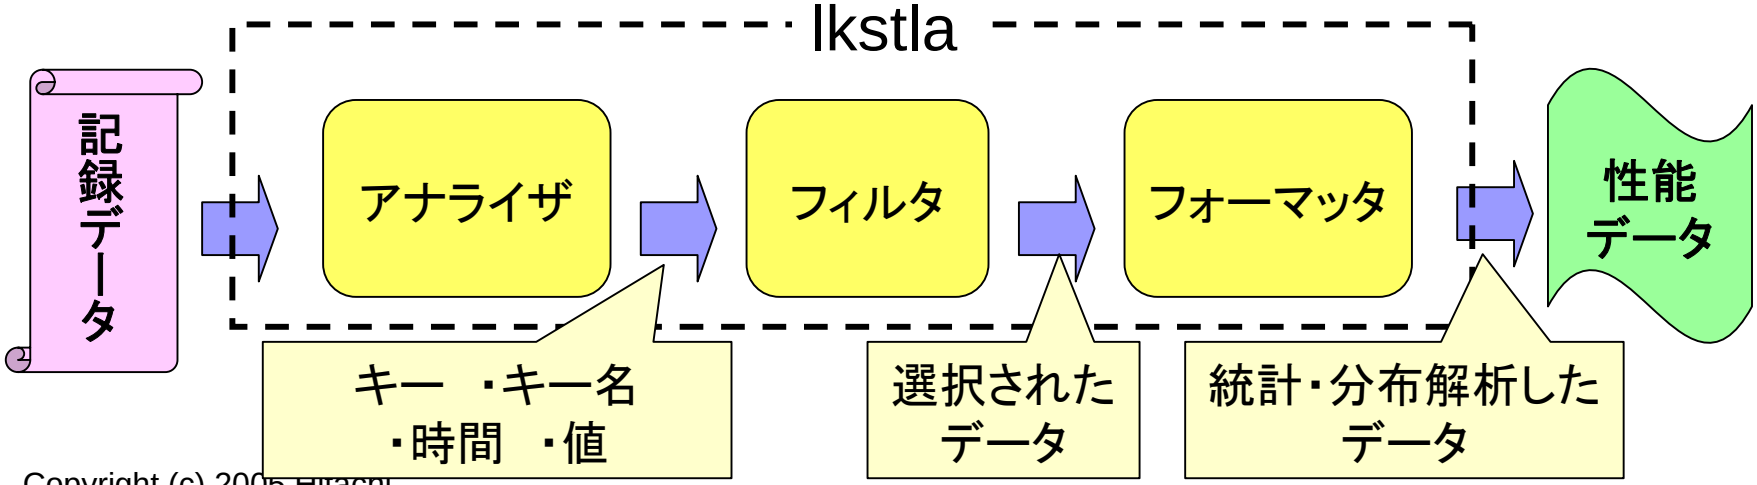

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

可視化ツール

- lkst_plot_log/lkst_plot_dist/lkst_plot_stat
  - lkstlaの解析結果をpdfにしてプロット

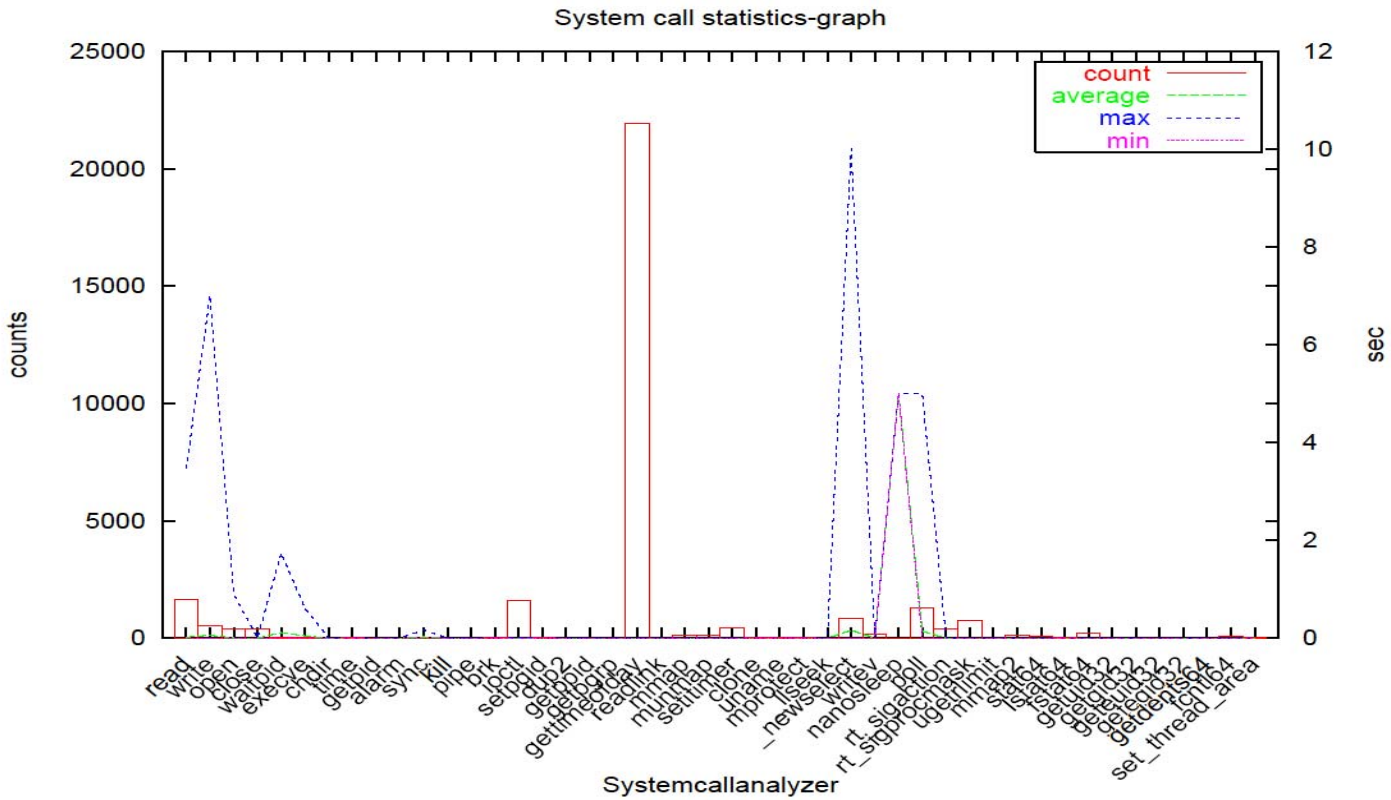

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

使い方

- デモ
  - マスクセットによる記録設定
  - バッファからのデータ保存
  - lkstlaによるデータの解析
  - lkst_plot_statを使ったデータの表示

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

IOボトルネック解析例

- Iozoneベンチマークによる MIRACLE LINUX の性能評価
- OProfileを使ったボトルネック箇所の特定
- LKST Log Toolsを使ったボトルネック解析

※ミラクル・リナックス社発表の資料に基づく

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

IOボトルネック測定

- 目的
  - システムの限界性能調査
  - ボトルネックの発見と原因解析
- Iozone
  - ファイルIO性能測定ベンチマーク
    - 並列化処理（プロセス / スレッド）
    - IO方法（read/write/random/mmap/etc.）
    - 同期方式（通常(非同期) / O_SYNC(同期)）
    - 処理ディスク数　1～4
    - 処理プロセス数　1～4

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

測定対象

- PCサーバ
  - Dual Xeon (Hyper-Threading)
    - 論理CPU数：4個
  - 6GBメモリ
  - SCSIドライブ
- ディストリビューション
  - MIRACLE LINUX V3.0
    - カーネル2.4ベース
- ファイルシステム
  - Ext3ファイルシステム
    - 事実上、Linuxの標準ファイルシステム

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

ベンチマーク環境構成

- ディスクコントローラ
  - Ultra320 SCSI
- SCSI　HDD
  - 1～4台使用
  - システムHDDと別
  - テストパターンによって増減

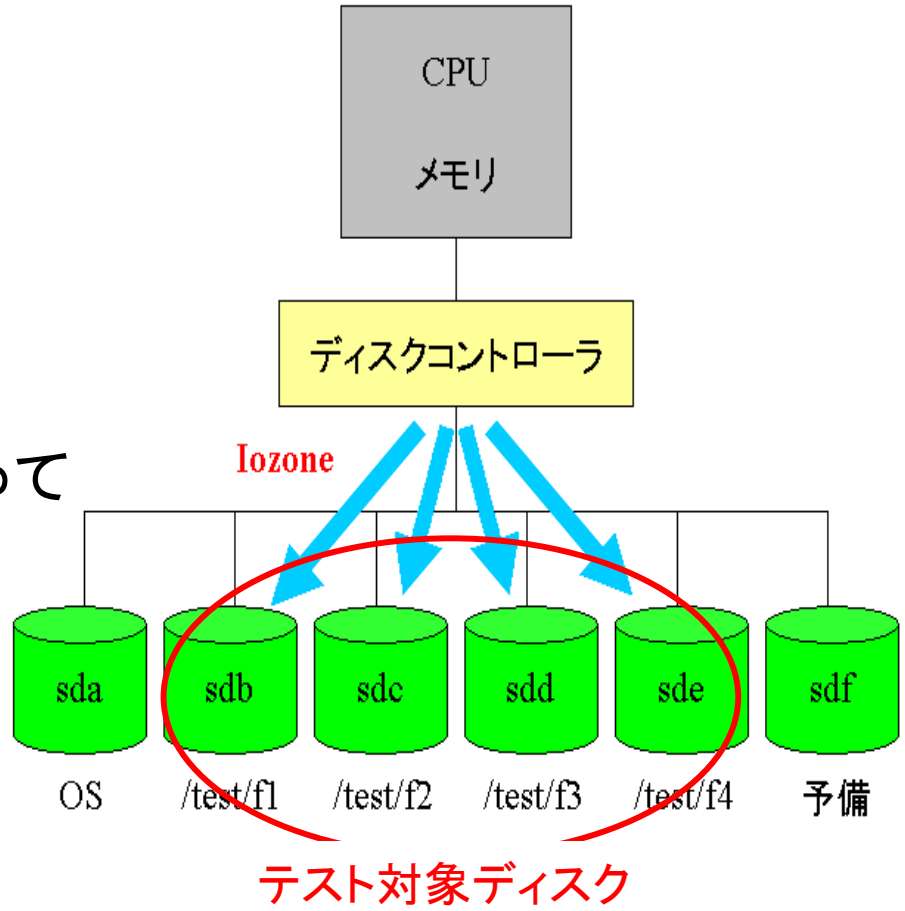

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

ベンチマーク結果

- writeスループット測定結果

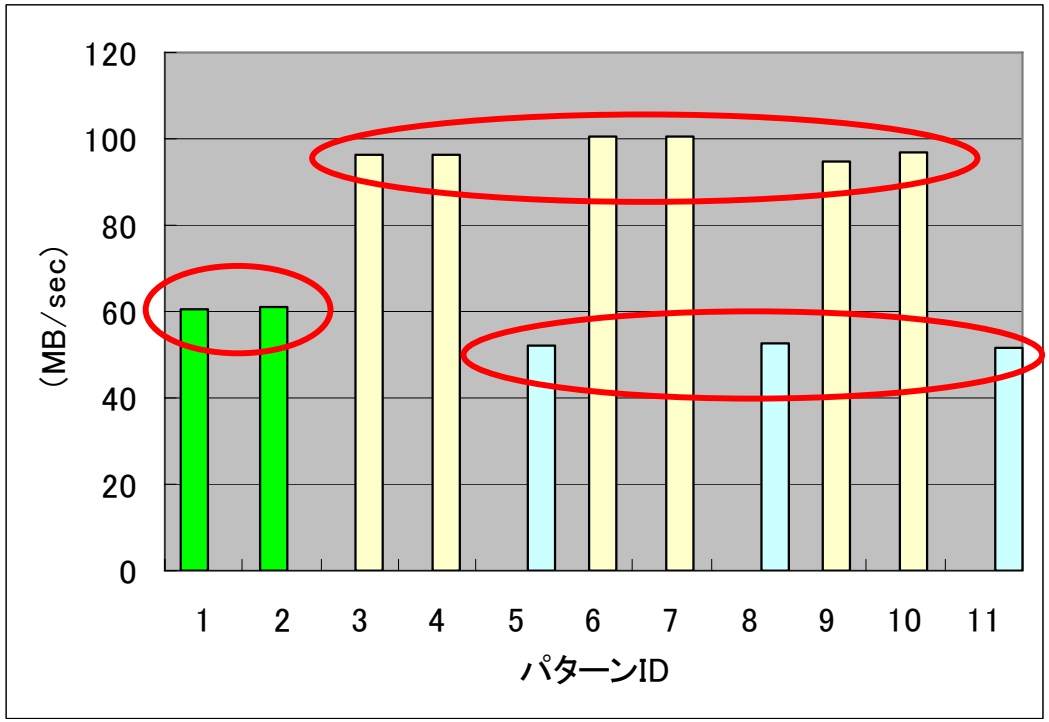

グループA:
CPU使用率が**高い**
最大スループット

グループB:
CPU利用率が**低い**
低いスループット

グループC:
CPU利用率が**高い**
最低スループット

→グループBとCにおいて性能が劣化した原因を探る

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

Iozoneパラメータ

パターンID	ファイルサイズ	使用ディスク数	スレッド使用	Iozoneコマンド数
1	8G	1	×	1
2	8G	1	○	1
3	4G	2	×	1
4	4G	2	○	1
5	4G	2	×	2
6	2731M	3	×	1
7	2731M	3	○	1
8	2731M	3	×	3
9	2G	4	×	1
10	2G	4	○	1
11	2G	4	×	4

グループB
グループA
グループC

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

解析手順

- ボトルネック解析の手順
  1. プロファイリングによる大まかな絞り込み
     - OProfile(*)を利用
  2. LKSTを用いて詳細なデータを取得
  3. LKSTLogToolsを用いてデータを解析
  4. 解析結果からの考察

* OProfile：
サンプリングベースのプロファイリングツール
設定したサンプリング間隔での実行箇所の特定を行う

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

OProfileによる解析

- グループBにおける実行箇所の絞り込み

順位	関数	カウント	占有率	累積占有率
1	default_idle	1,993	24.37	24.37
2	try_to_free_buffers	532	6.504	30.87
3	launder_page	532	6.504	37.38

アドレス	サンプル数	default_idle内占有率	命令
0xc0109254	3	0.1505	je 0x0109280
0xc0109260	1	0.05018	movl 0x14(%edx),%eax
0xc0109268	1945	97.59	hlt
0xc0109269	44	2.208	ret

hlt命令が多くサンプリングされている→**OSの待ち時間が多い**

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループBの解析(2)

LKSTによるIO処理の解析(1)

- 待ち時間処理→IO処理
  - IO処理時間をLKSTで解析

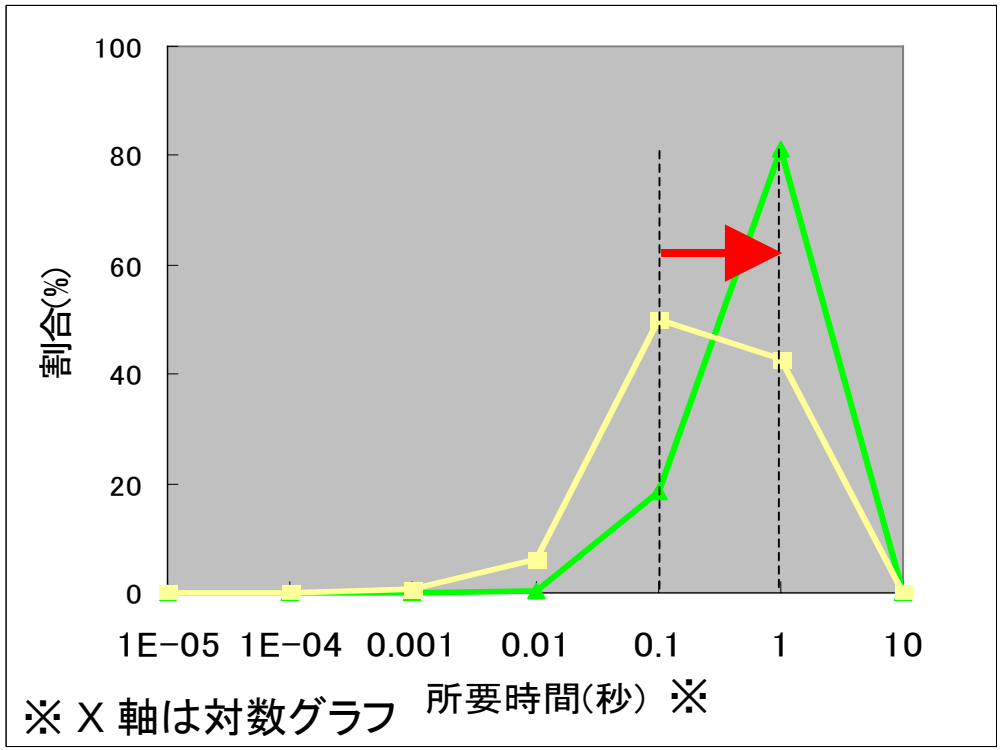

→グループBのIO処理時間がグループAより**一桁大きい**ところに**ピーク**がある

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループBの解析(3)

LKSTによるIO処理の解析(2)

- IOリクエストキューの長さをLKSTで解析

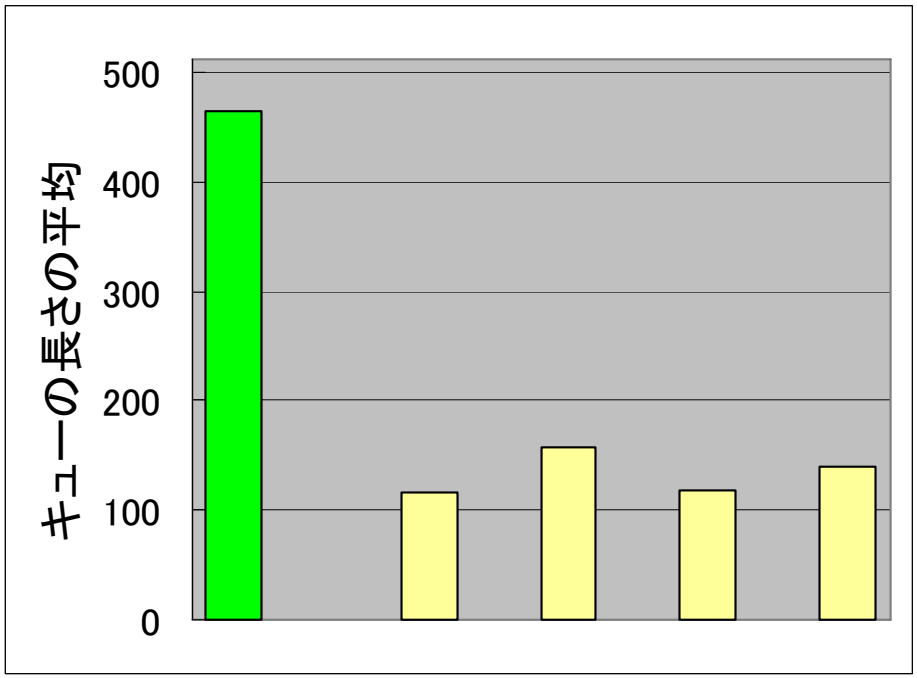

→グループBの**キューの長さがほとんど限界値**(=512)

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループBの解析結果

- Oprofileによる解析
  - hlt命令が多い
- LKSTによるIOリクエストキューの解析

→ディスクが少ない

→並列処理が出来ず、キューが長くなる

→IO処理が遅い

→CPU処理に空き時間発生→hlt命令実行

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

OProfileによる解析

- グループCにおける実行箇所の絞り込み

順位	関数	サンプル数	占有率(%)	累積占有率(%)
1	.text.lock.ioctl	10,310	28.74	28.74
2	.text.lock.buffer	8,257	23.02	51.76
3	default_idle	2,166	6.038	57.80
4	do_generic_file_write	2,048	5.709	63.50

ビジーウェイト処理が多くサンプリングされている→**ロックに問題**

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

ビジーウェイト処理とは（1）

- 通常のロック待ち処理
  - 例）セマフォ、mutexなど

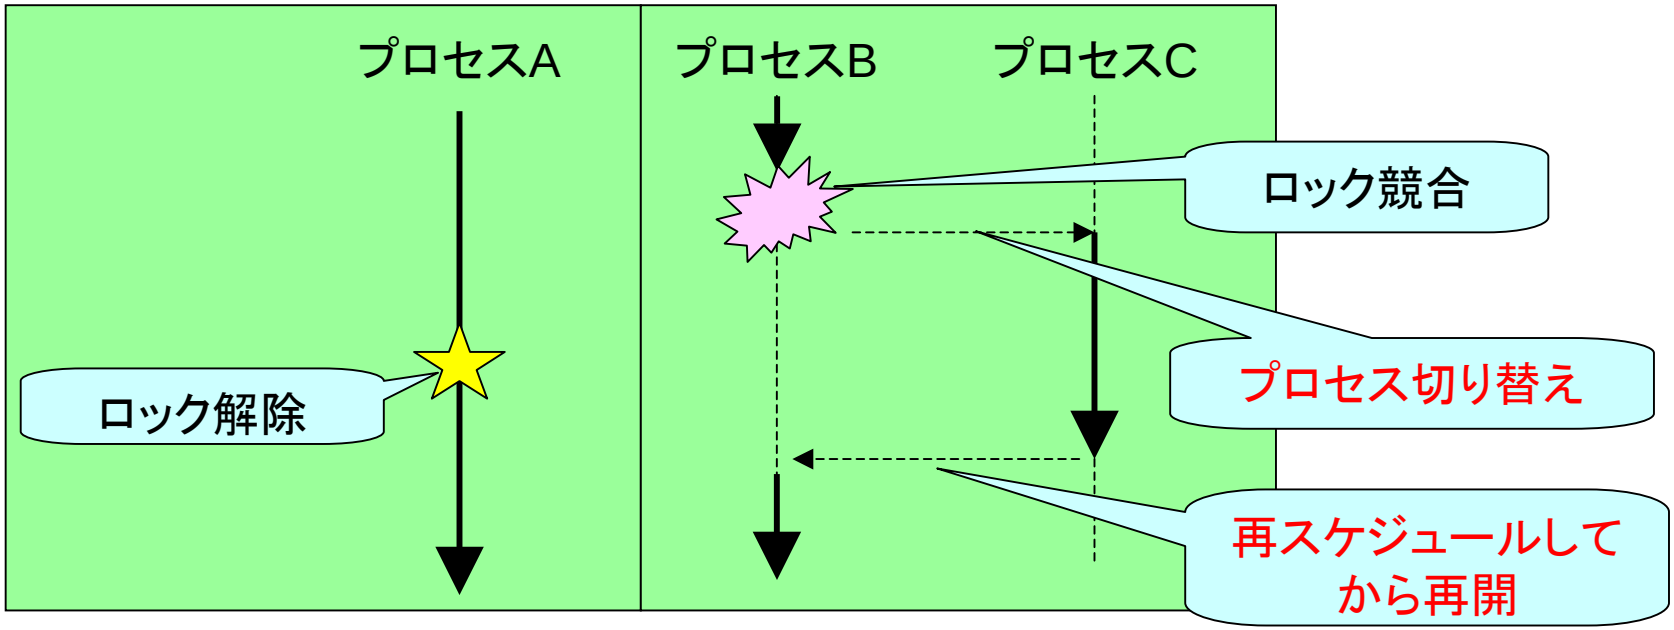

プロセス切り替えを行う→**CPU処理時間を無駄にしない**

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

ビジーウェイト処理とは（2）

- ビジーウェイト処理
  - 例）カーネル内スピンロック

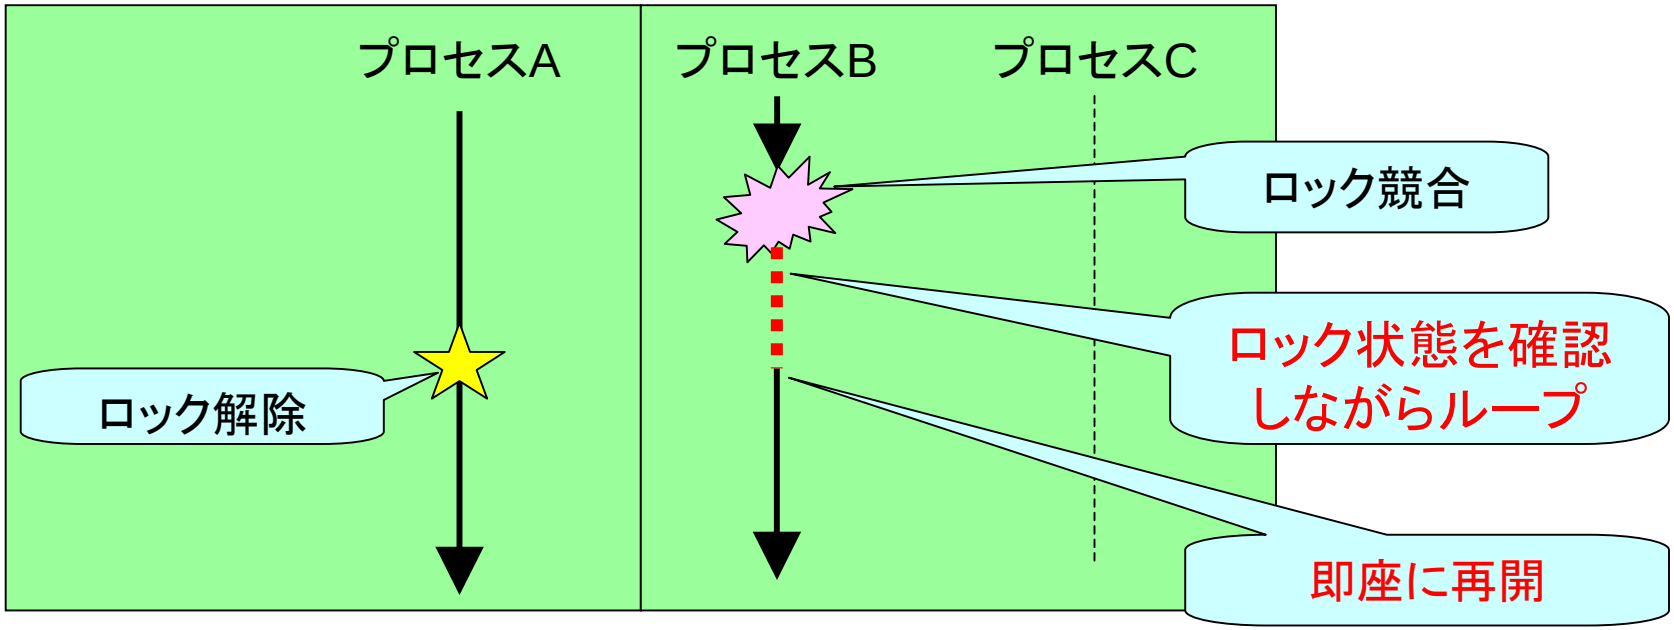

プロセスを切り替えずに待つ→**CPU処理時間が無駄になる**

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループCの解析(2)

LKSTによるビジーウェイト解析(1)

- ビジーウェイト処理時間をLKSTで解析

順位	アドレス	回数	平均(秒)	最大(秒)	合計(秒)	割合(%)
1	0xc019f83e	85	0.3777	16.14	32.1	41.1
2	0xc01977d1	1,028	0.02984	15.51	30.7	39.3
3	0xc018ad07	4	3.786	15.14	15.1	19.4
4	0xf8863ba3	61,477	1.8E-07	2.49E-05	0.0111	0.0142
5	0xf88637bb	61,476	1.79E-07	7.42E-06	0.0110	0.0141

全ビジーウェイト処理の99.8%が3箇所に集中

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループCの解析(3)

LKSTによるビジーウェイト解析(2)

- ビジーウェイト処理時間の分散を見る

アドレス	～1マイクロ秒	～10マイクロ秒	～100マイクロ秒	～1ミリ秒	～10ミリ秒	～100ミリ秒	～1秒	～10秒	10秒以上
0xc019f83e	82	1	0	0	0	0	0	0	2
0xc01977d1	963	48	11	3	1	0	0	0	2
0xc018ad07	2	1	0	0	0	0	0	0	1

非常に長いビジーウェイトが何度かおきている

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

グループCの解析結果

- Oprofileによる解析
  - グローバルカーネルロックのサンプリング頻度が高い→ロック回数が多い or ロック時間が長い
- LKST
  - 実際に10秒以上のビジーウェイト処理の発生を確認→ロック時間が長い

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

LKSTのオーバヘッド(kernel build)

- 評価環境
  - Pentium4 Xeon 2.8GHz (L2:1MB) (Hyper Threading有効)
  - Memory: 4GB
  - Linux 2.6.9+LKST 2.2.1 on Fedora Core 2

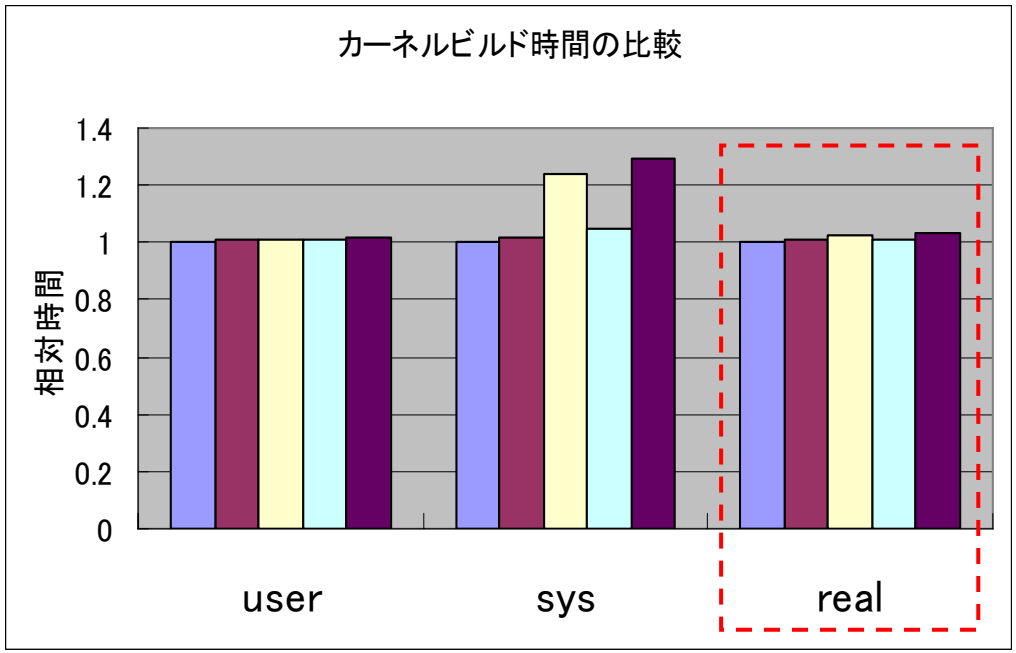

(測定環境:IPA提供)

アプリケーション実実行性能(real)への影響は0.5~3.5%程度

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

まとめ

- まとめ
  - LKSTを使用した性能評価機能の開発
    - LKSTの機能を拡張し、ログから性能情報を解析する機能を開発
  - OProfileとLKSTを連携したカーネルボトルネックの解析
    - IO高負荷時のカーネル処理のボトルネックを解析
- 今後の予定
  - LKST
    - サンプリング機能をつけるなどして、収集情報の増加を抑えたい
    - lkstlaを強化し、解析できるイベントを追加したい
- 関連URL

  OSS推進フォーラム http://www.ipa.go.jp/software/open/forum/
  LKST http://lkst.sourceforge.jp/
  Iozone http://www.iozone.org/
  OProfile http://oprofile.sourceforge.net/news/

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

商標

- Linuxは、Linus Torvaldsの米国およびその他の国における登録商標あるいは商標です。
- MIRACLE LINUXはミラクル・リナックス株式会社が使用権許諾を受けている登録商標です。
- Intel, Intel Xeon, Pentium は、アメリカ合衆国およびその他の国におけるインテル コーポレーションまたはその子会社の商標または登録商標です。
- その他の記載されている社名および製品名は各社の登録商標また商標です。

その他

- この発表内容は「独立行政法人 情報処理推進機構 オープンソースソフトウェア活用基盤整備事業」に係る委託業務の調査・開発に基づくものです。

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

Happy Evaluating!

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.

補足:ビジーウェイトプロセスの解析

- ロックプロセスの特定

時刻	cpu	コマンド名	lock/unlock	関数
10:59:59.109884679	0	kdm_greet	lock	
10:59:59.109884823	0	kdm_greet	unlock	
11:00:15.543851385	3	iozone	unlock	schedule()
11:00:15.543853871	1	crond	lock	permission()
11:00:15.543862258	1	crond	unlock	

約15秒もの間ビジーウェイト状態にあった

→Iozoneプロセスが他のアプリケーションの動作を邪魔していた
→スループット低下の原因？

Copyright (c) 2005 Hitachi, Ltd., All Rights Reserved.