Linux 障害解析の状況と今後の展望

Oct.15, 2004

NTT Data 先端技術株式会社
鈴木幸市
koichi@intellilink.co.jp

エンタープライズ環境で Linux の利用を促進するうえで、カーネル障害解析は重要な位置を占める。カーネルダンプとしてはLKCD や NetDump が知られているが、より高い確実性、信頼性を目指した Linux カーネルダンプ取得ツールの提案もなされてきている。これらの動向について紹介する。

背景：なぜ障害解析？

- エンタープライズや政府機関での利用、ミッションクリティカルなアプリケーションへの適用の増大
  - 高信頼化、高可用性追求も重要であるが
  - 障害時の対応が非常に重要になりつつある
    - システム停止による社会的影響
    - 会社の信用問題

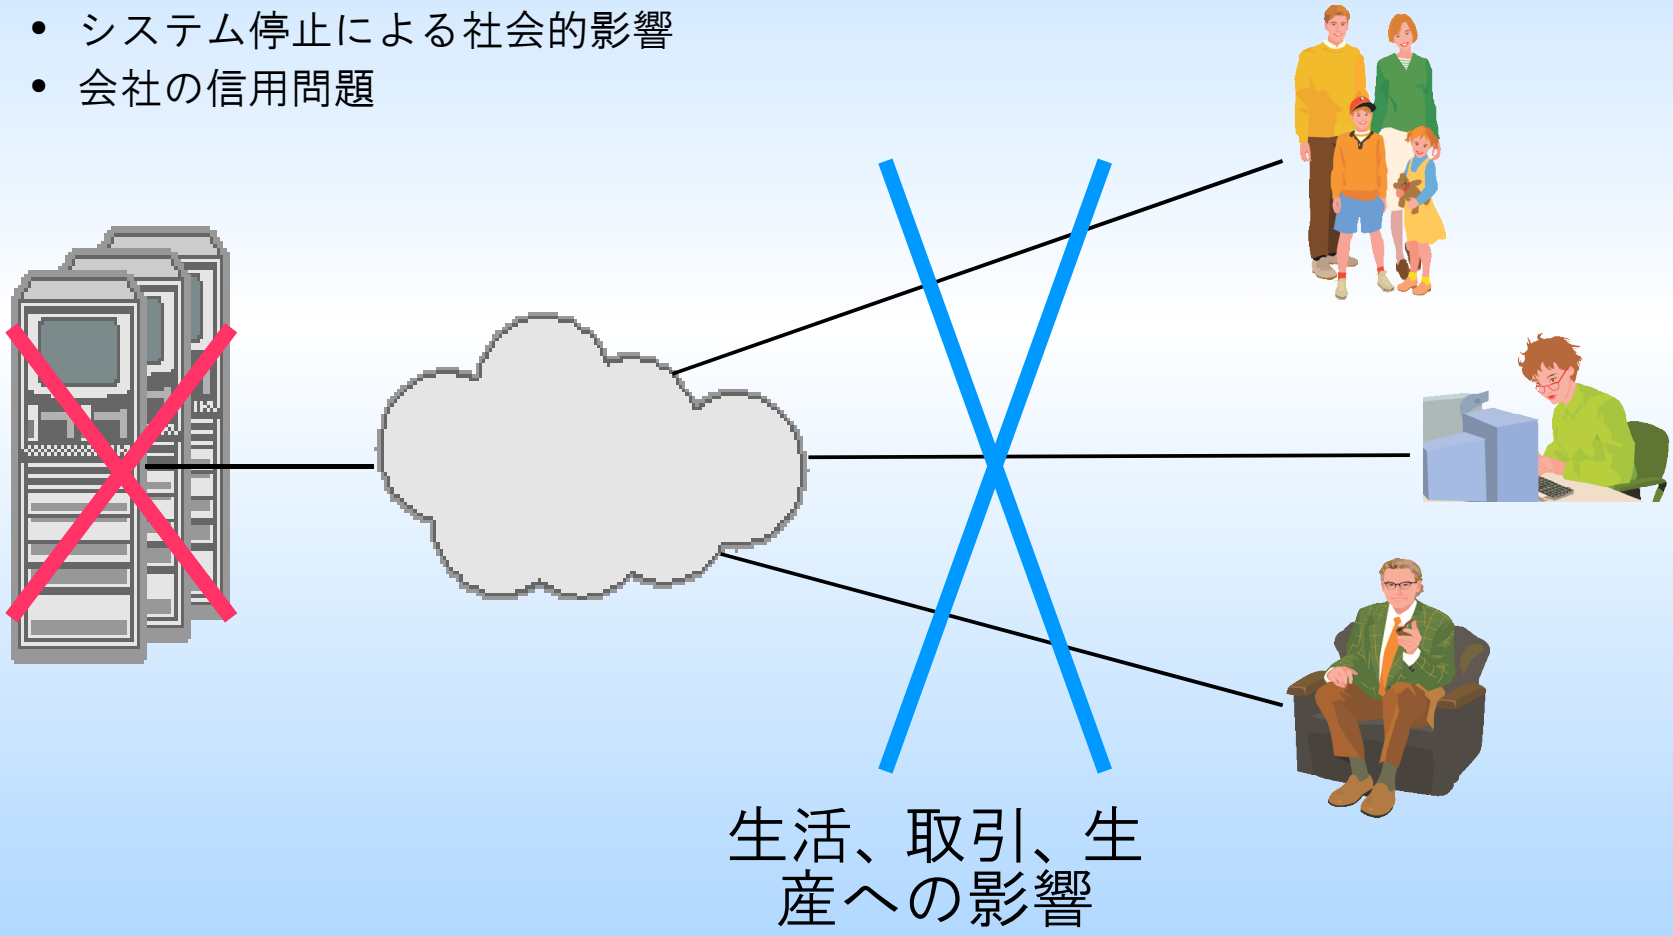

背景：なぜ障害解析？(cont.)

- システムが停止したら
  - リブートして動いただけでは対応は不十分
  - 障害原因と対策の説明責任
    - 障害解析が必須の機能
    - 今後同様な障害が起こらないようにどのような対策を講じるか
    - その対策は十分か
    - きちんと原因がわかっていることが大前提
    - ソフト障害でも緊急にバグがとれない場合、回避策を講じる必要がある
- システムが停止しなくとも
  - クラスタノードの障害など、システム全体は停止しないが部分的な障害はおこる
  - これらの不具合の原因を究明し、システム停止に至らないように対策を講じることが重要

背景：なぜ障害解析？(cont.)

障害

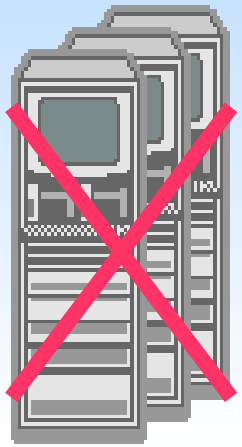

資料採取

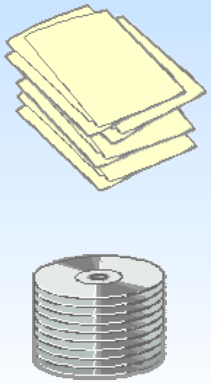

原因究明
対策

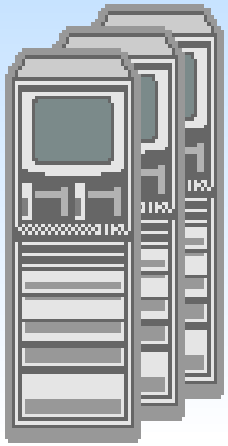

応急措置

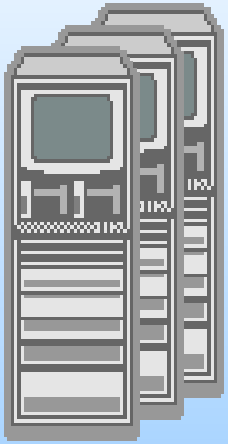

説明

カーネルは安定しているか？

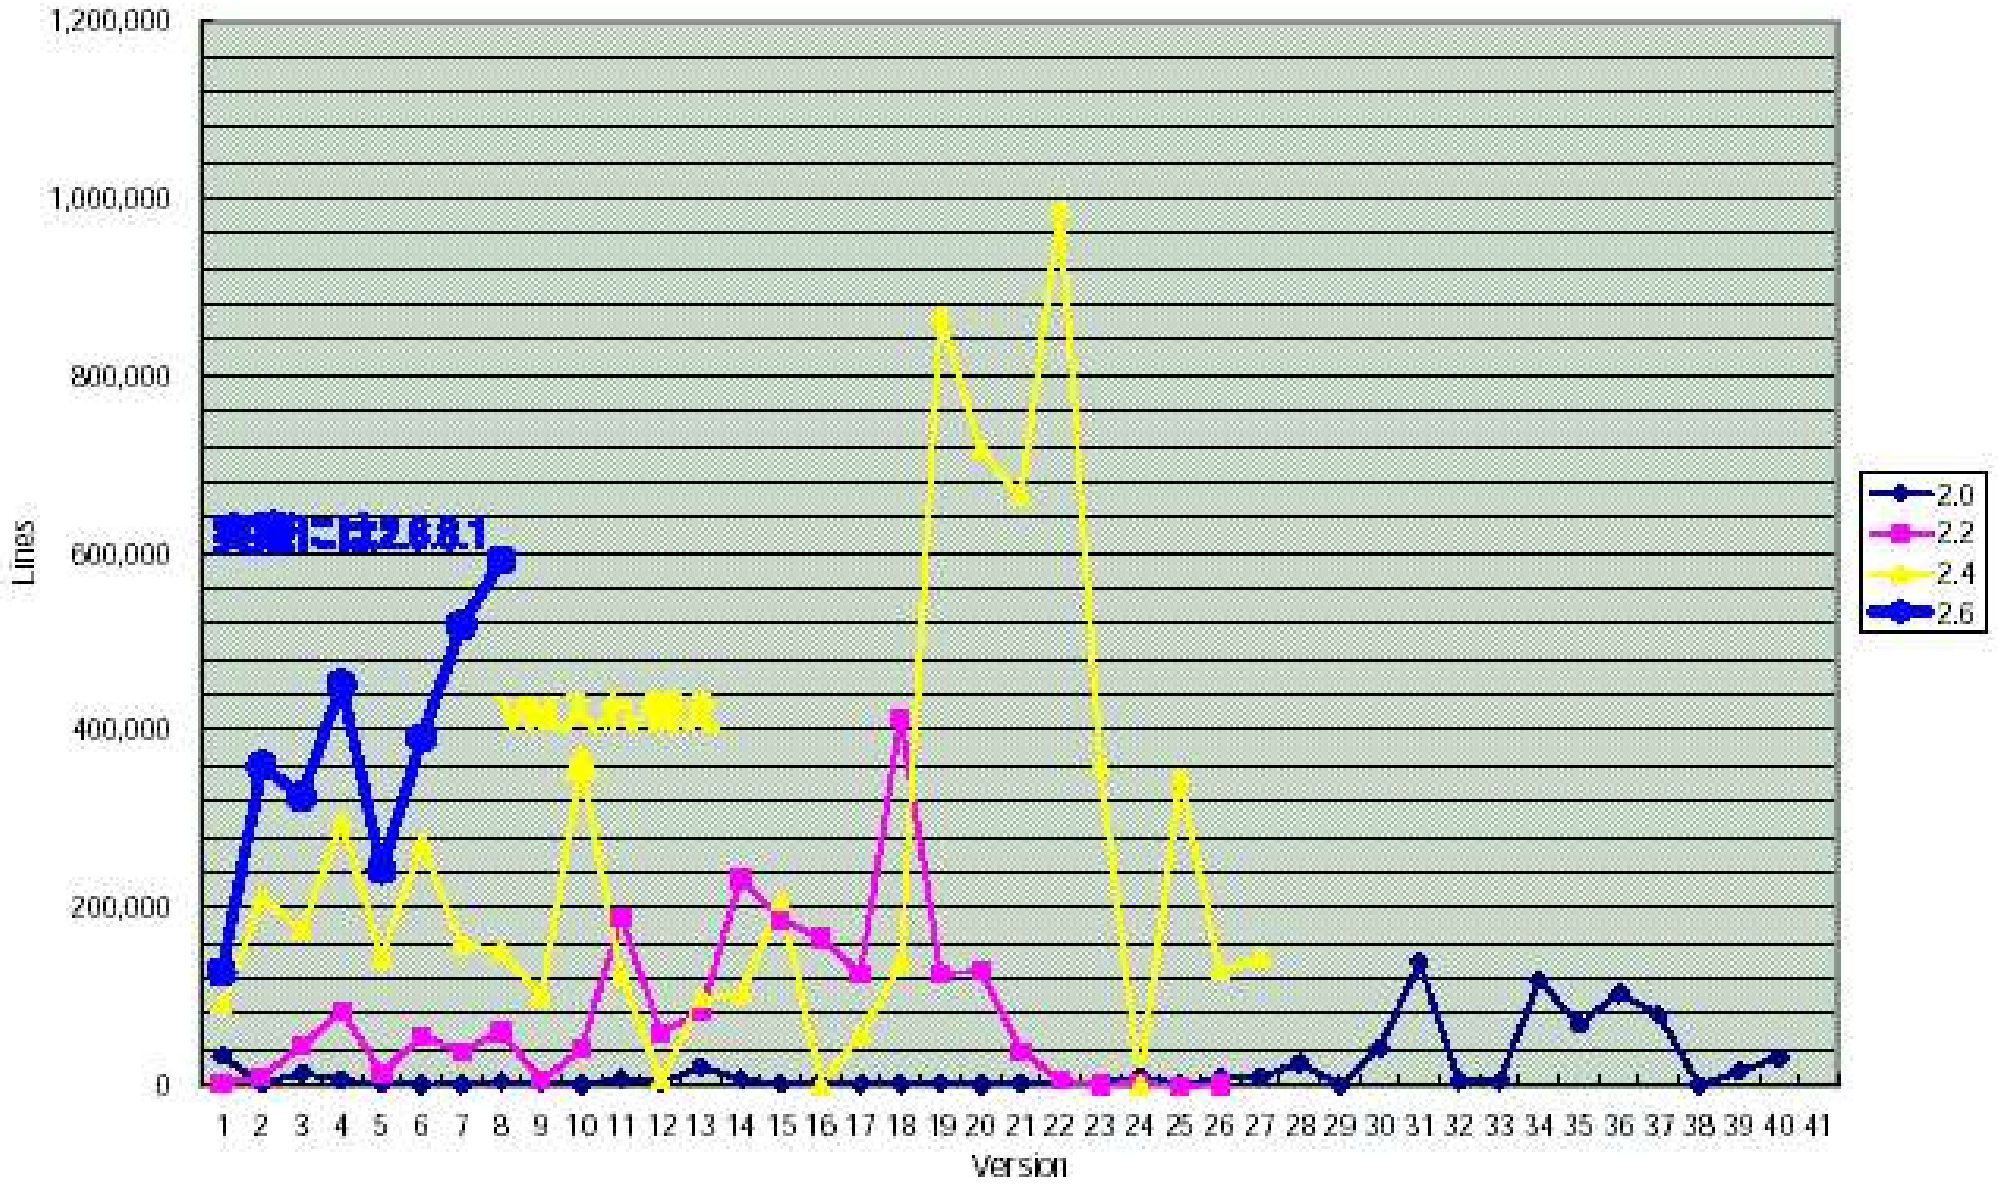

LINUX 故障解析の現状

- エンタープライズシステムでは、故障が発生した場合、原因を素早く特定し、迅速に対応することが求められている
- 障害を解析することによって
  - ハードとソフトの切り分け
  - カーネルとアプリケーションの切り分け

  を行わなければならない
- 原因の究明や切り分けのためには、カーネルのダンプやトレースデータが必須である
  - クラッシュダンプによる原因究明が有効
- しかし、ＬＩＮＵＸには標準でダンプ機能がない

LINUX 故障解析の現状

システム障害の事象例

- カーネルパニックが発生してシステムが停止する・・・しかし再現性がない
- システムが突然スローダウンし、果てにはハングする
- 方式検討を行い環境構築してみたが、どうも思ったような性能が出ない

- 原因特定の手段は？

- （カーネルが原因だと思われる場合） KDB や KGDB によるデバッグ
  - すぐさま再起動が必要な状況であるため、システムを止めて作業することはできない
  - たとえ可能だとしても、作業者がその場に赴いて全て解析するのは難しい
- 同じ環境を用意して、再現待ち　→　KDB 等で解析
  - 再現してくれるとは限らない
- ダンプ解析を行う
  - LINUX には標準でメモリダンプ機能がない
  - ダンプが取れない場合がある

カーネルダンプの取得

- カーネル自身がダンプをイニシエートする必要がある
  - マイクロカーネルのように、上位でカーネルの動作を制御する機構がない
  - ハードウェアサポートもない
    - メインフレーム等の LPAR を使うと外部でダンプがとれるが IA アーキテクチャのハードではこのようなものはほとんどない

  (絵を入れる)

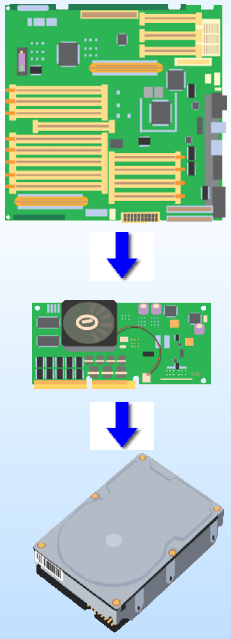

ハードウェアを用いた
カーネルダンプ

メインフレーム
など

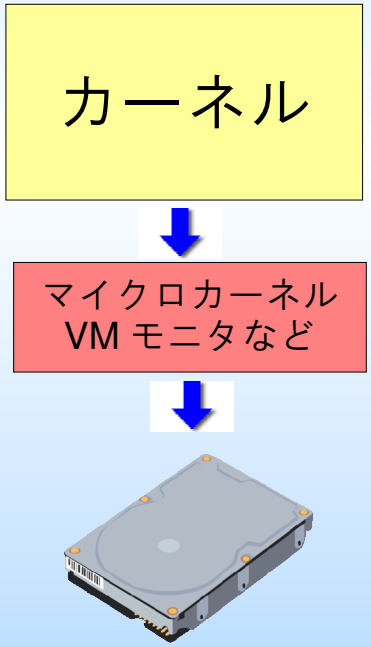

マイクロカーネル等に
よるカーネルダンプ

Mach, VMWare
など

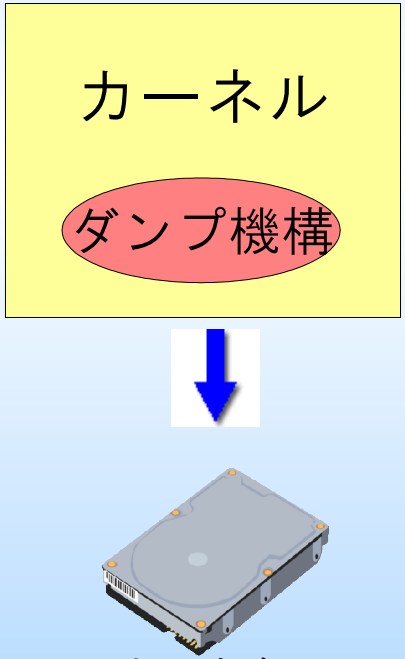

カーネル自身による
カーネルダンプ

ほとんどの Linux
実装

カーネルダンプの取得 (cont.)

- 信頼性のあるダンプをとる必要がある
  - ダンプ取得中にメモリの状態が変化してしまい、ダンプ内容の一貫性が失われないようにする必要がある
- 確実にダンプをとる必要がある
  - 障害が発生したがダンプが取れないケースは最小限にとどめる必要がある
- ユーザ空間の再現も必要である
  - アプリケーション起因で障害が発生するケースもある
  - メモリダンプと共に、スワップを保全しておけばユーザ空間の再現は可能

カーネルダンプ用既存ツール (1)

LKCD

- 最初に SGI が開発し、オープンソースとして公開したもの
- その後、IBM 、NEC 、日立、富士通共同で拡張を行った
- クラッシュダンプ採取のしくみと解析ツールからなる

長所

- 活動が活発である
- ディスクダンプ、ネットワークダンプ、メモリダンプと 3 つの手段がサポートされている。

短所

- ディスクダンプでデバイスがビジー (使用中) だとダンプが取れない
- ディスクダンプの場合、割り込み許可して処理するので、他の割り込みと同時に処理が行われる。そのため、資源の競合やダンプデータの不整合が起こり得る。

カーネルダンプ用既存ツール (2)

diskdump

- 富士通が開発したディスクダンプを実現する仕組み
- SCSI のポーリングモードを用い (割り込みは使わない) 、時サーバの HDD へダンプを採取

長所

•割り込みを用いず、ポーリングモードで書き込みを行うことで、ダンプ取得の確率が高まる

短所

•SCSI の最下位レイヤのドライバの修正が必要となる
•これらをコンパイルしてカーネルを再構築する必要がある

カーネル 2.6 での新しいカーネルダンプ取得技法 (1)

- クラッシュしたカーネルを用いたダンプ取得には確度、一貫性の限界がある。
  - クラッシュしたカーネルを使わずにダンプを取る
  - リブートして新しいカーネルを走らせようとすると、BIOS でダンプすべきメモリ内容が初期化されてしまう !!

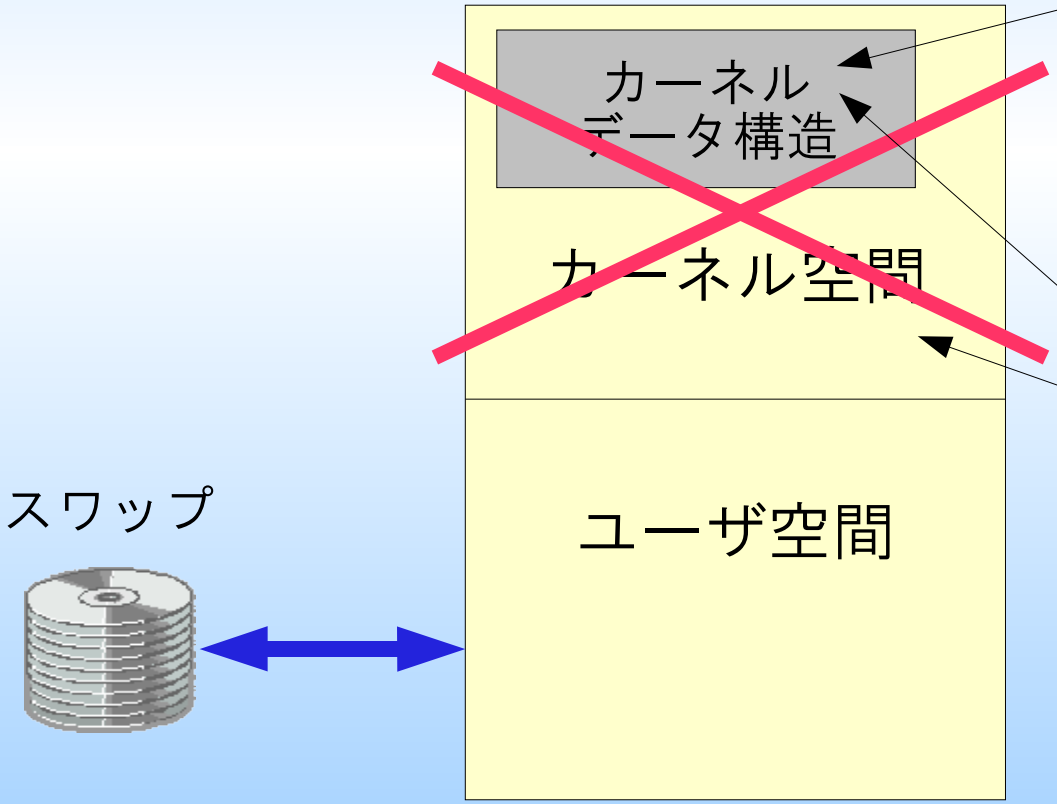

このデータ構造をそのまま使うと内容が破壊されていたりデッドロックを引き継いだりする可能性大

クラッシュしていてどう破壊されたのか定かでない

この部分を使ってダンプを取得しなければならない

カーネルがクラッシュしたということは ...

カーネル 2.6 での新しいカーネルダンプ取得技法 (2)

- カーネル 2.6 の新たな機能
  - Linux カーネルから別のカーネルをブートする内部関数の実装
    - kexec()
  - これを使えばクラッシュしたカーネルから別のカーネルを使ってダンプができる

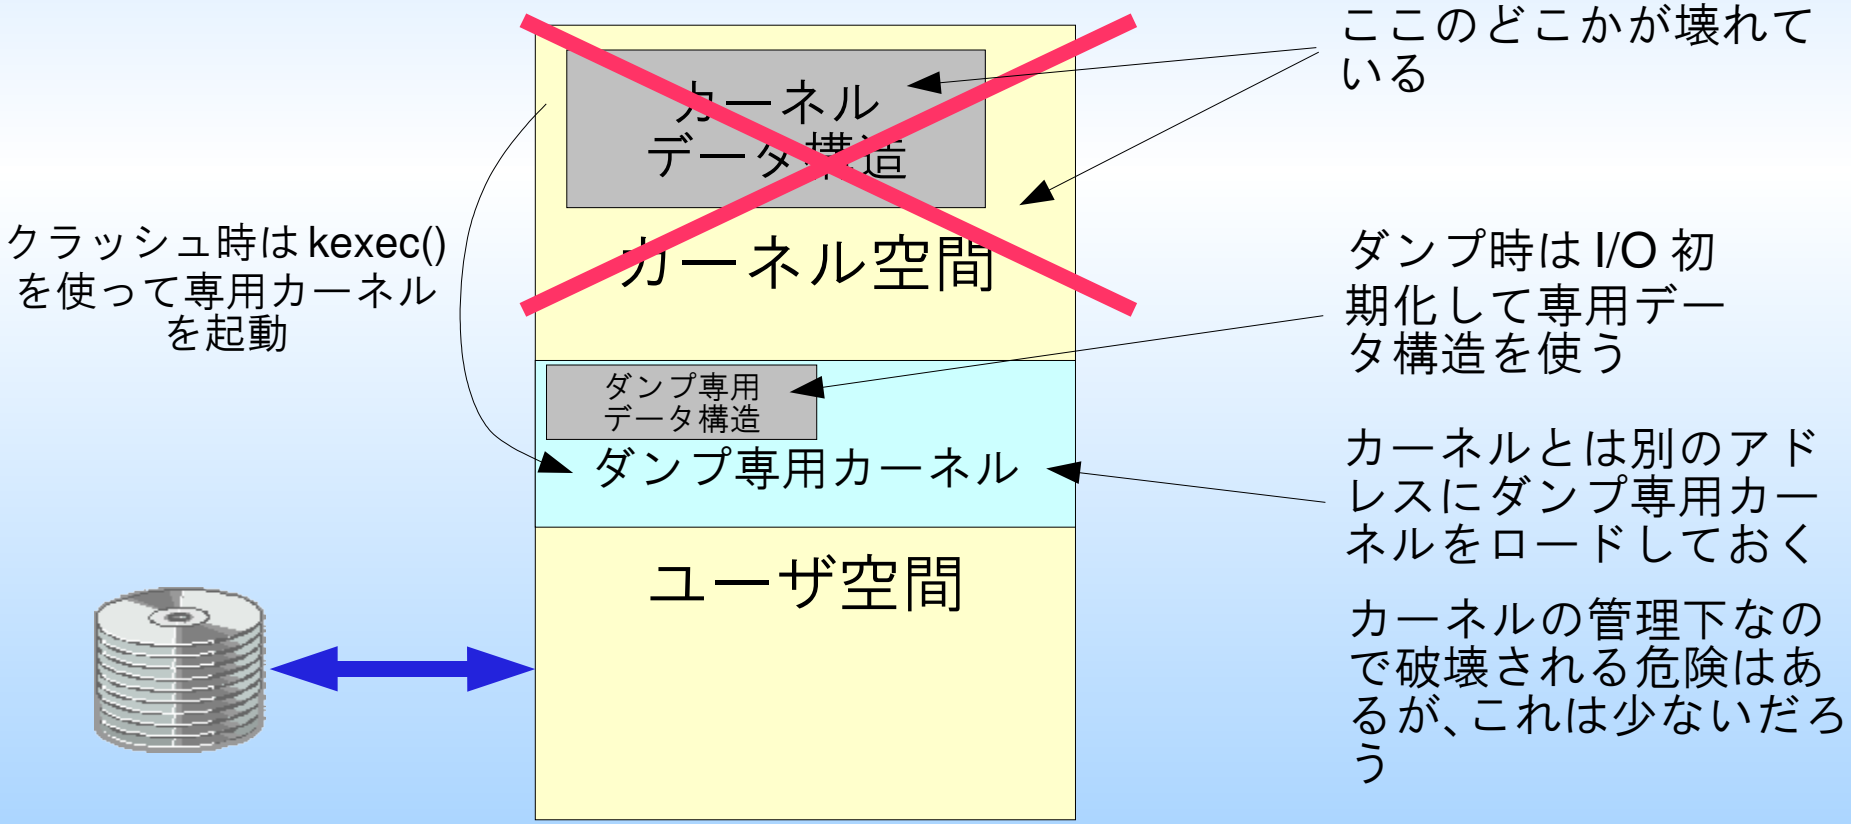

新しいカーネルダンプの実装例
IBM India Software Labs

Hariprasad Nellitheertha,
Linux Technology Center, ISL

- kexec() を介してダンプ専用カーネルを起動
- ダンプしたデータはローカルに /dev/oldmem デバイスに蓄積
  - /dev/mem 同様にメモリイメージでアクセス可能
  - /dev/oldmem デバイスはあらかじめ作成しておく

出典： The kexec Way to Lightweight Reliable System Crash Dumping,
Hariprasad Nellitheertha, Linux Technology Center, ISL, IBM

ダンプ取得のプロセス

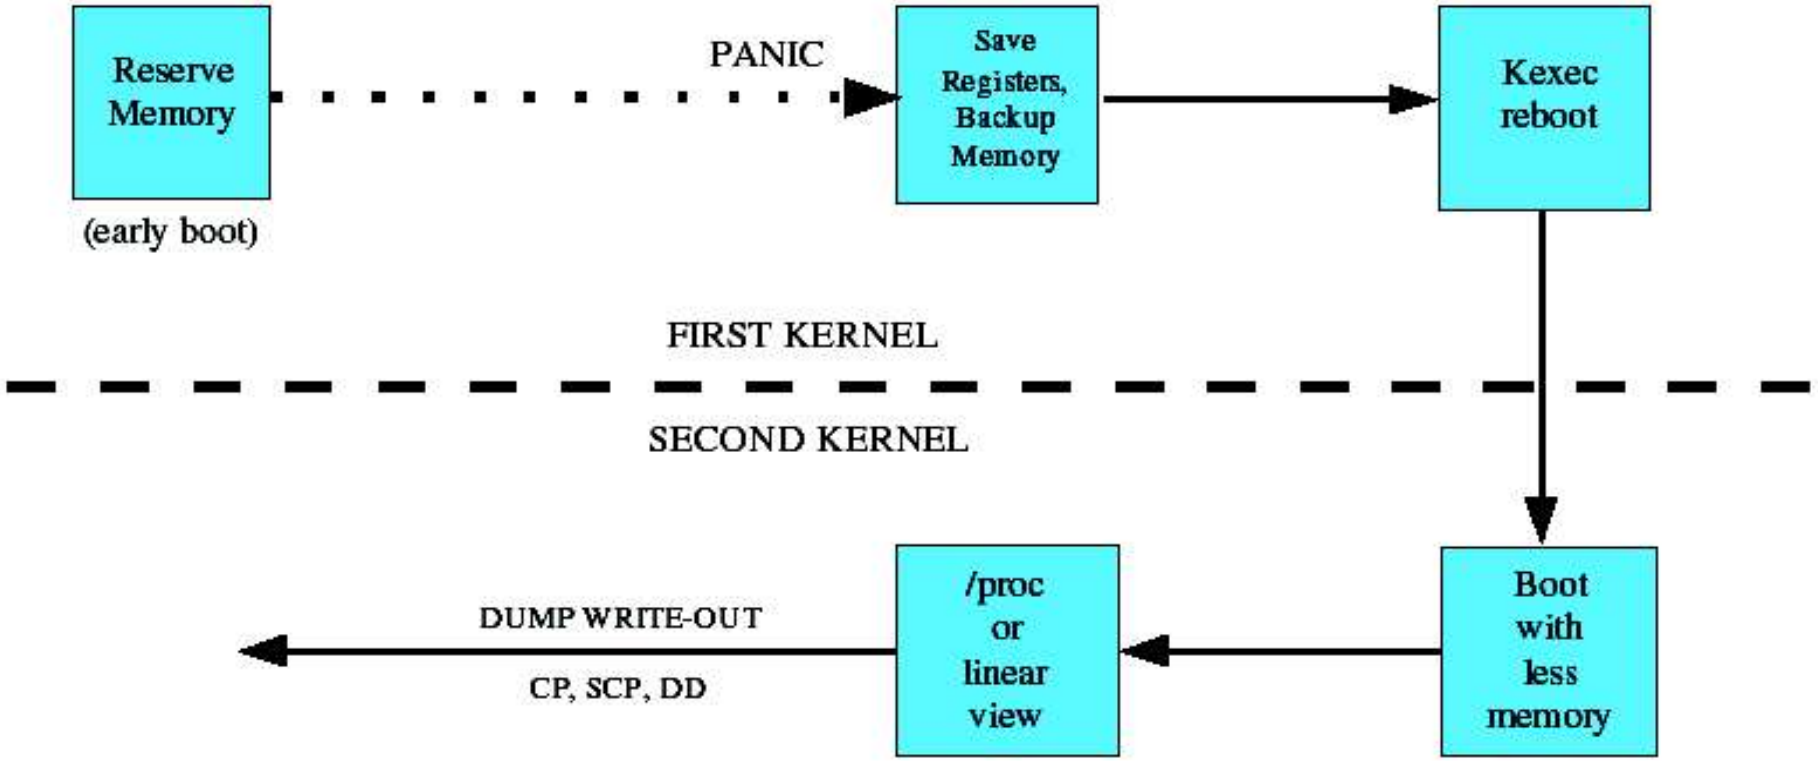

出典： The kexec Way to Lightweight Reliable System Crash Dumping, Hariprasad Nellitheertha, Linux Technology Center, ISL, IBM

kexec() 利用上の工夫

- kexec() は、古いカーネルを上書きしてしまう
- 上書きされる前にこの部分のメモリイメージを退避してからダンプ

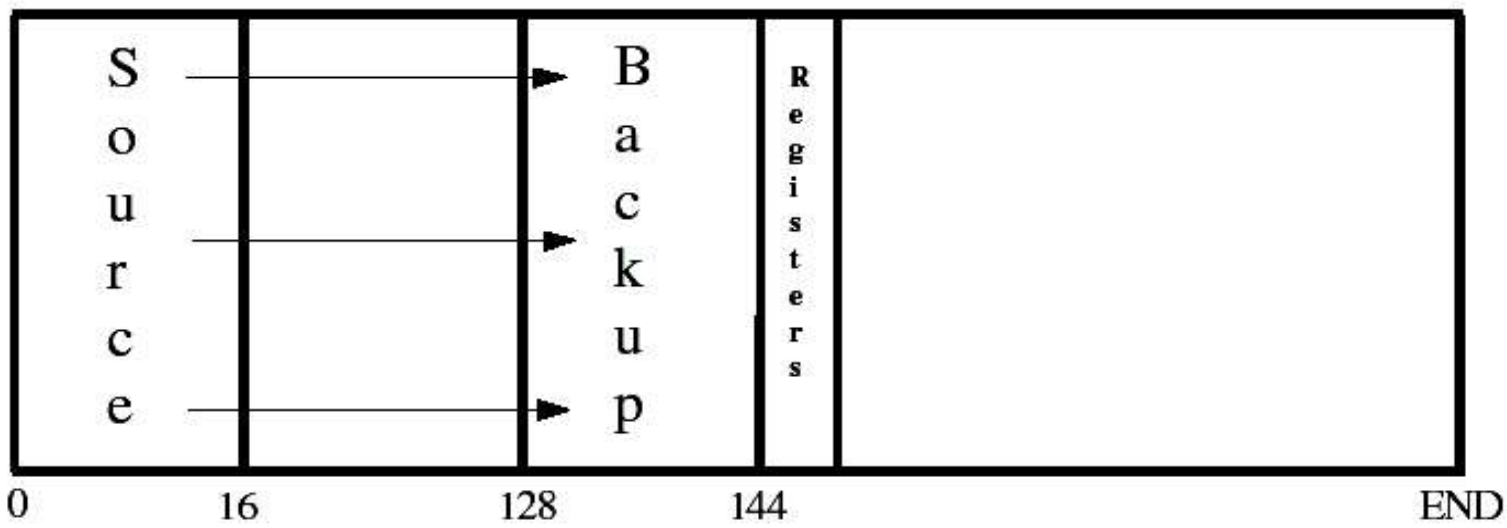

出典： The kexec Way to Lightweight Reliable System Crash Dumping, Hariprasad Nellitheertha, Linux Technology Center, ISL, IBM

kexec() を使ったもう一つのダンプ取得技法
Linaccident ダンプツール

NTT DATA & VA Linux Japan

- kexec() では古いカーネルイメージが上書きされる
  - 任意の場所にダンプミニカーネルをロードして起動できるように kexec() を変更 → mkexec()
- ダンプイメージは事前に設定したディスクパーティションに書き出す
- クラッシュしたカーネルのコードもデータ構造も用いない
  - 安全なミニカーネル内のコードとデータ構造で実行
  - ダンプ採取の確率向上
- ミニカーネルは、以下のコードをベースに開発
  - Linux カーネル
  - LKCD
  - kexec
- ミニカーネルにはダンプ処理と安全かつ必要最小限のドライバで構成
  - ドライバは Linux カーネルのものを使用
  - ミニカーネル内にロードされている
- カーネルダンプは lcrash(LKCD の解析ツール) を用いて解析

ダンプの取得 (1)

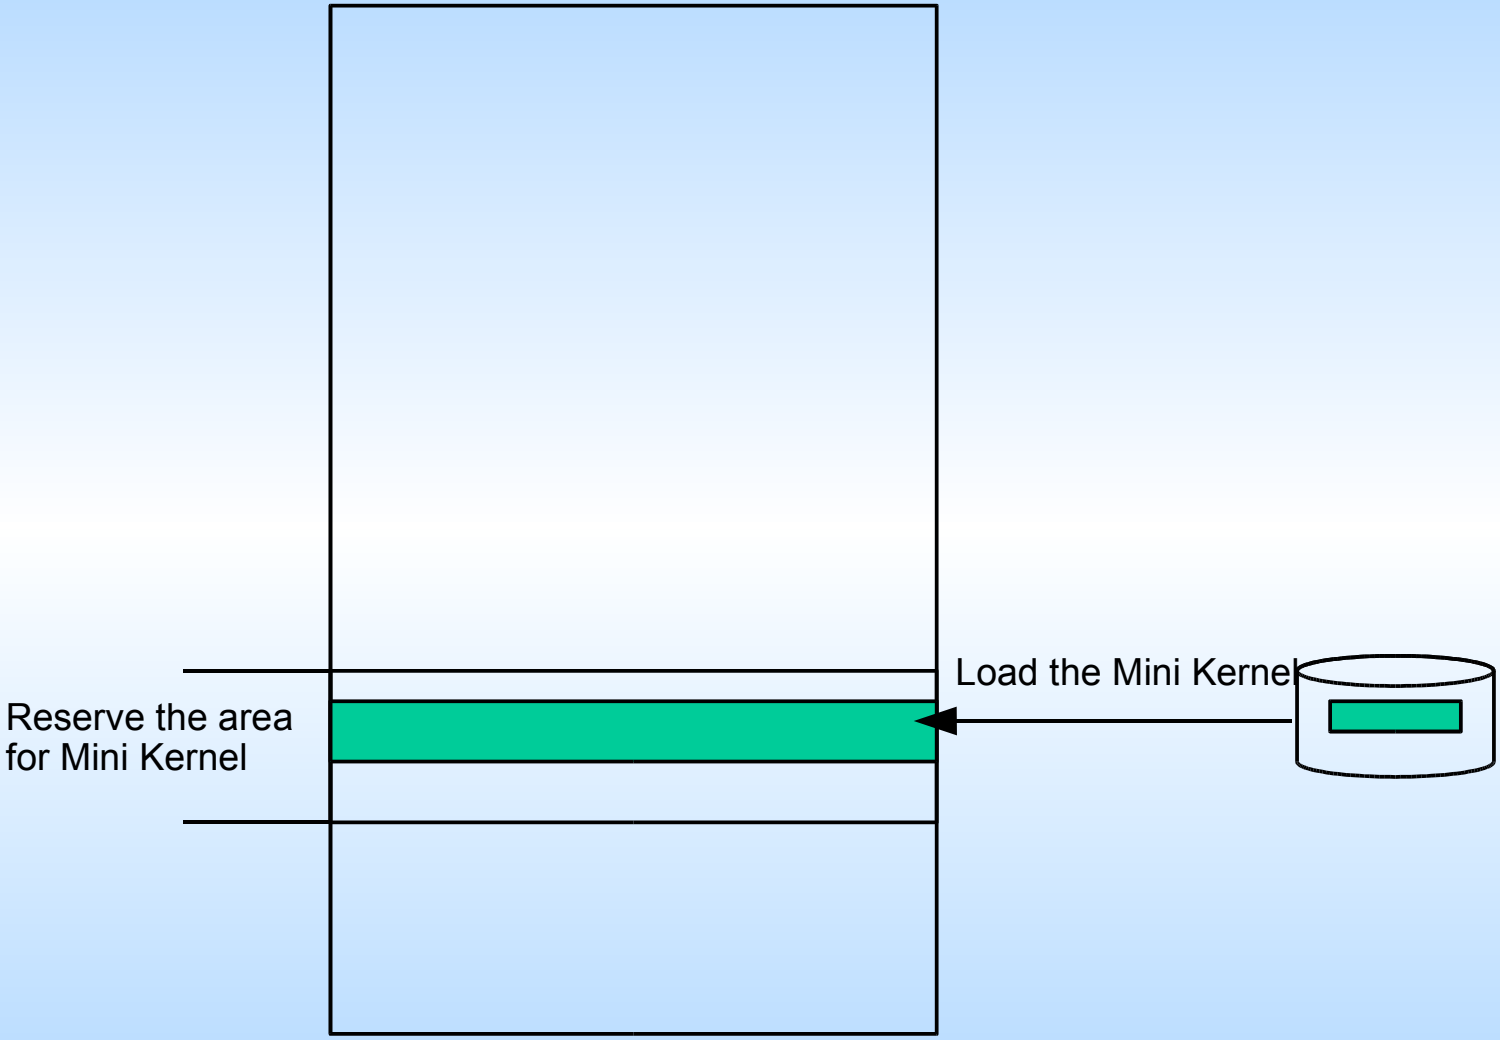

ダンプの取得 (2)

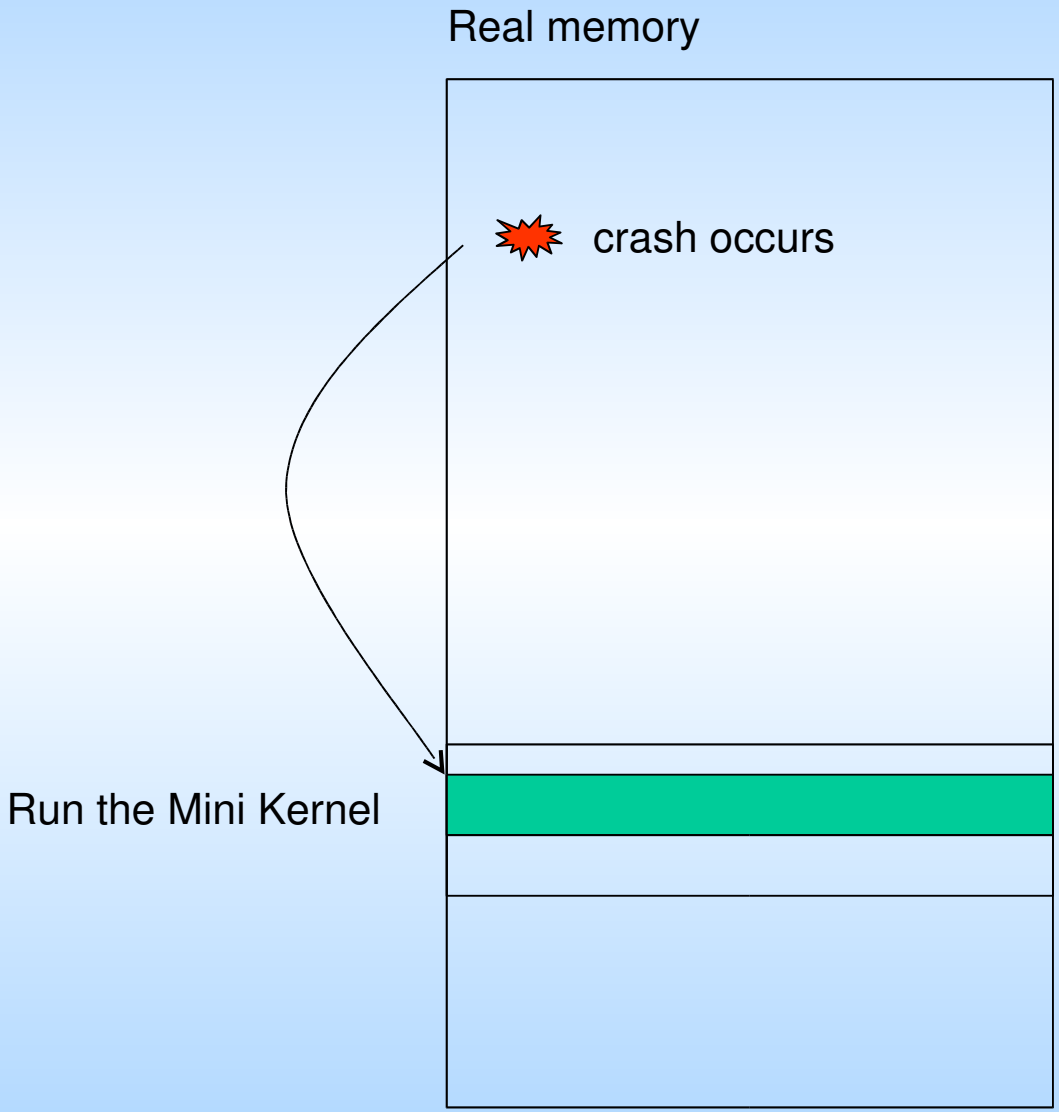

ダンプの取得 (3)

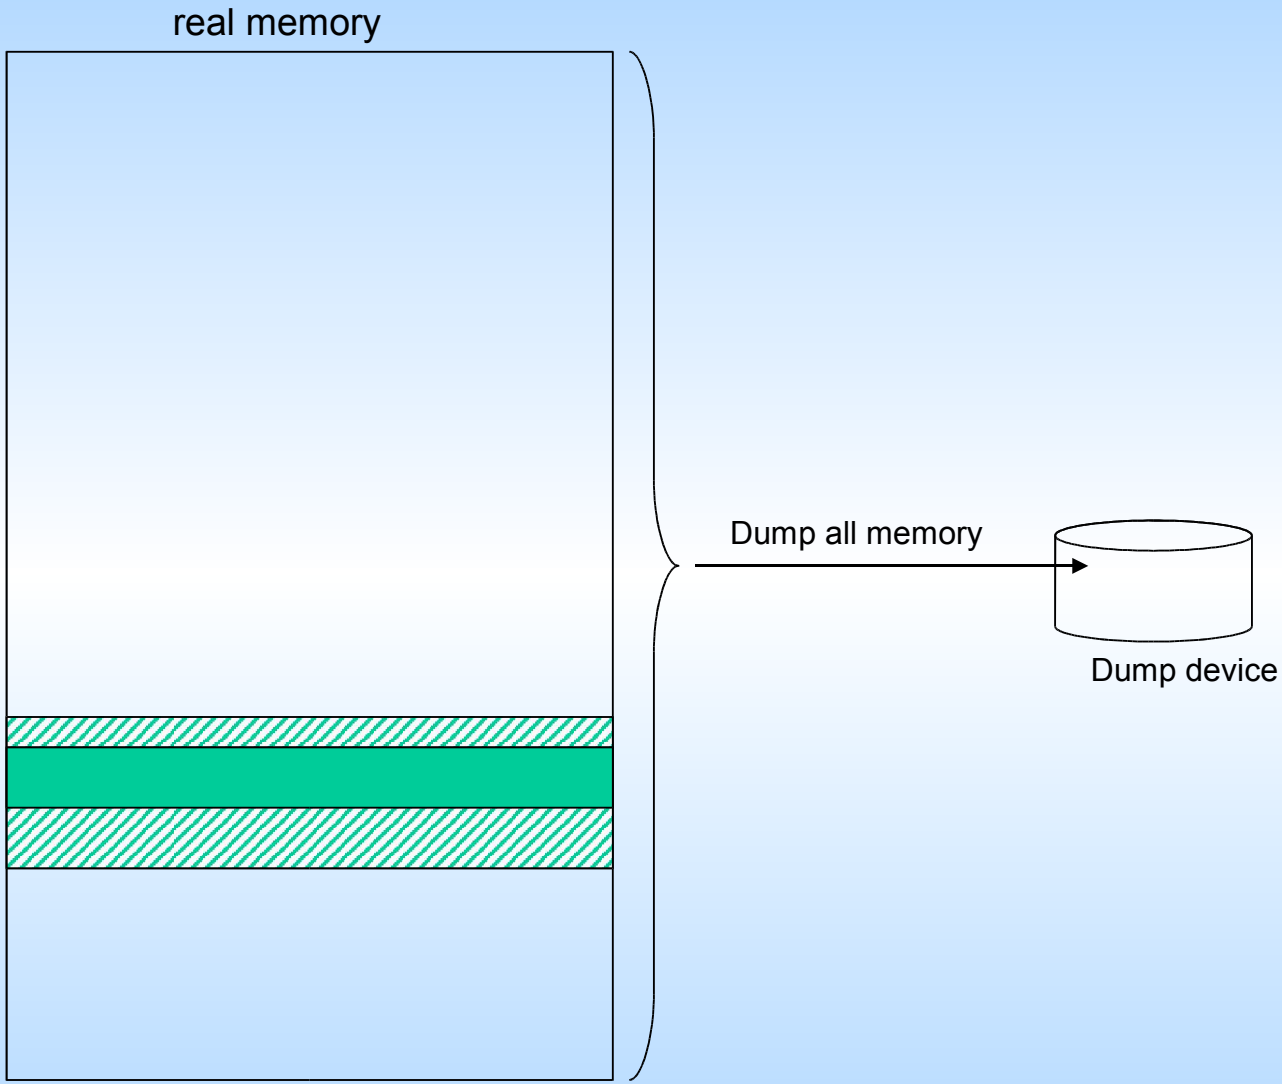

ダンプ手法の比較

		LKCD(disk)	Netdump / LKCD(net)	mcore / LKCD(mem)	diskdump	Linaccident
採取できる情報	実行コンテキスト	○	○	○	○	○
	メモリ	○	○	○	○	○
	キャッシュメモリ	×	×	×	×	×
	スワップ領域	×	×	×	×	○
確実性	資源のロック	×	△	○	△	○
	メモリ破壊時	△	△	△	△	○
採取の契機	panic / oops	○	○	○	○	○
	nmi_watchdog	○	○	○	○	○＋α
	手動	○	○	○	○	○
	nmi スイッチ	×	×	×	×	×
ライブダンプの可否		○	○	×	○	×（検討項目）

スワップと組み合わせたユーザ空間の再現と障害解析

各種解析資料

- ダンプファイル
- カーネル構造情報 (Kerntypes)
- カーネルイメージ
- スワップ領域ダンプファイル
- System.map （シンボルマップ）
- .config ファイル
- カーネルソース
- 共有ライブラリのバージョン

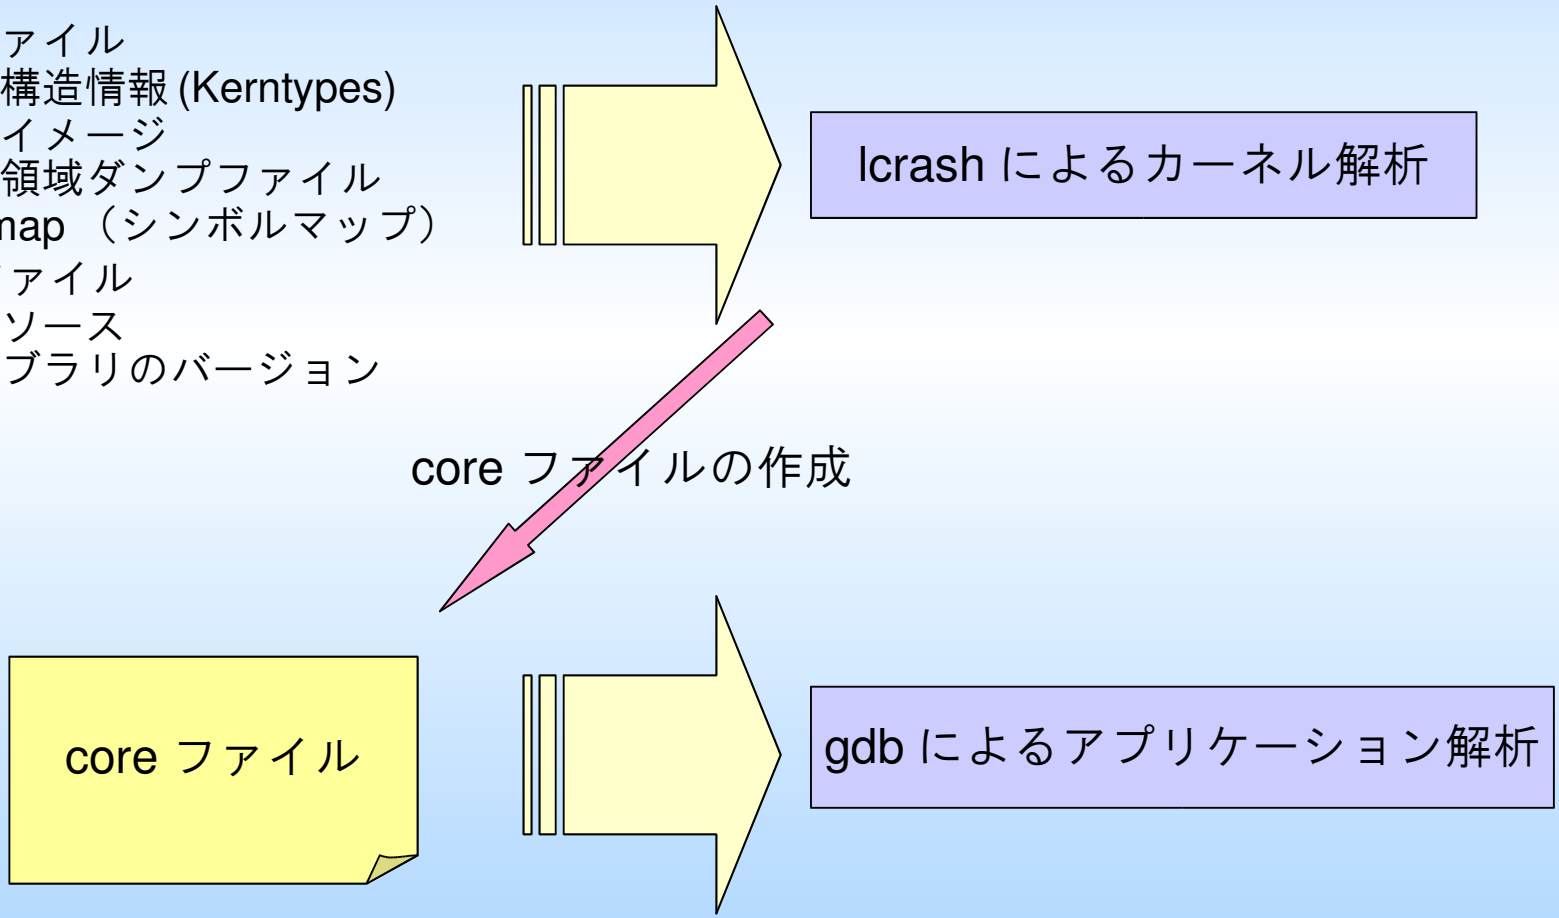

lcrash によるカーネル解析

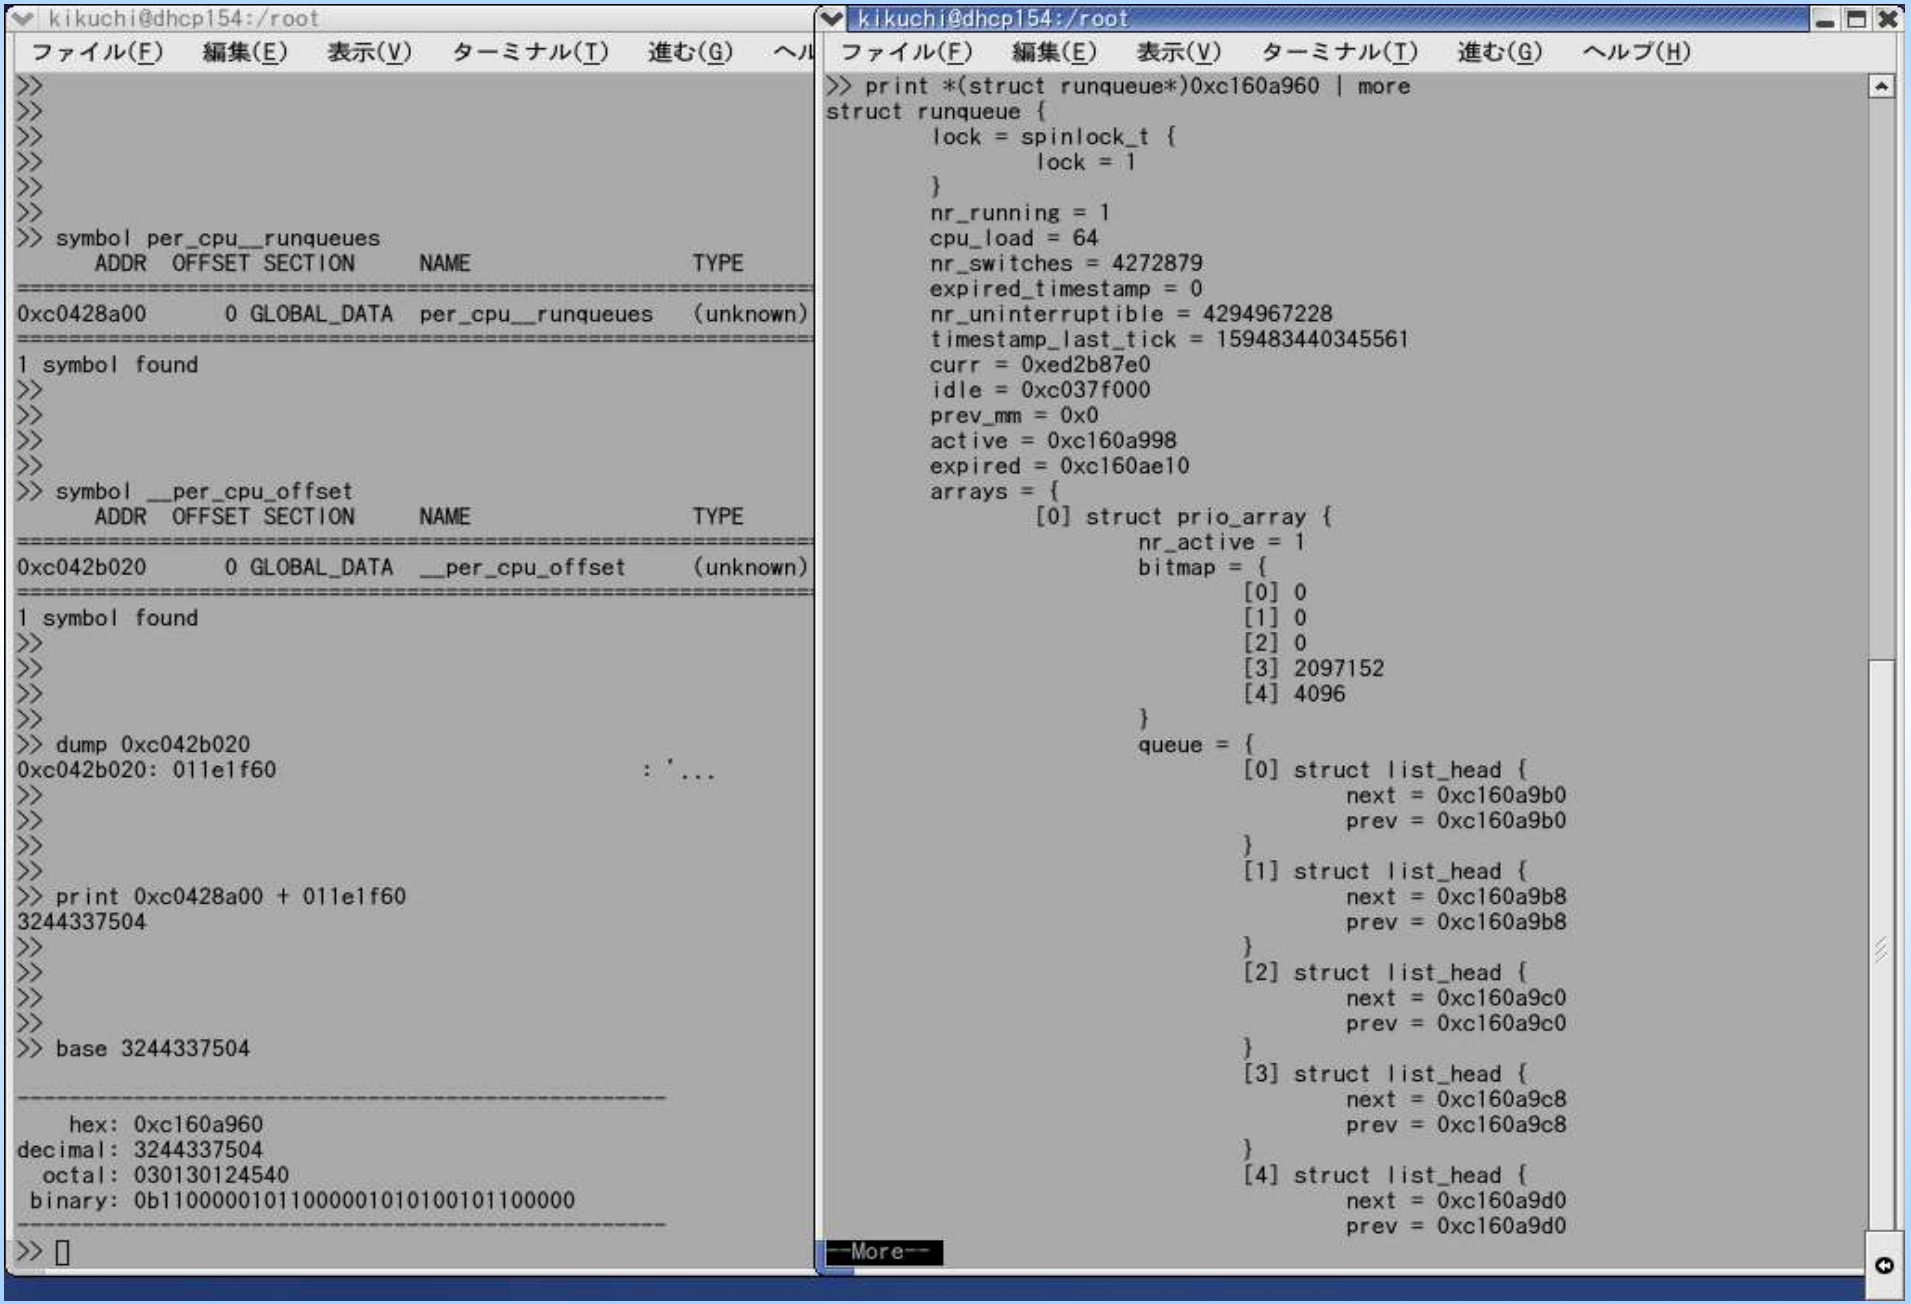

gdb によるアプリケーション解析

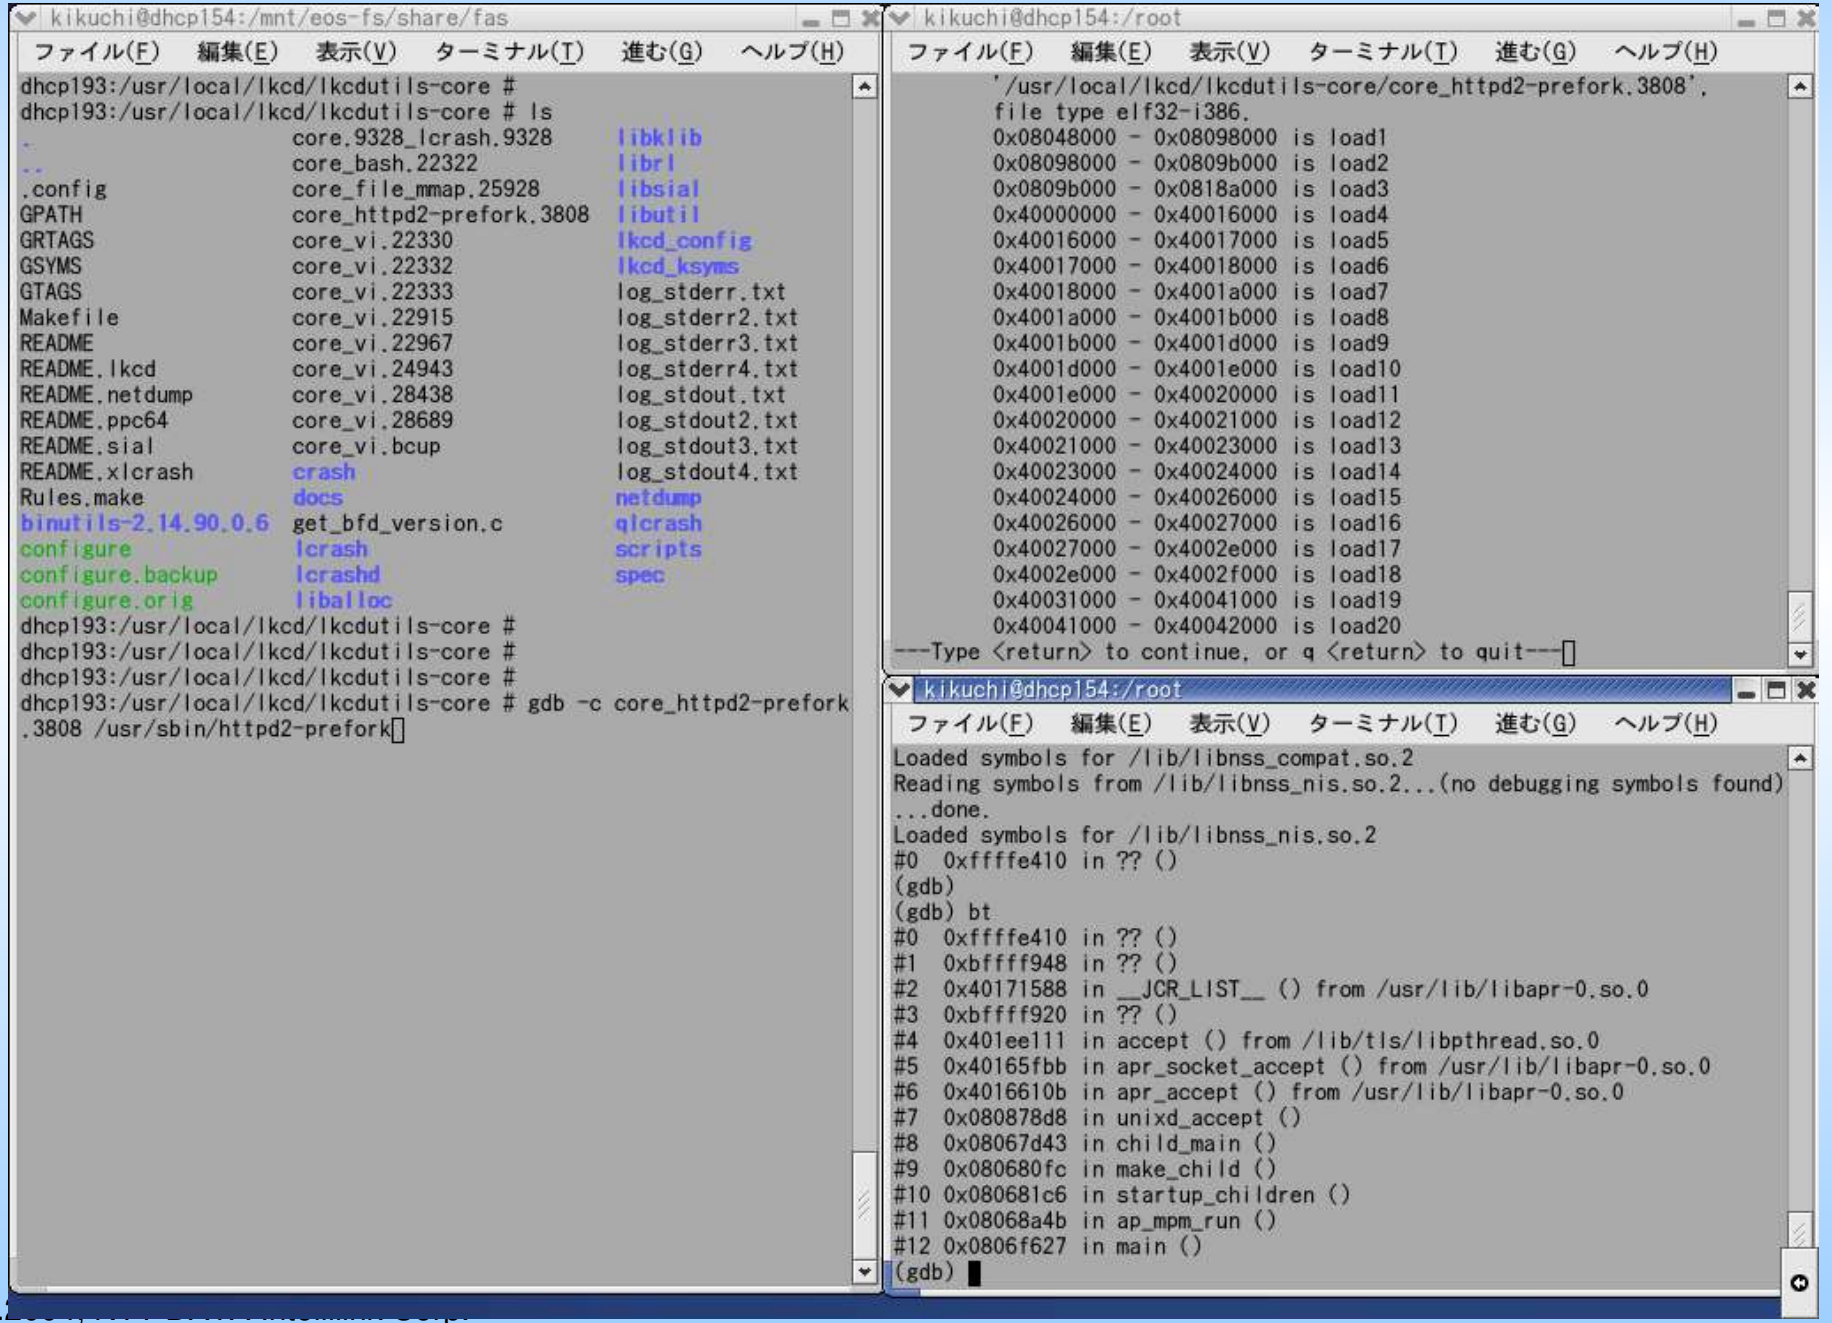

日本 OSS 推進フォーラム開発基盤 WG での検討状況
高信頼化ツール開発プラン

- ミッションクリティカル対応には RAS の強化が必須（ダウンタイムの最小化、障害の早期検出）
- 高信頼化に必要なツール群を「トレースツール、ダンプツール、性能評価ツール、アロケーション情報評価ツール」に分類
- 不足している領域を新規に整備（ダンプ解析スクリプト、アロケーション情報評価）

ミッションクリティカル対応高信頼化ツール群

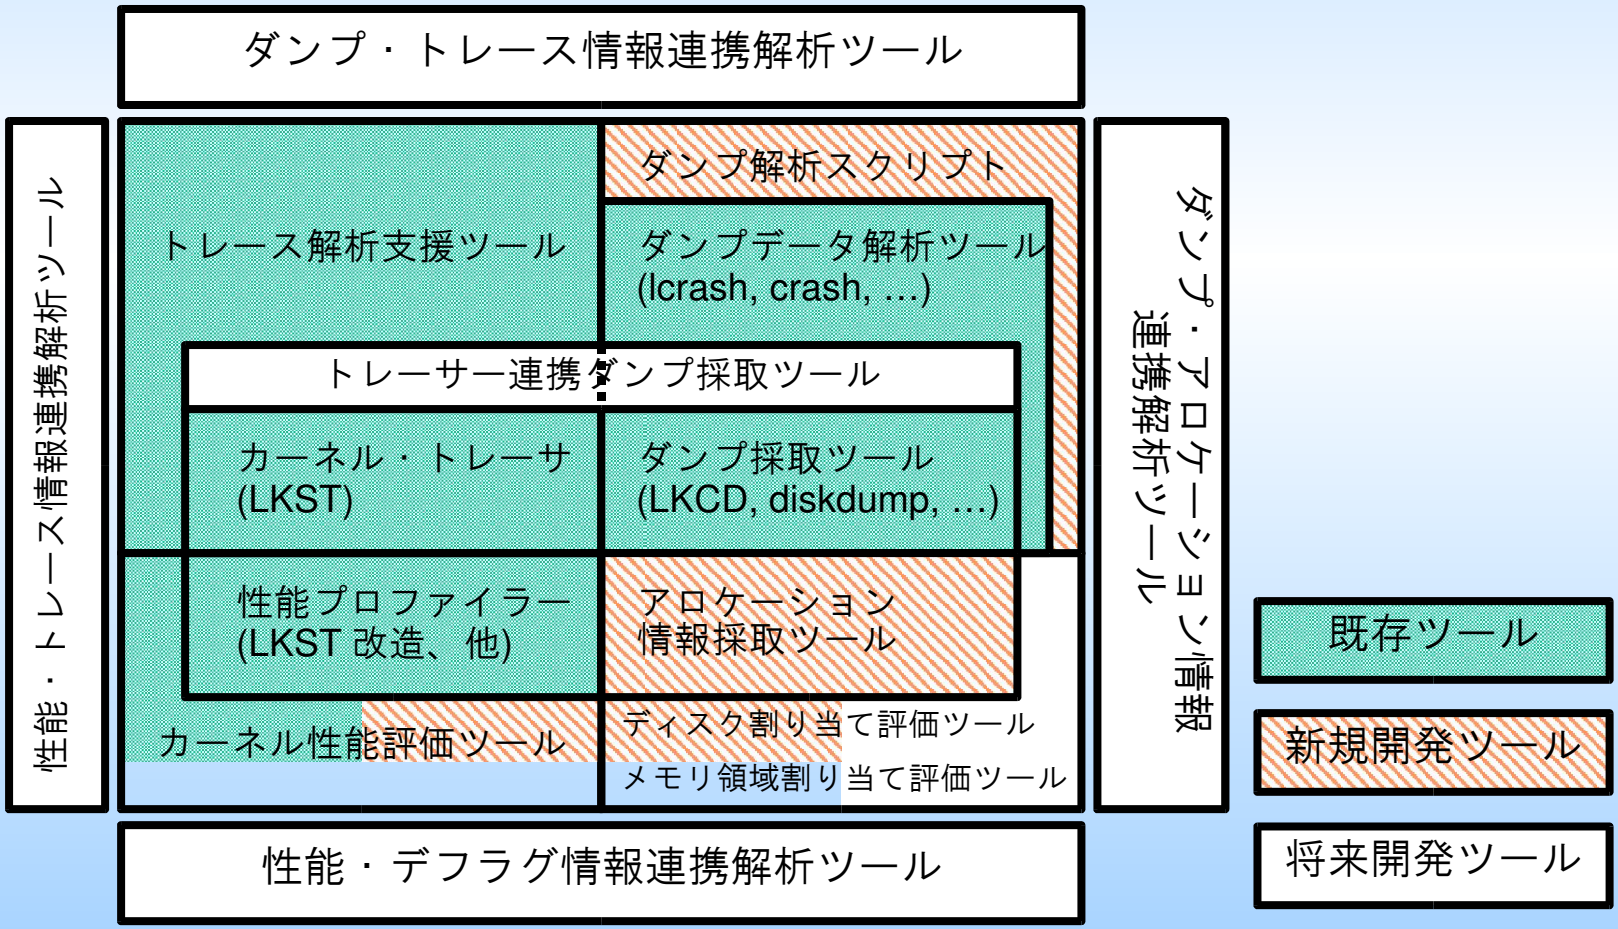

出典： OSS セプテンバーセミナー in 札幌

今後の期待

- 障害解析ツールの開発の促進
  - OSS 推進フォーラムなど
- カーネルダンプのメインツリーへの反映
  - 2004 年のカーネルサミットでも話題に
- カーネルダンプ情報の安全な運用方法
  - 暗号化を施した転送、蓄積

Thank you very much

koichi@intellilink.co.jp