Linux Conference 2005

Linux 用ログ構造化ファイルシステム

天海 良治　一二三 尚　○小西 隆介
佐藤 孝治　木原 誠司　盛合 敏

日本電信電話株式会社　NTTサイバースペース研究所
OSSコンピューティングプロジェクト

発表の流れ

- 背景
- 開発目標
- ログ構造化ファイルシステムについて
- 設計方針
- Linux での実装
- 評価
- 実装経験
- まとめ

背景

- 障害に弱い ext2 (5 年程前)
  - ファイルシステムの信頼性の懸念
- ext3, XFS, ReiserFS, JFS (現在)
  - ジャーナリング技術採用の FS が充実

信頼性，堅牢性，復旧性の改善に大きく貢献

ジャーナリングファイルシステムで十分？

ジャーナリング FS: 変更するメタデータをジャーナルファイルに前書き，後消しする方式

- 信頼性の確保には，書き込みの順序保証が重要
  - ブロックデバイス層のエレベータシークによる副作用
  - 厳密な順序保証 → ジャーナルファイルとの間でシークが発生
- ユーザデータに対する障害復旧時の一貫性保証は不完全
  - データジャーナリング (ext3 のオプション) は？
    - 書き出すデータ量が2倍になる
    - ジャーナルファイルとユーザデータの領域間でシークが発生

高い信頼性を実現し，かつシークによる性能低下を抑えられる解はないか？

もう一つの選択肢：LFS

信頼性向上のアプローチとしてログ構造化ファイルシステム (**L**og-structured **F**ile **S**ystem)[Rosenblum91] に着目

- ディスクブロックの書き込みを上書きではなく追記で実現
  - 信頼性と性能が両立可能
  - 高速なスナップショット機能が実現可能
- ローカルFSでの実装例は少ない
  - Linux 2.2 時代に Linlog-FS があったが，実験段階で開発停止

nilfs (**N**ew **I**mplementation of the **L**og-structured **F**ile **S**ystem) を開発

開発目標

- 高信頼であること
  - 壊れにくく，ファイルシステムでデータベース並みの信頼性をもつ
- 高可用であること
  - 停止時間が短く，障害発生後の復旧時間が短い
- 運用性に優れること
  - オンラインバックアップ，誤消去したファイルの復旧を可能にするため，短時間にスナップショットがとれる
- 高性能であること
  - ext3 に同等もしくはそれ以上の性能

従来ファイルシステムのブロック配置

- inode を含むメタデータは固定割り付け
- データブロックは，最初の write 時に割り当て，以後上書き

⇒ 上書きは破壊： 過渡的に整合性のない中間状態が発生

⇒ ジャーナリングFS： ジャーナルファイルにも更新ブロックを書き，復旧不可能な中間状態をなくす

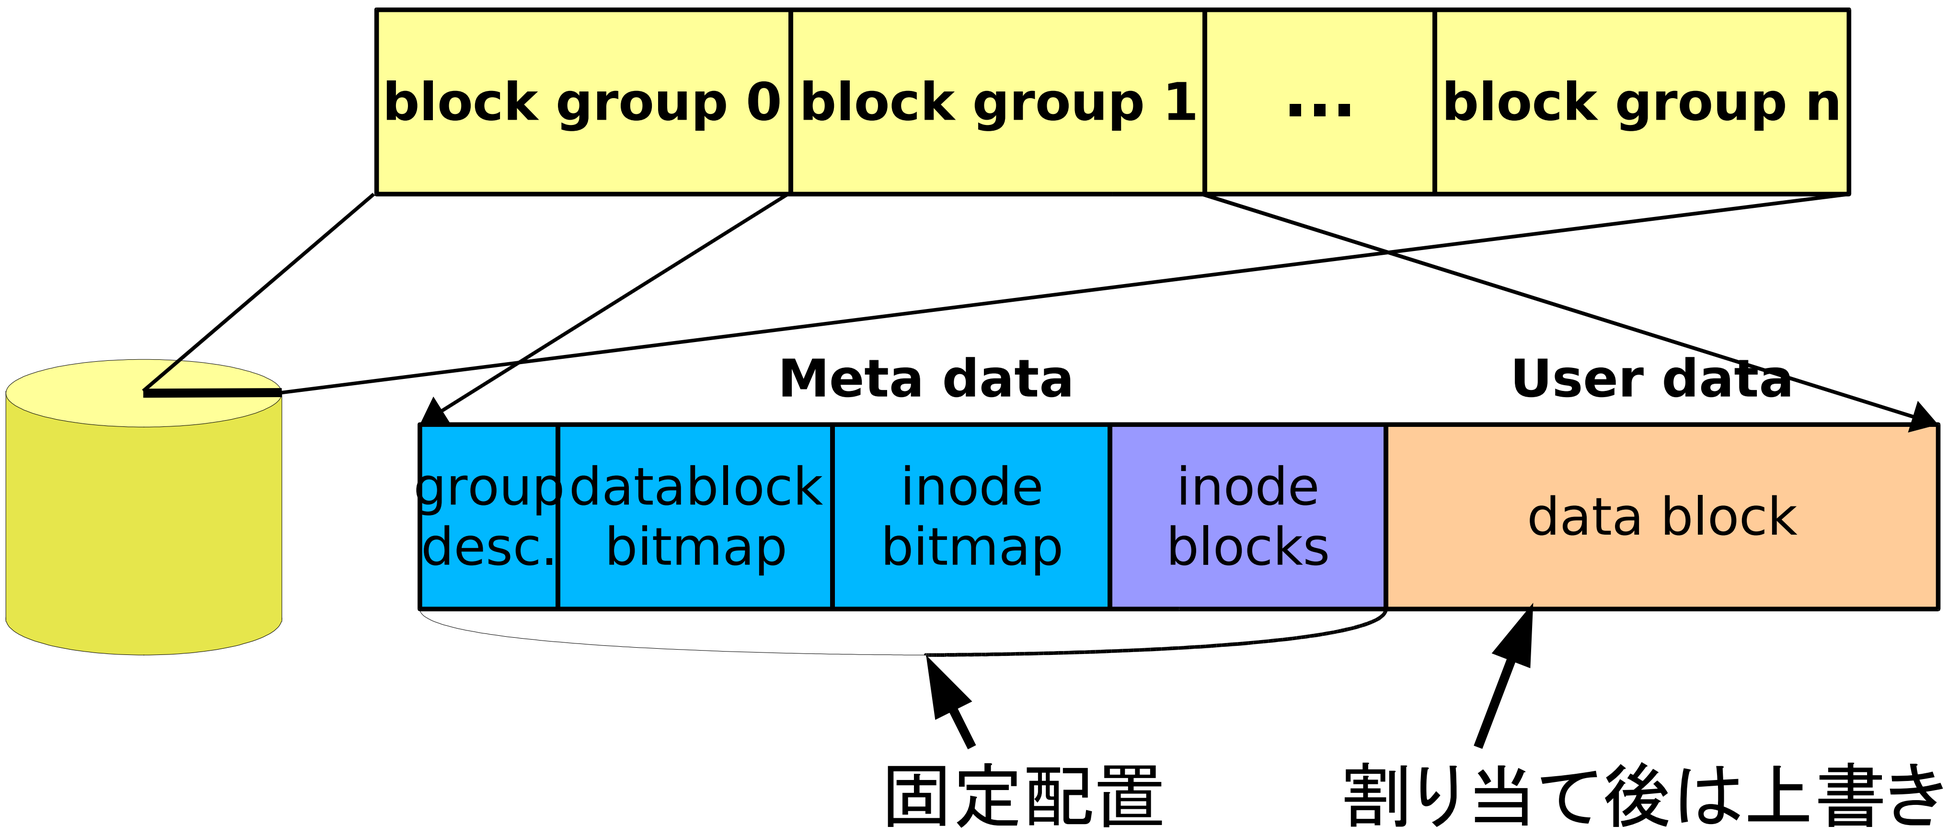

LFS のブロック配置

- 復旧不可能な中間状態の発生を追記により回避
  - inode, データブロックとも，常に新しい領域に書き出す
  - 書き出しはセグメントという単位で atomic に実施

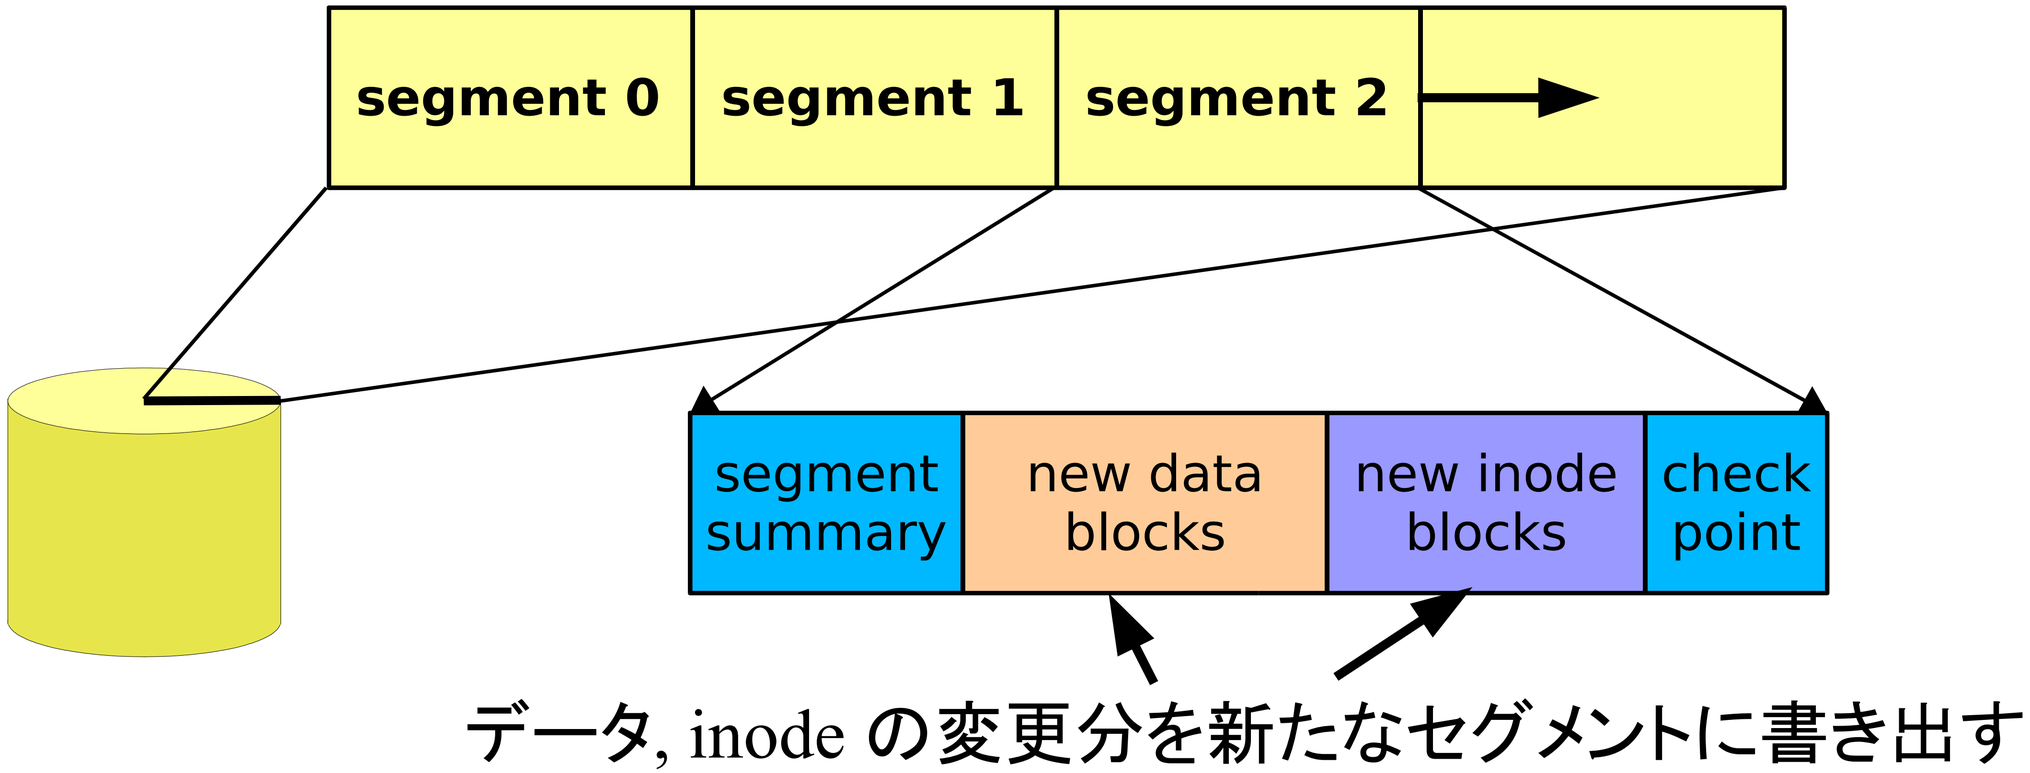

LFS における書き込みの例

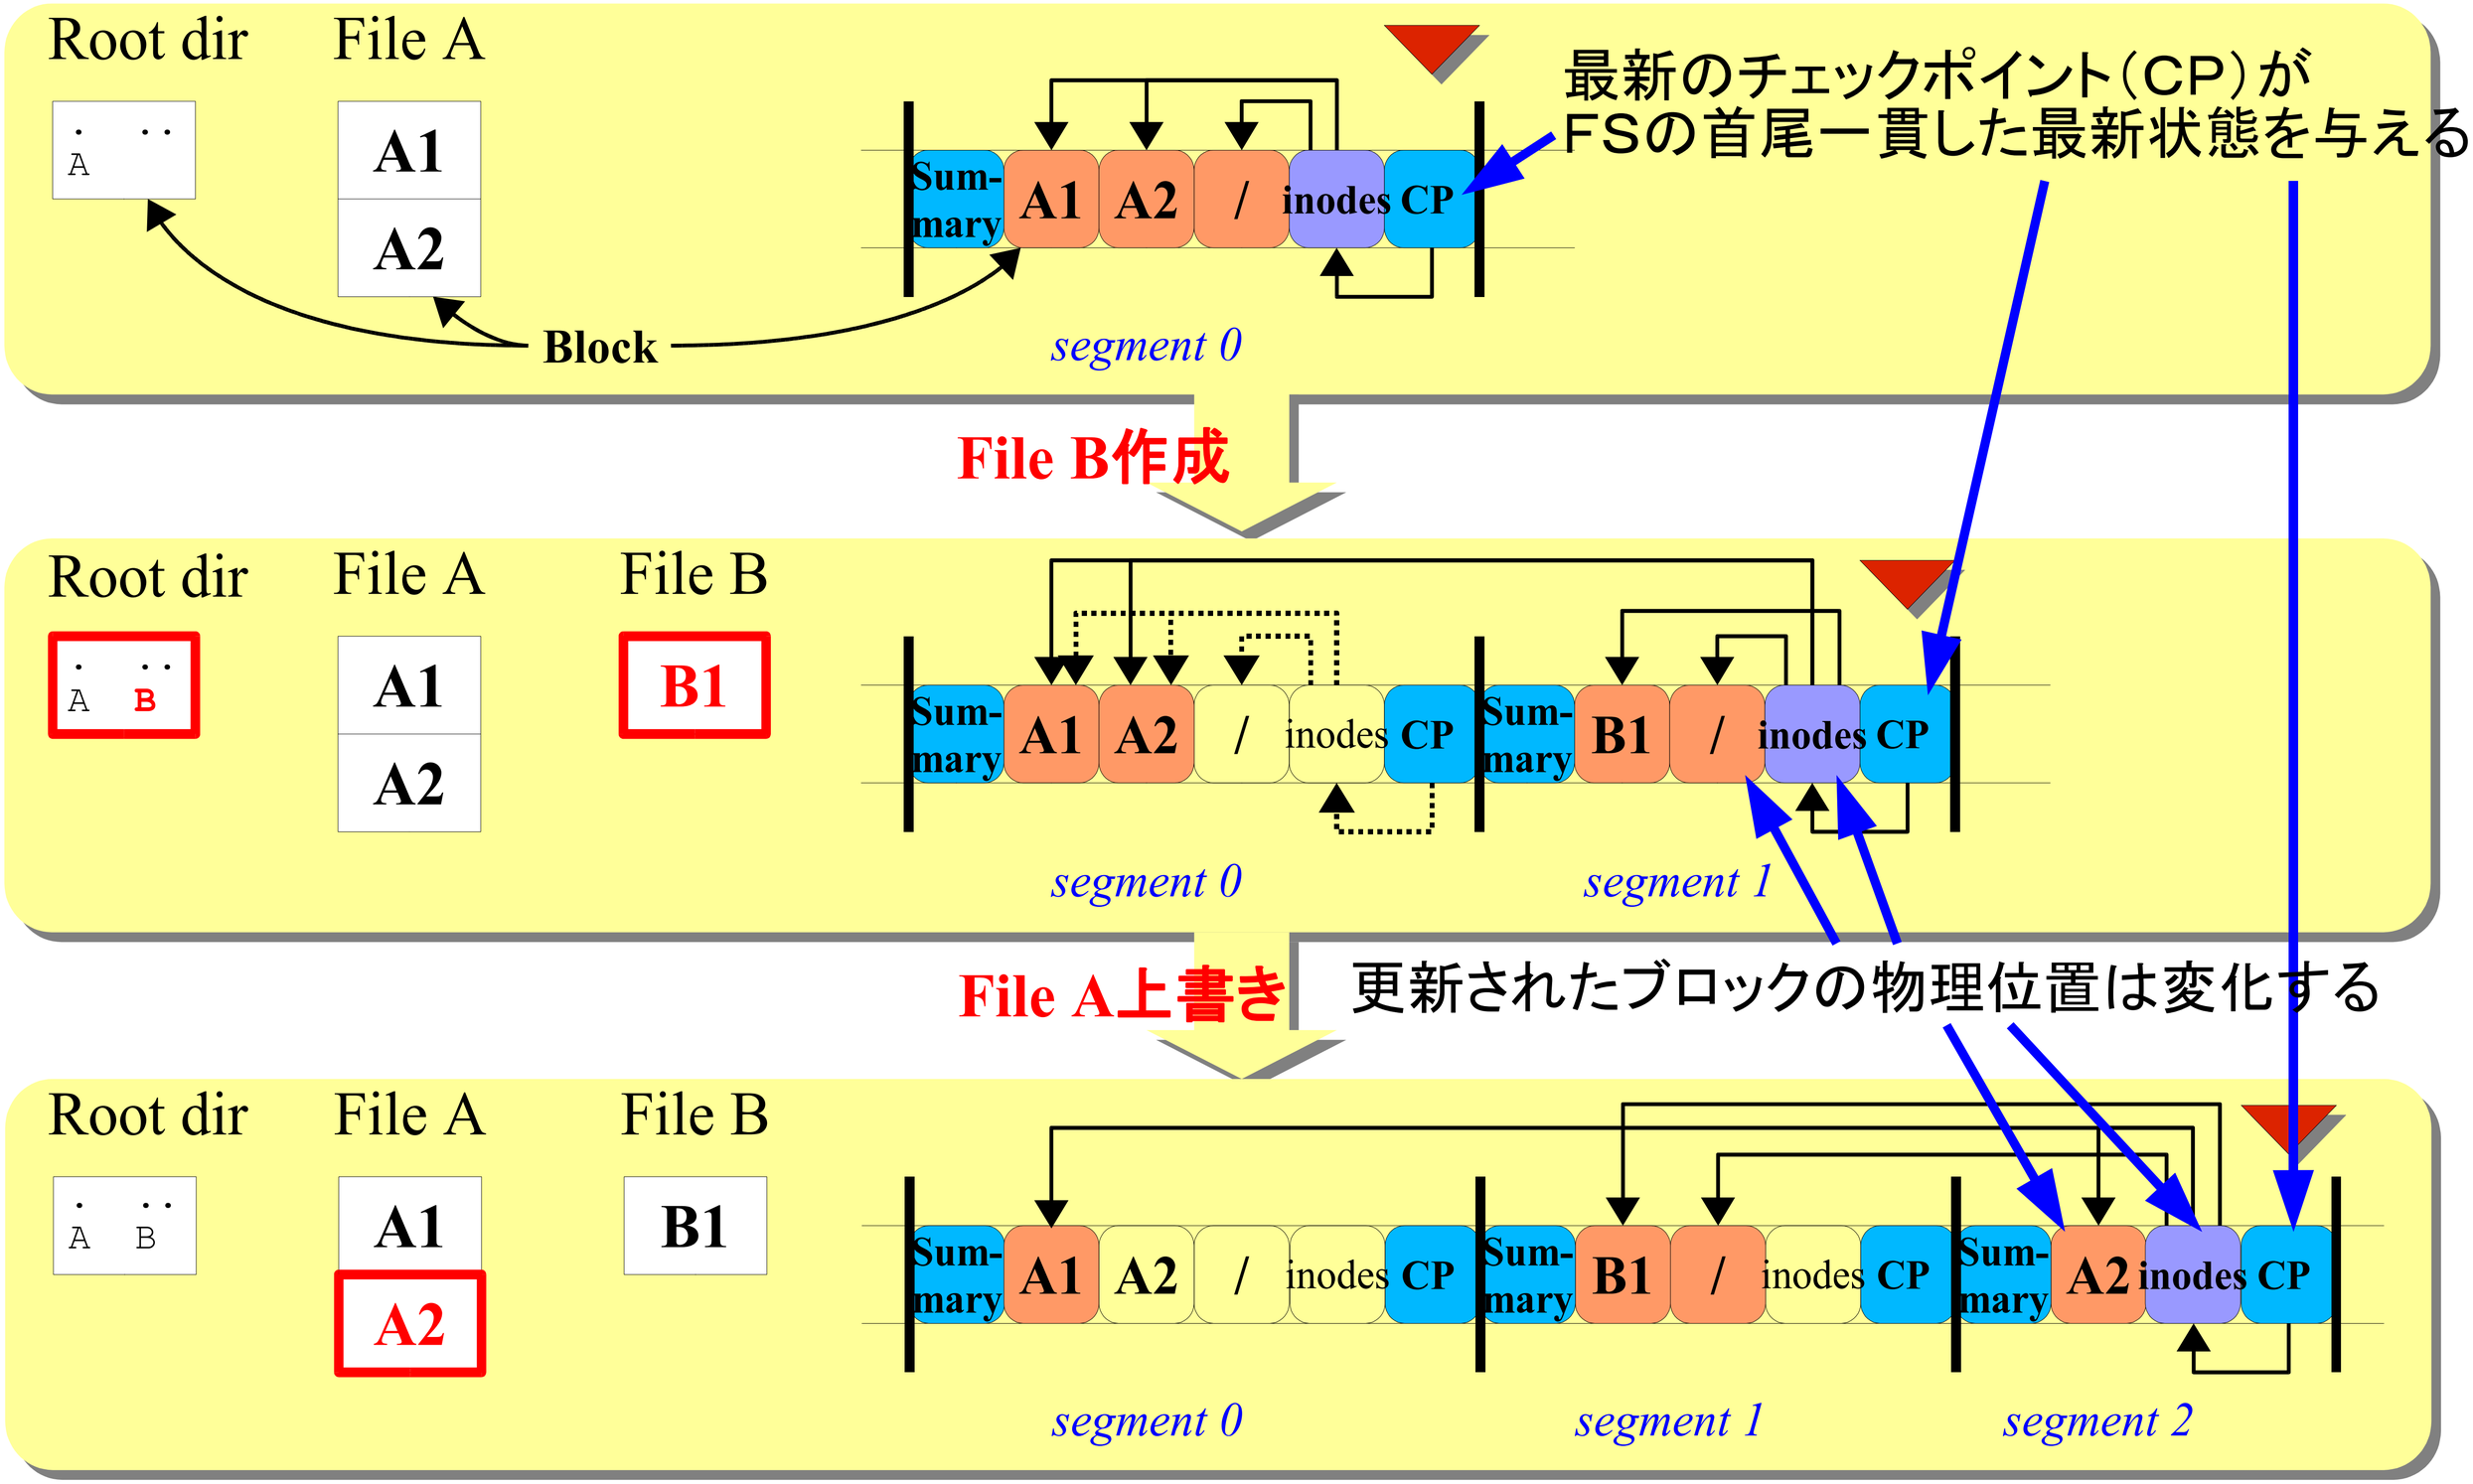

Garbage Collection (GC)

書き込みを続けるには，不要ブロックを整理し，連続空き領域を作る処理が必要．

⇒ **LFS の性能低下要因**

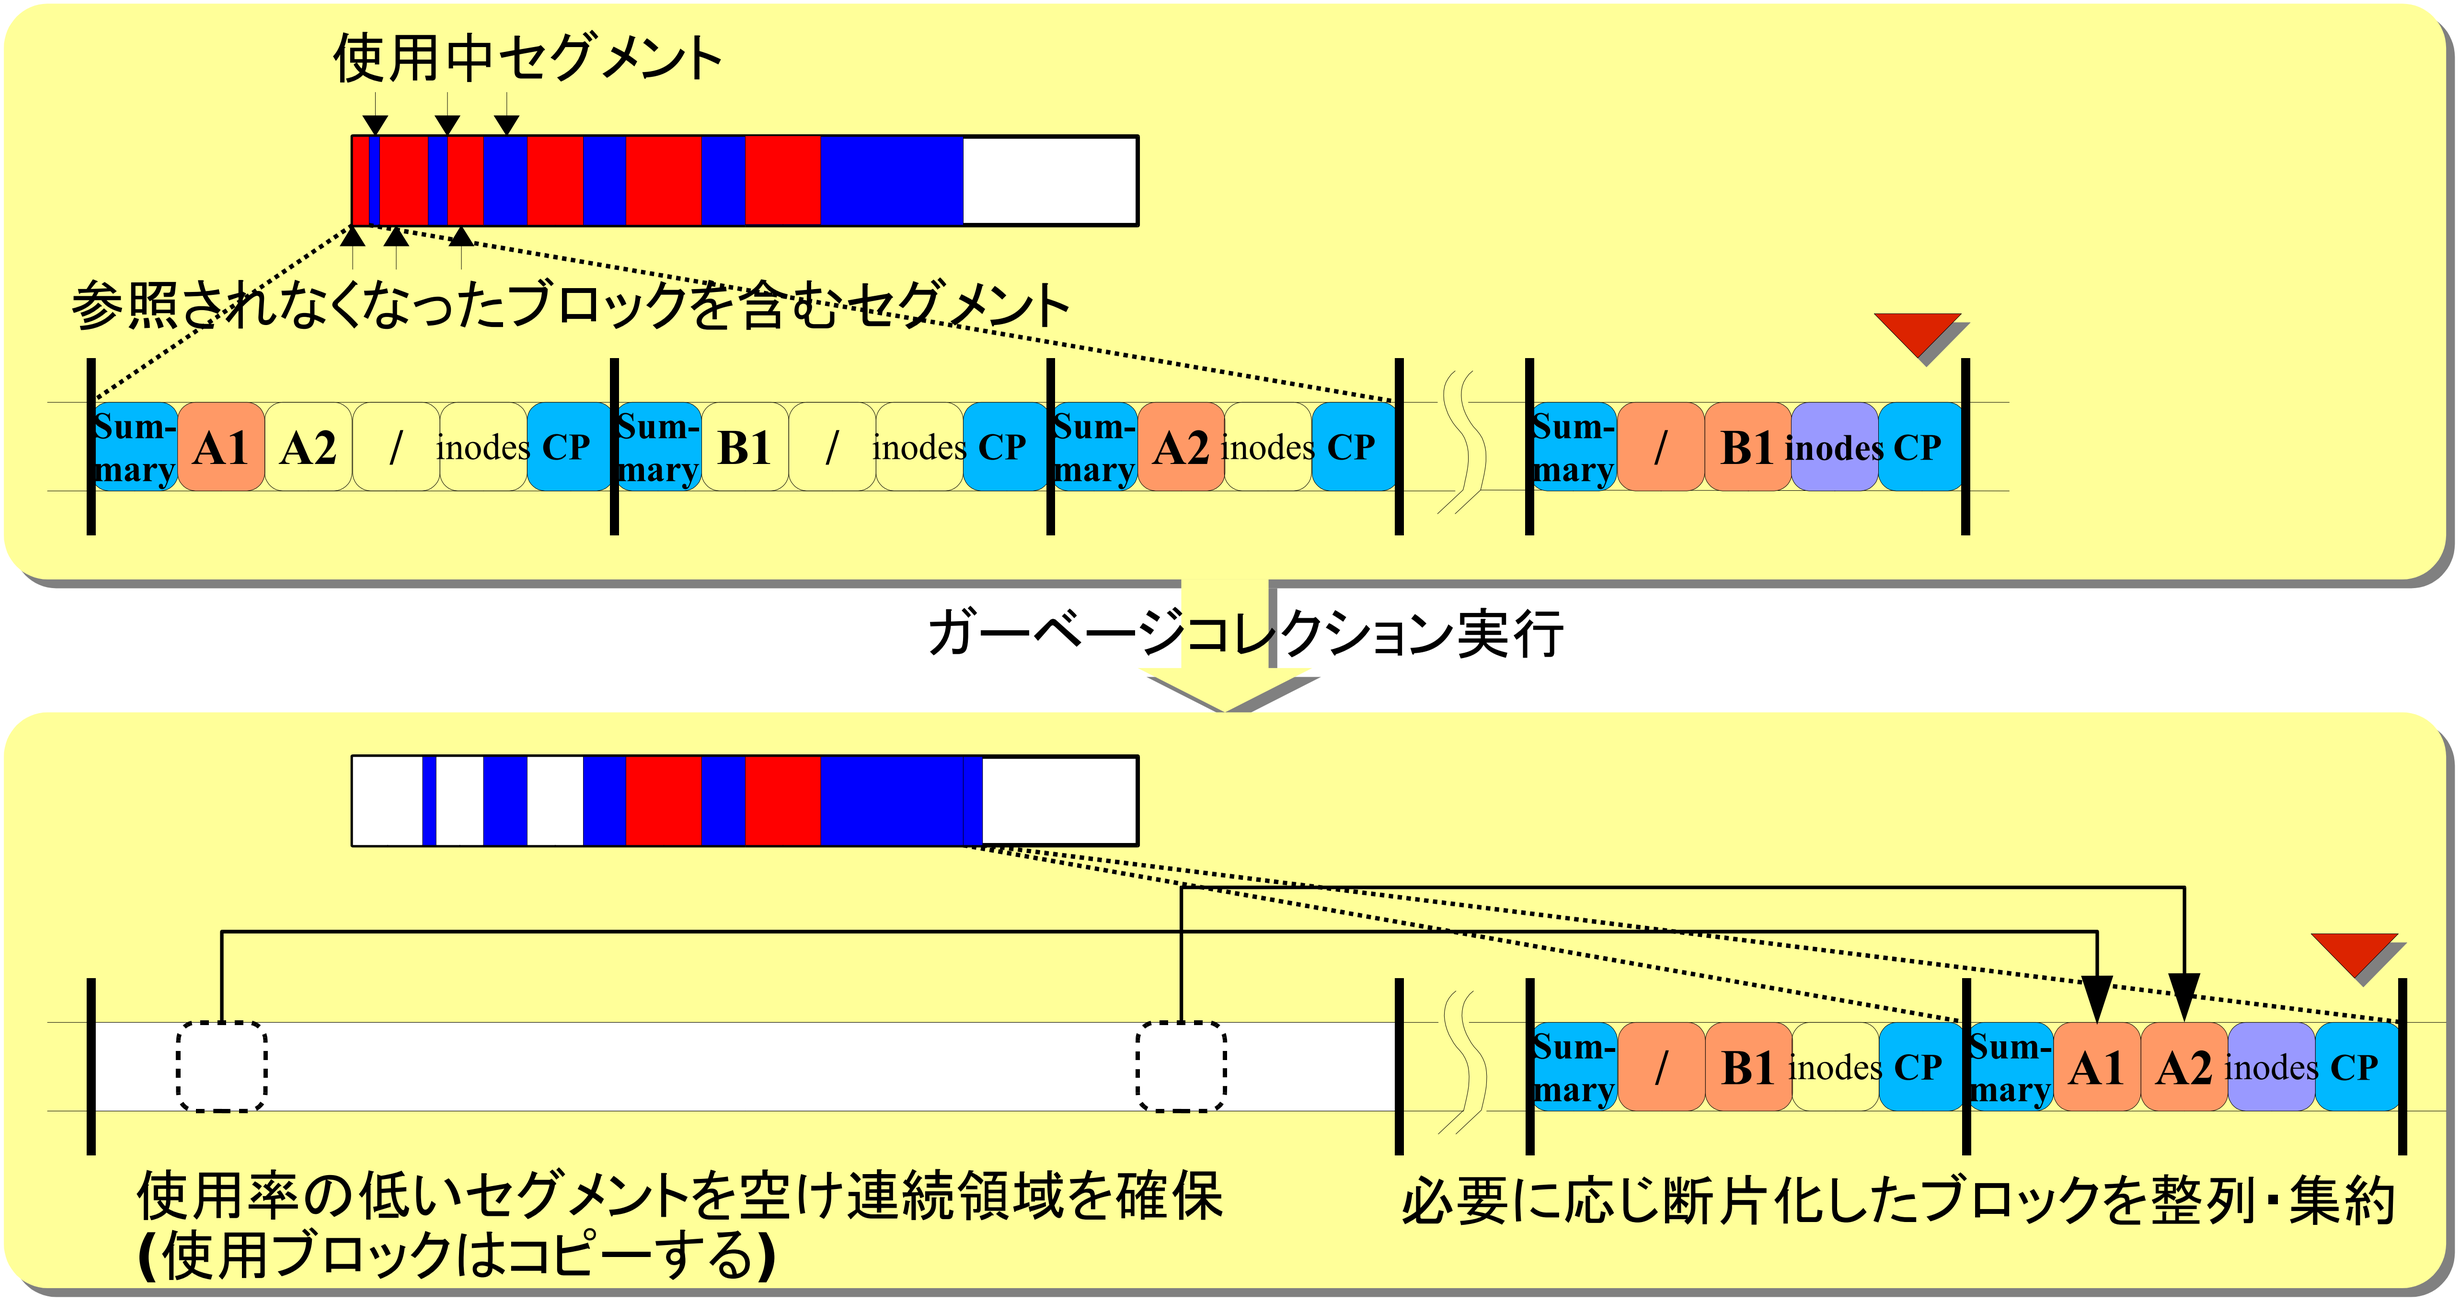

nilfs(v1) の設計方針

- ファイルブロックと inode を B-Tree (平衡木) で管理
  - 大きなファイル (64 ビットサイズ) や多数 inode の管理・検索の効率化
  - ディスクブロック番号の動的な変化に対応
- 信頼性の確保
  - チェックサム付与による正しい書き込み完了の確認
  - ディスクブロックの上書きは極力排除
  - BIO 活用による連続書き込みの実装と順序保証
- その他
  - Linux セマンティクスの踏襲
  - カーネルコードへの変更を避ける（ モジュールで導入可能)
  - VFS, ページキャッシュ, バッファ管理等との親和性

nilfs(v1) のディスクレイアウト

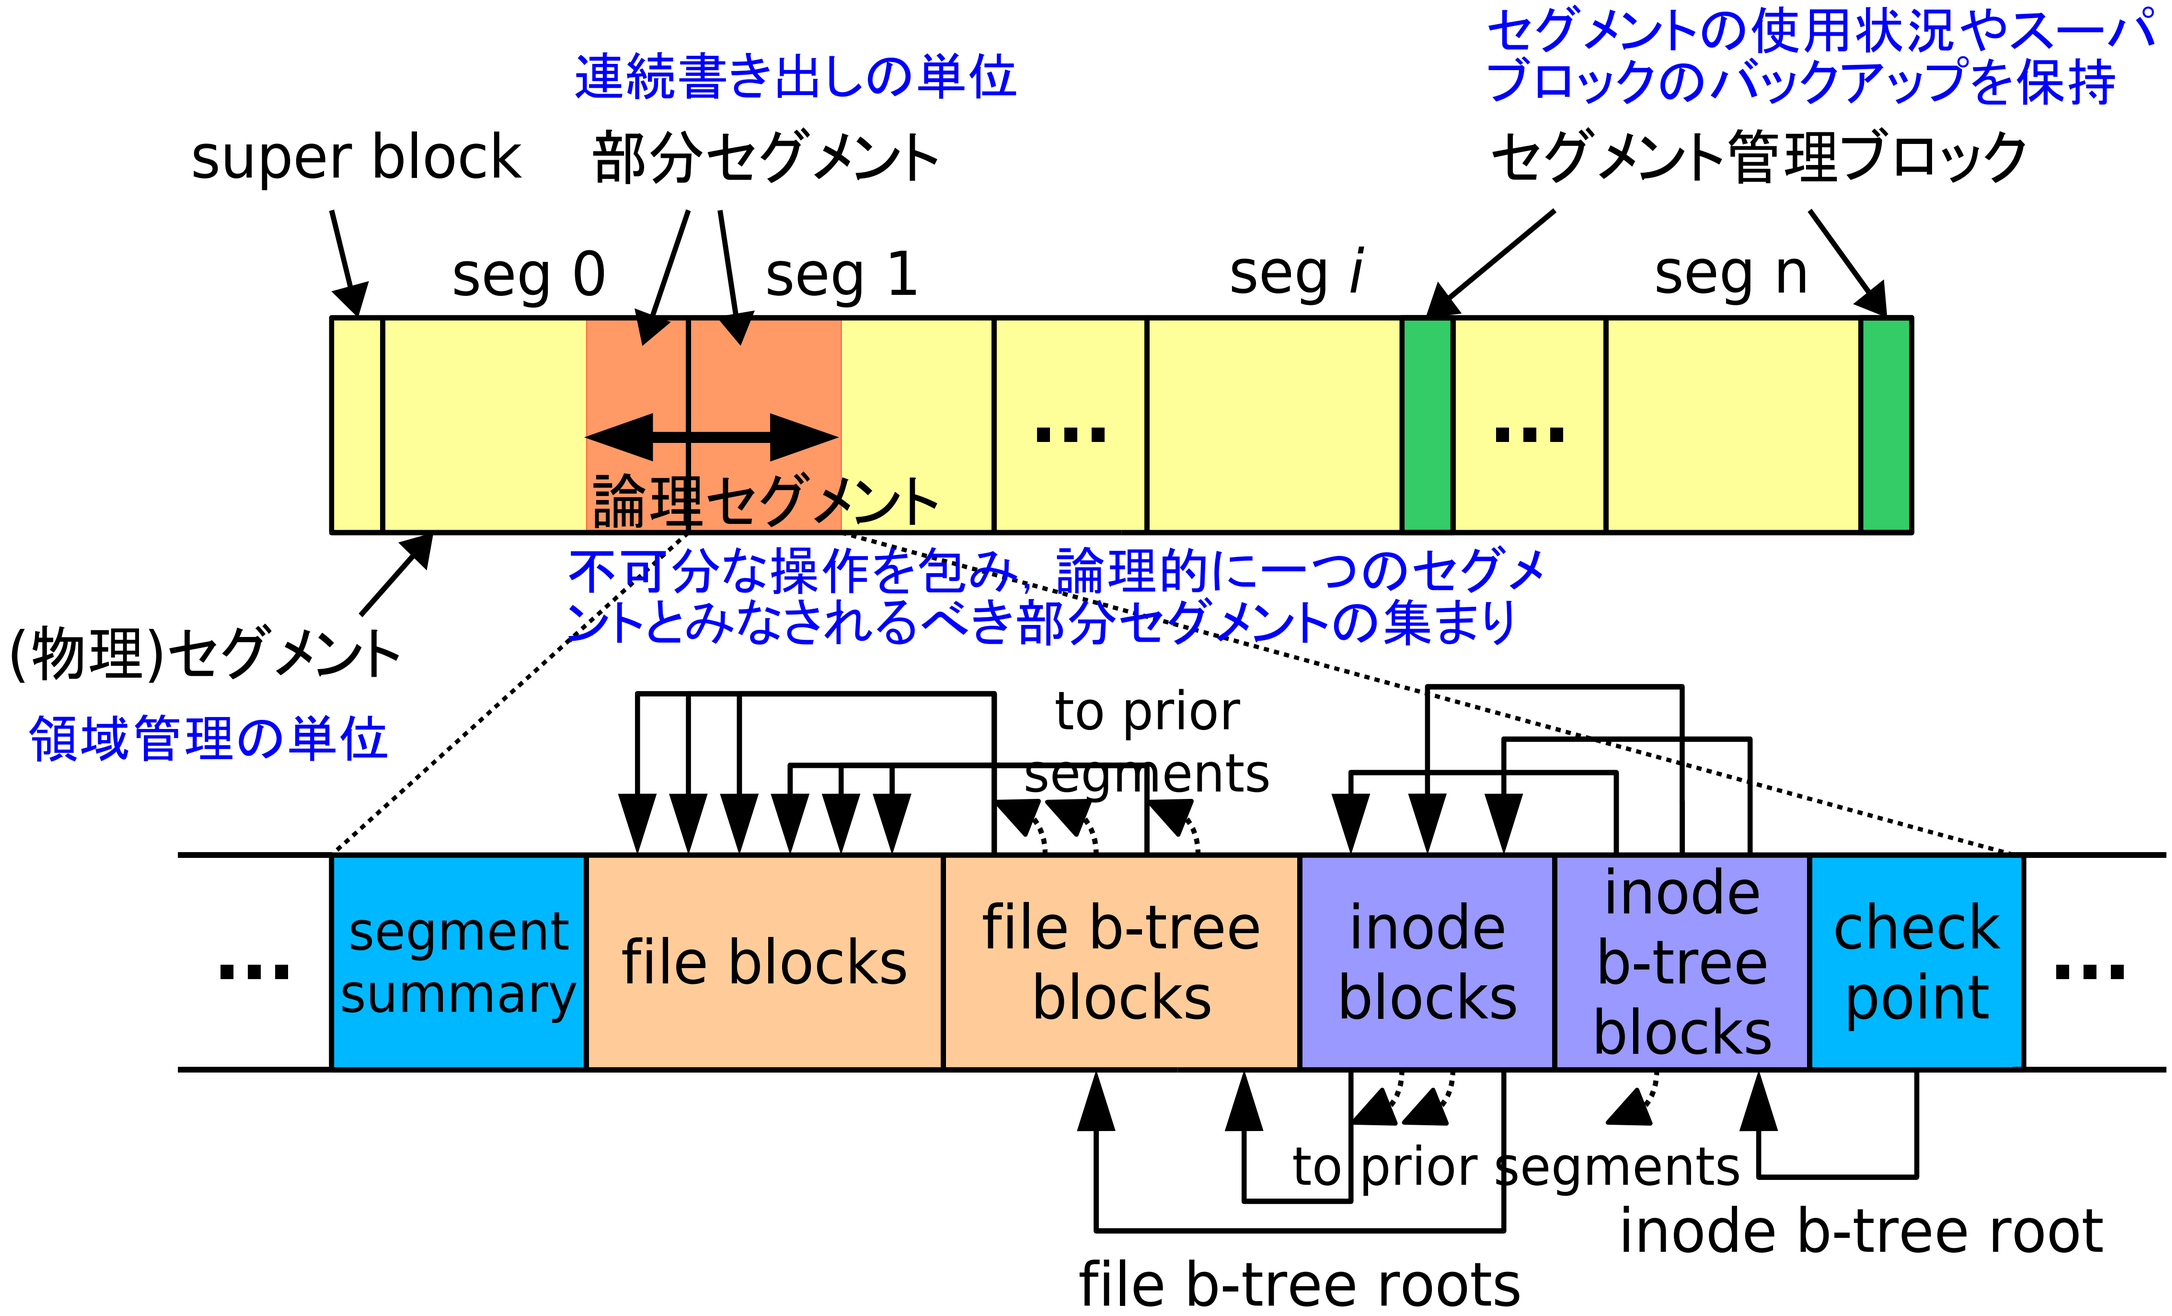

nilfs(v1) の機能構成

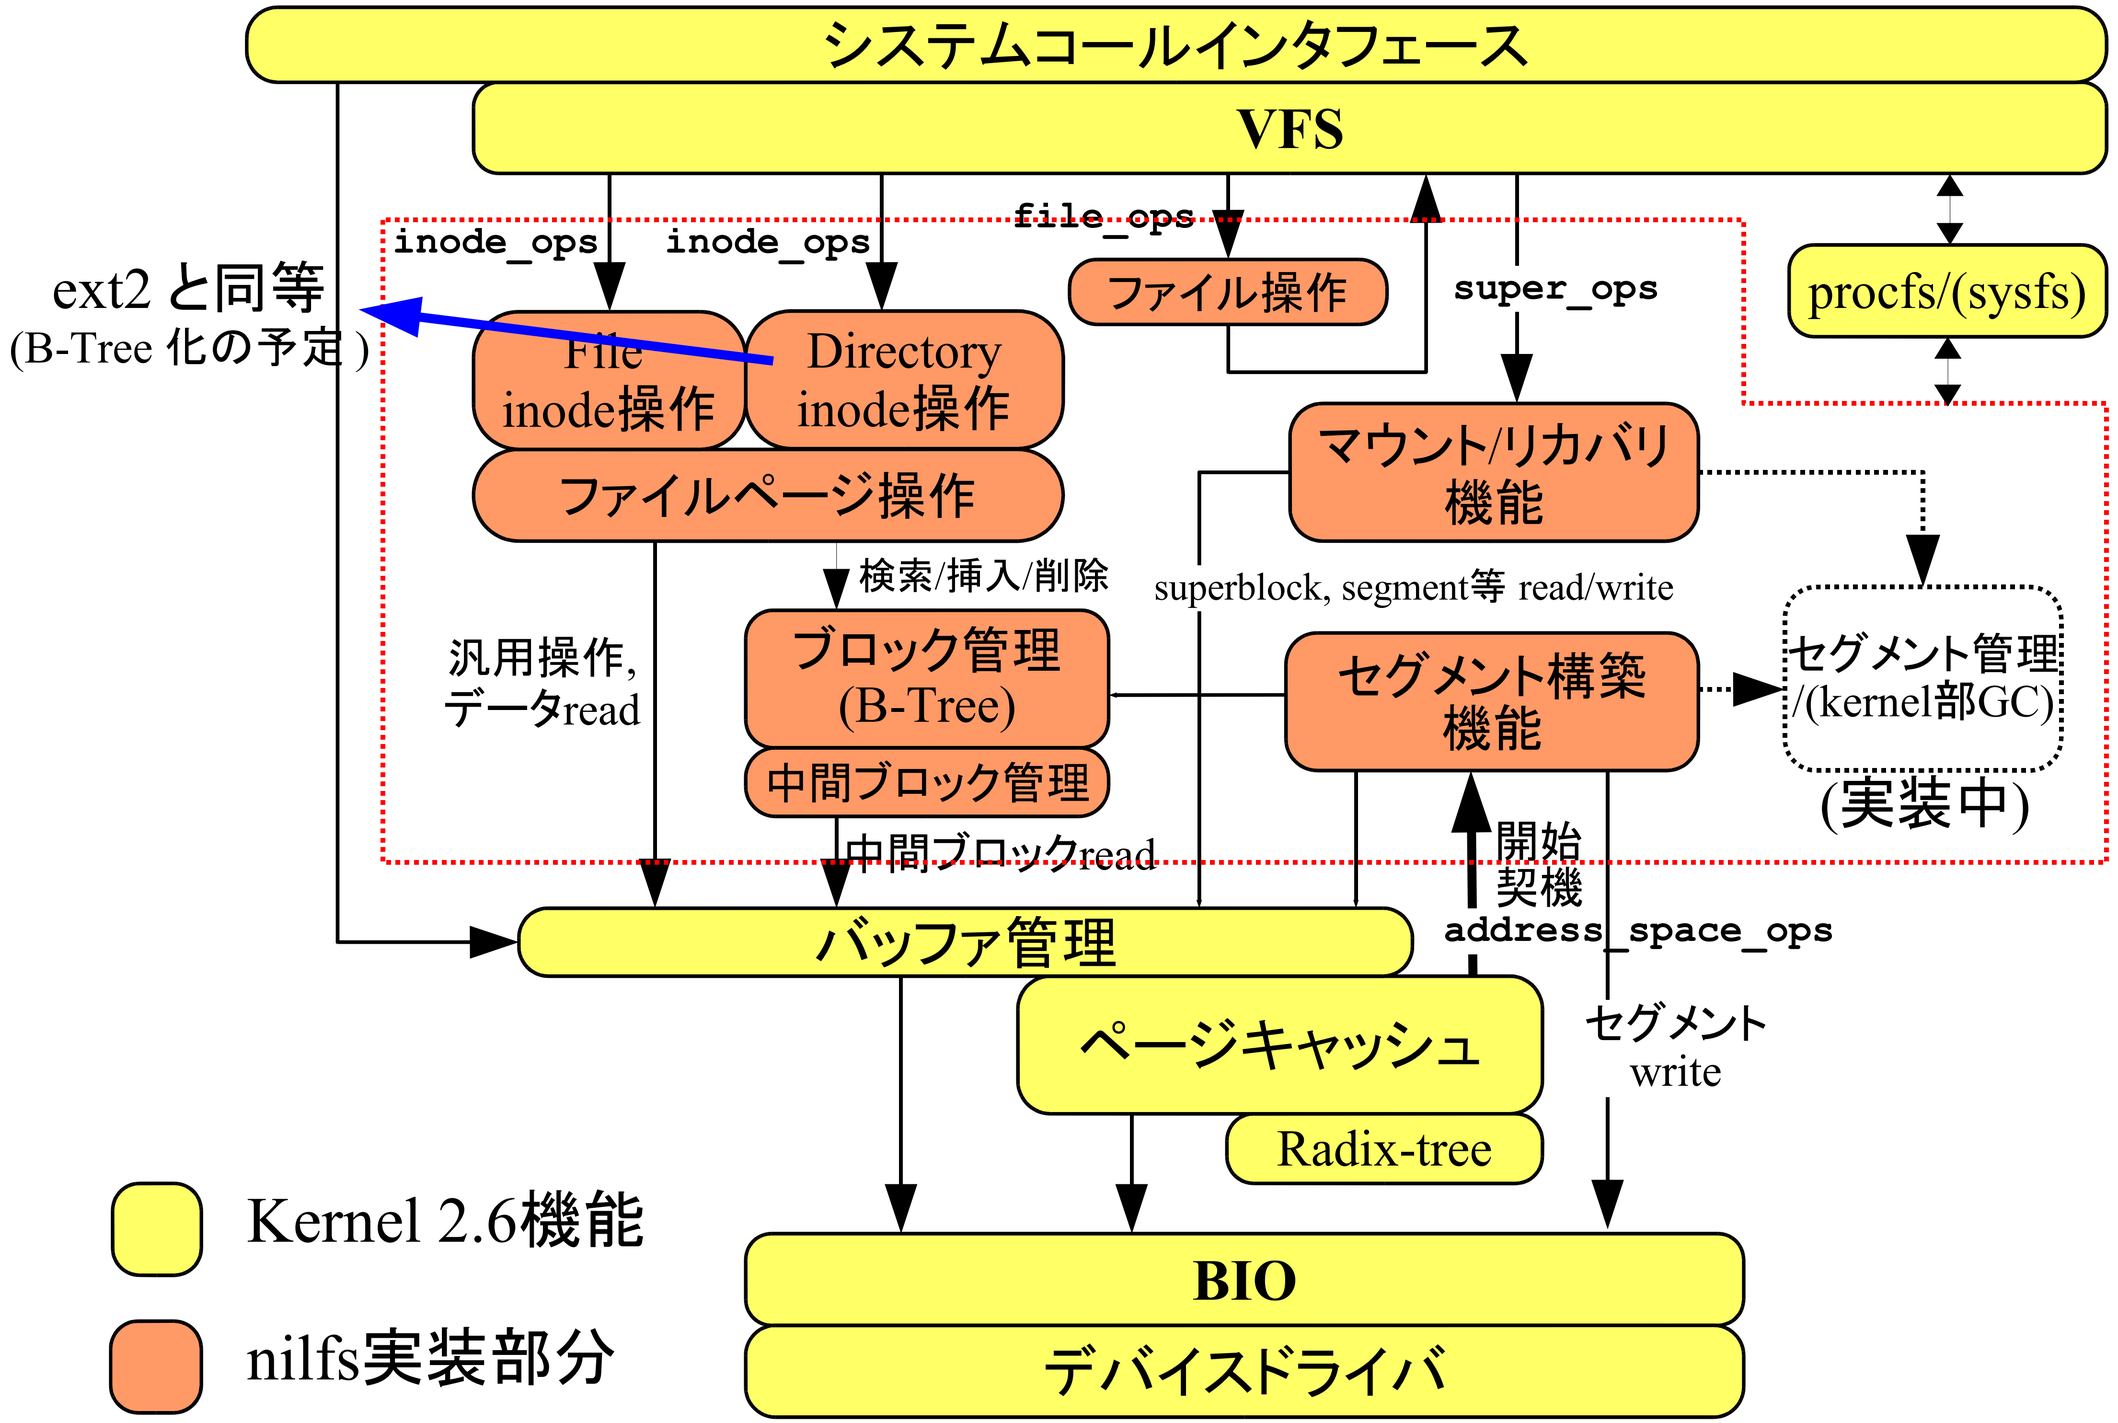

Linux のページキャッシュにおけるバッファの管理

ユーザデータの管理

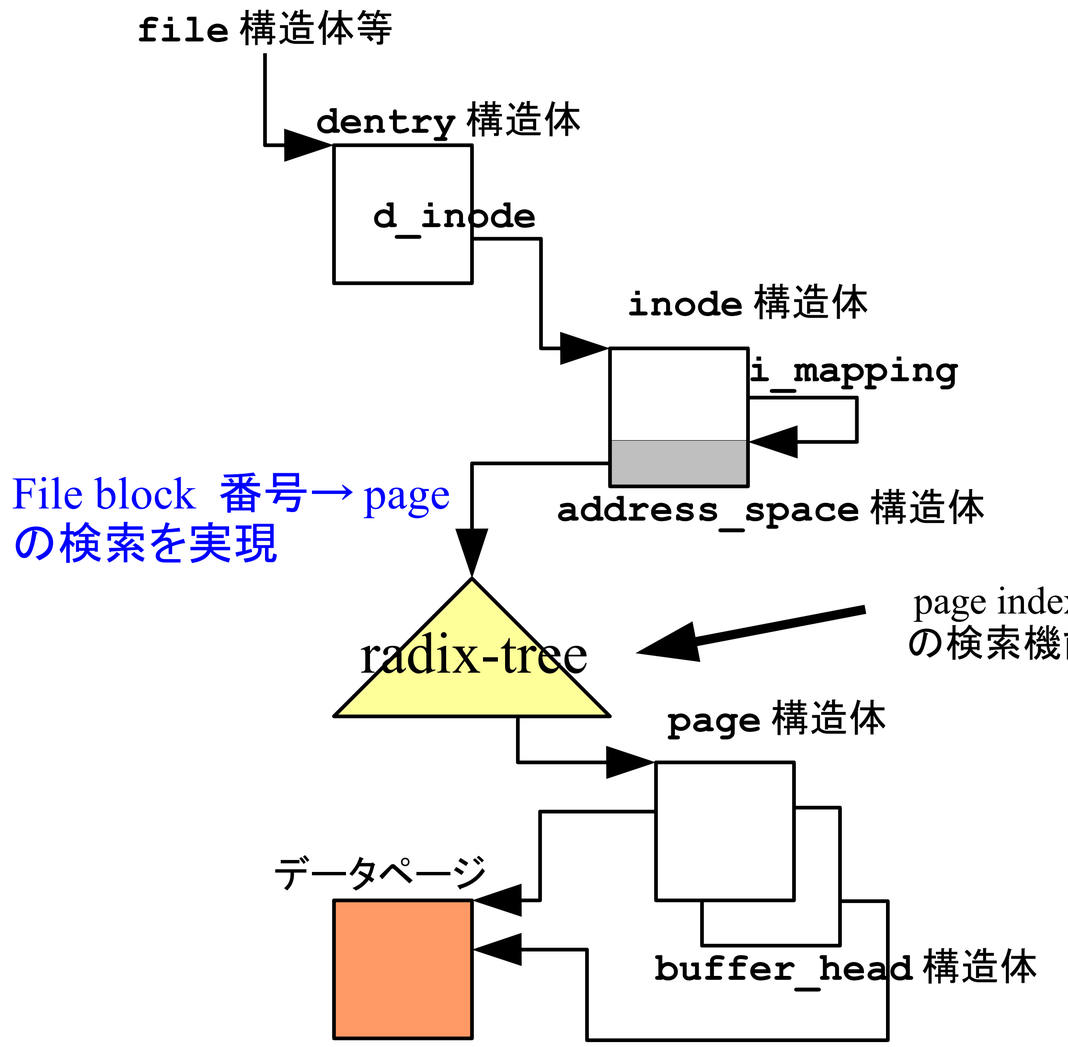

メタデータの管理

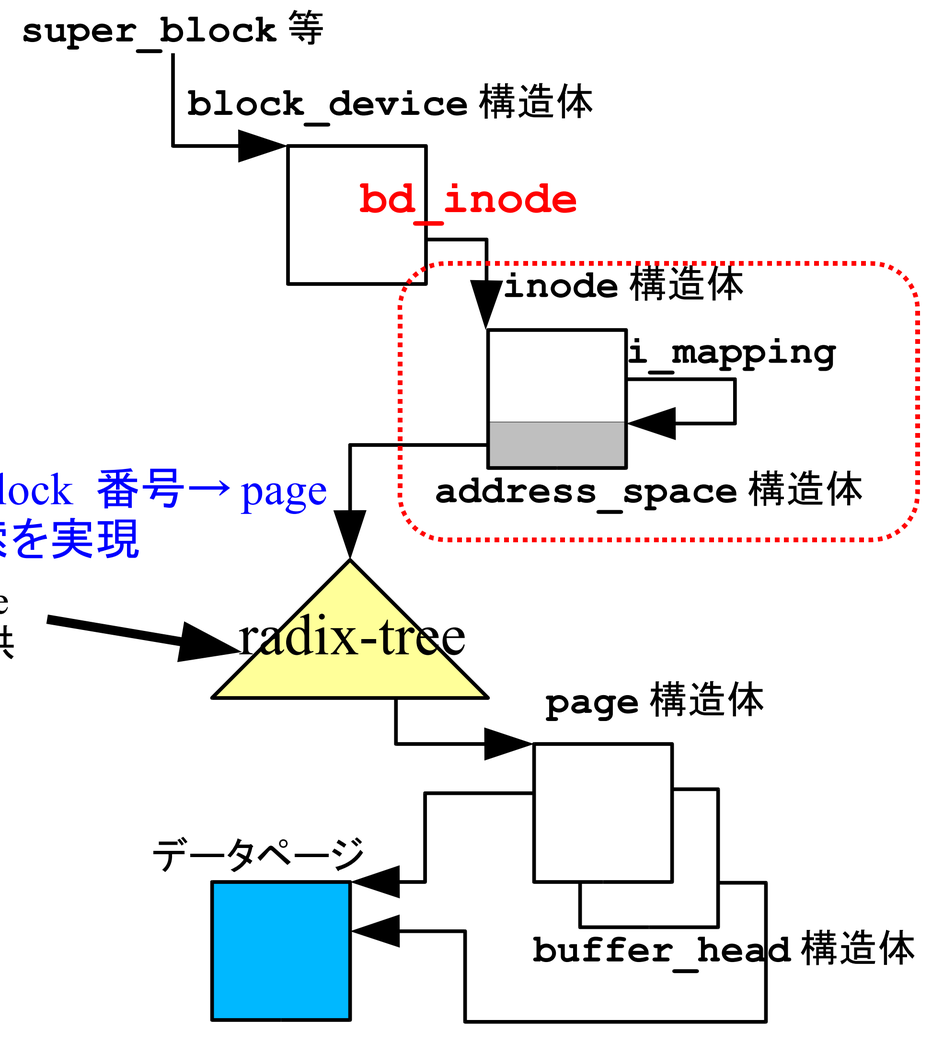

- 間接ブロックを含めメタデータは，ディスクブロック番号をキーに bd_inode で一括管理

nilfs におけるバッファの管理

- B-tree 中間ブロックのバッファ管理の効率化
- 動的なブロック位置変化への対応
  - ブロックの位置は書き出す直前まで決まらない
  - ファイル，inode のバッファ検索キーは論理的な番号であり，変更不要
- Block device オブジェクトに頼らない書き出し制御の実現

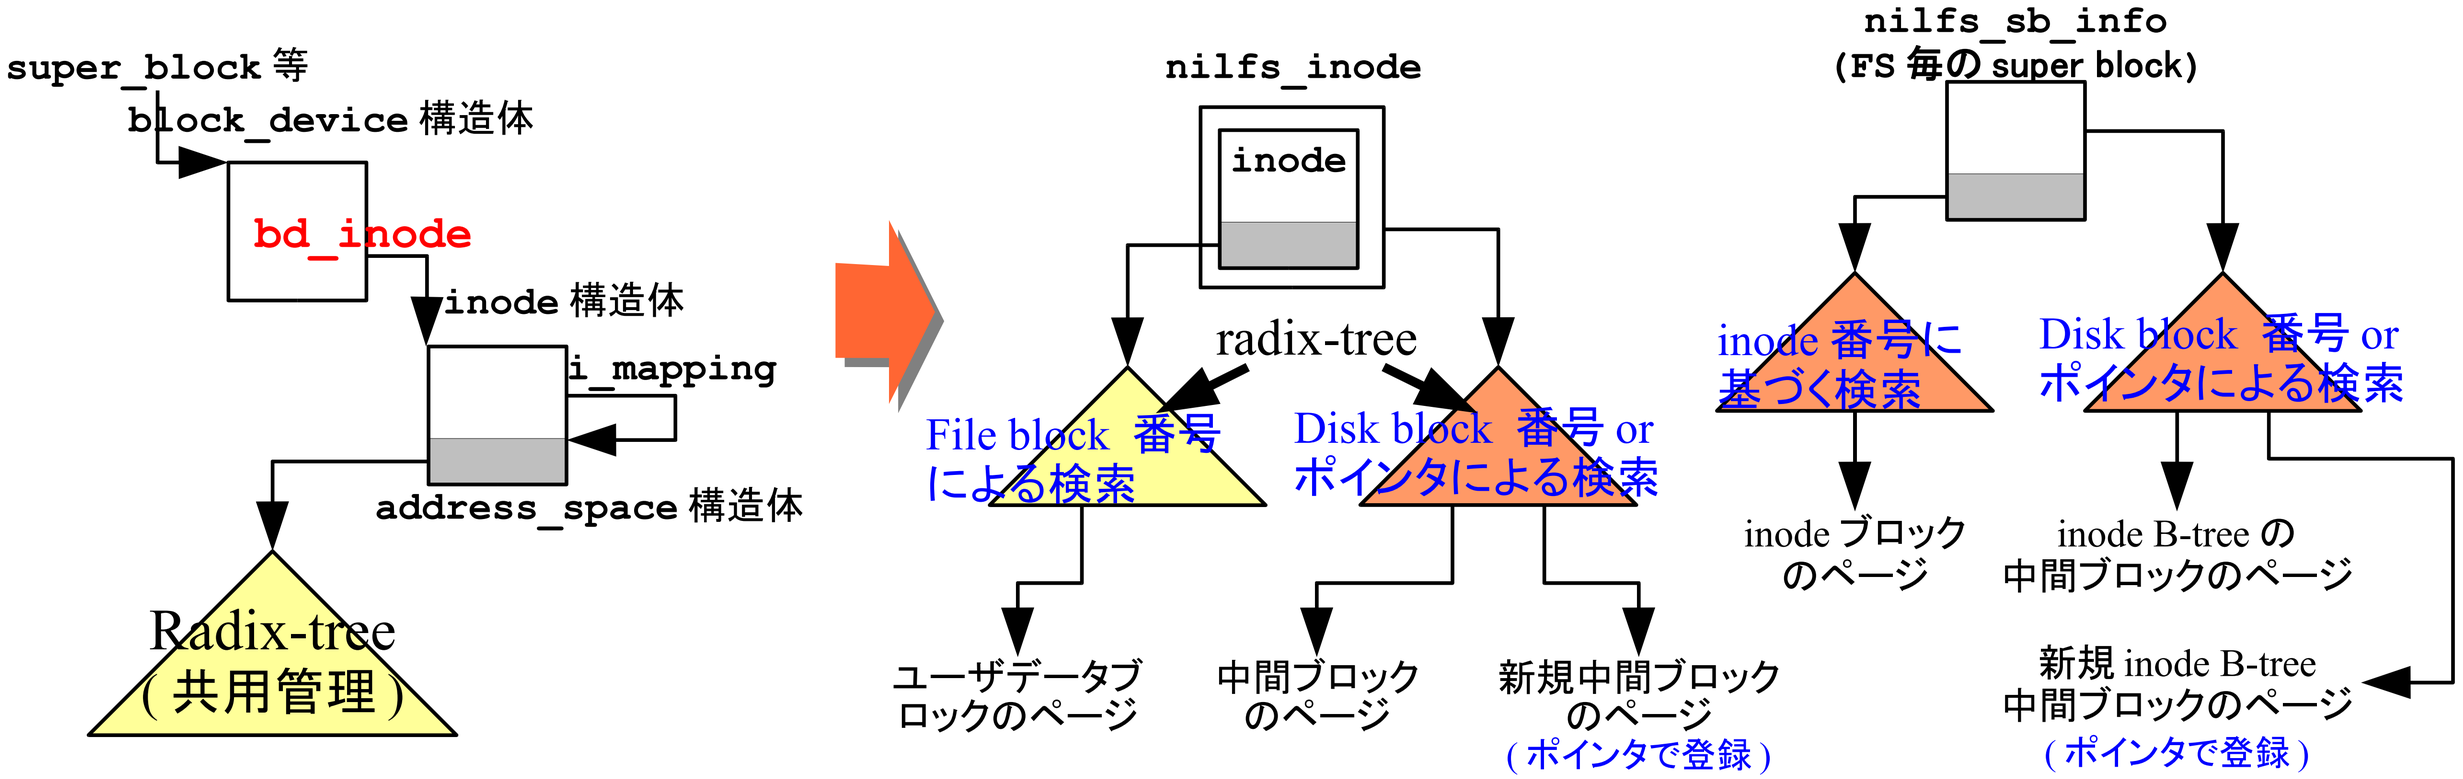

ページキャッシュ機能を用いつつ，bd_inode を使わず個別に管理

スナップショット機能

- 各チェックポイントが，それぞれ一貫したスナップショットを与える
  - チェックポイント作成機能 +GC からの保護機能として実装
  - チェックポイントの管理は通常ファイルで行う予定
  - ディスク容量を消費する
    - 保全するデータの絞り込み，追い出し等の工夫は今後
- デモンストレーション

性能測定について

- 測定項目（iozone)
  - シーケンシャルライト・ランダムライトのスループット
  - シーケンシャルリード・ランダムリードのスループット
- 測定条件
  - Kernel Version: 2.6.10
  - Ext3 Journaling Mode: Ordered mode (Default)
  - nilfs は GC 未実装．性能チューニング未実施．

測定マシンのスペック

CPU	Pentium 4 3.0GHz
メモリ	1GBytes
ディスク	IDE Disk (ATA 7,200 rpm)

書き込みのスループット

write + fsync

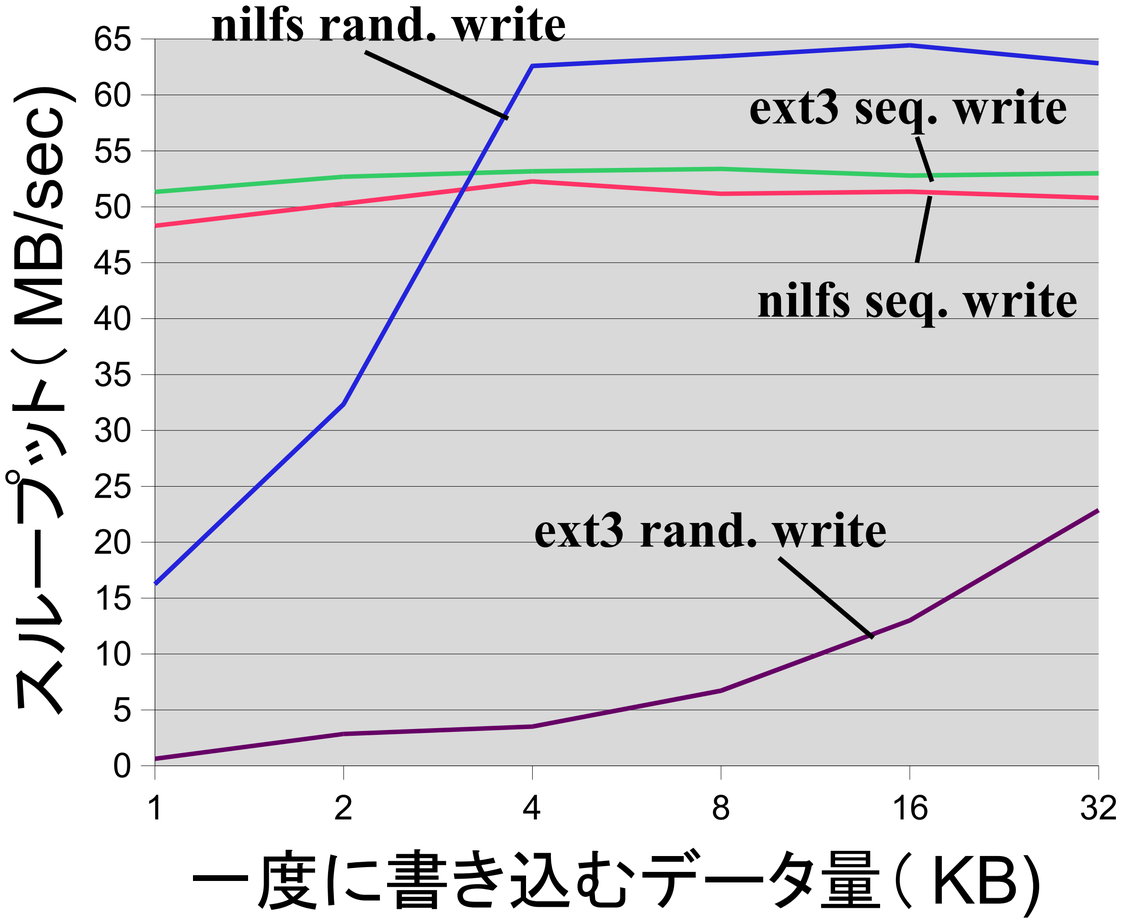

write with O_SYNC

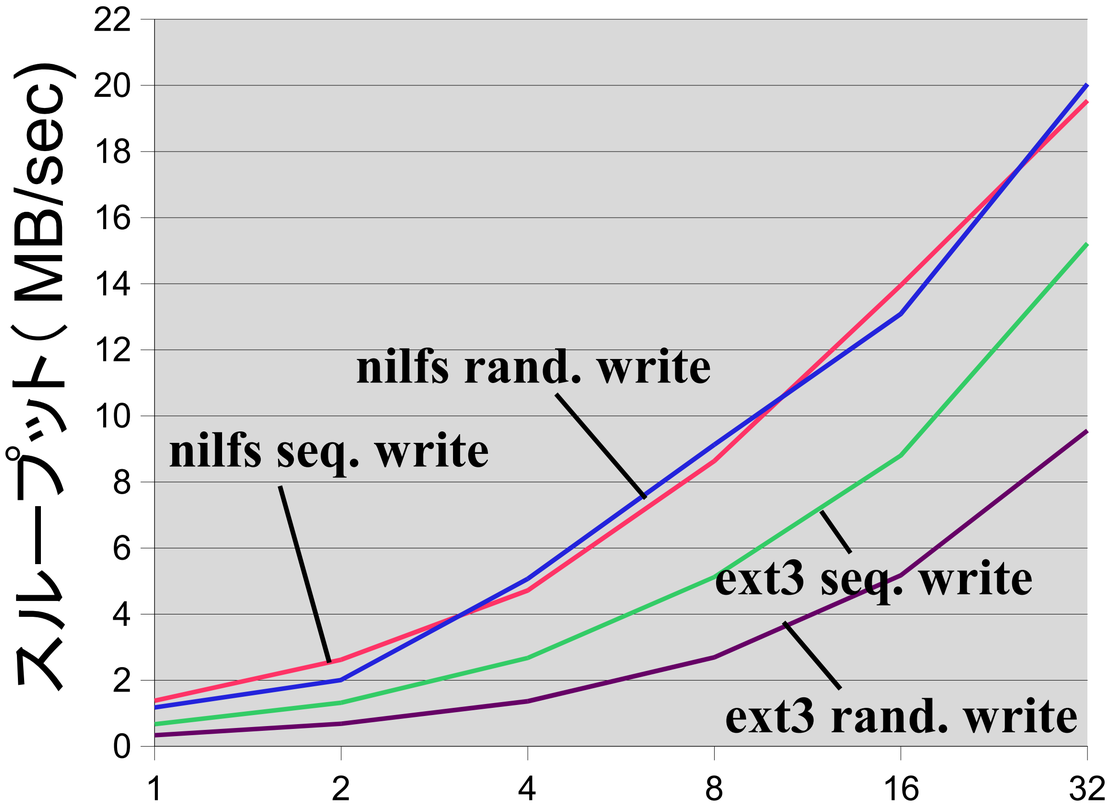

- 連続書き込み(ext3)
- ランダム書き込み(ext3)
- 連続書き込み (nilfs)
- ランダム書き込み (nilfs)

- ランダムライトは上書き
- シーケンシャルライトは新規作成
- ファイルサイズは 512MB

読み込みのスループット

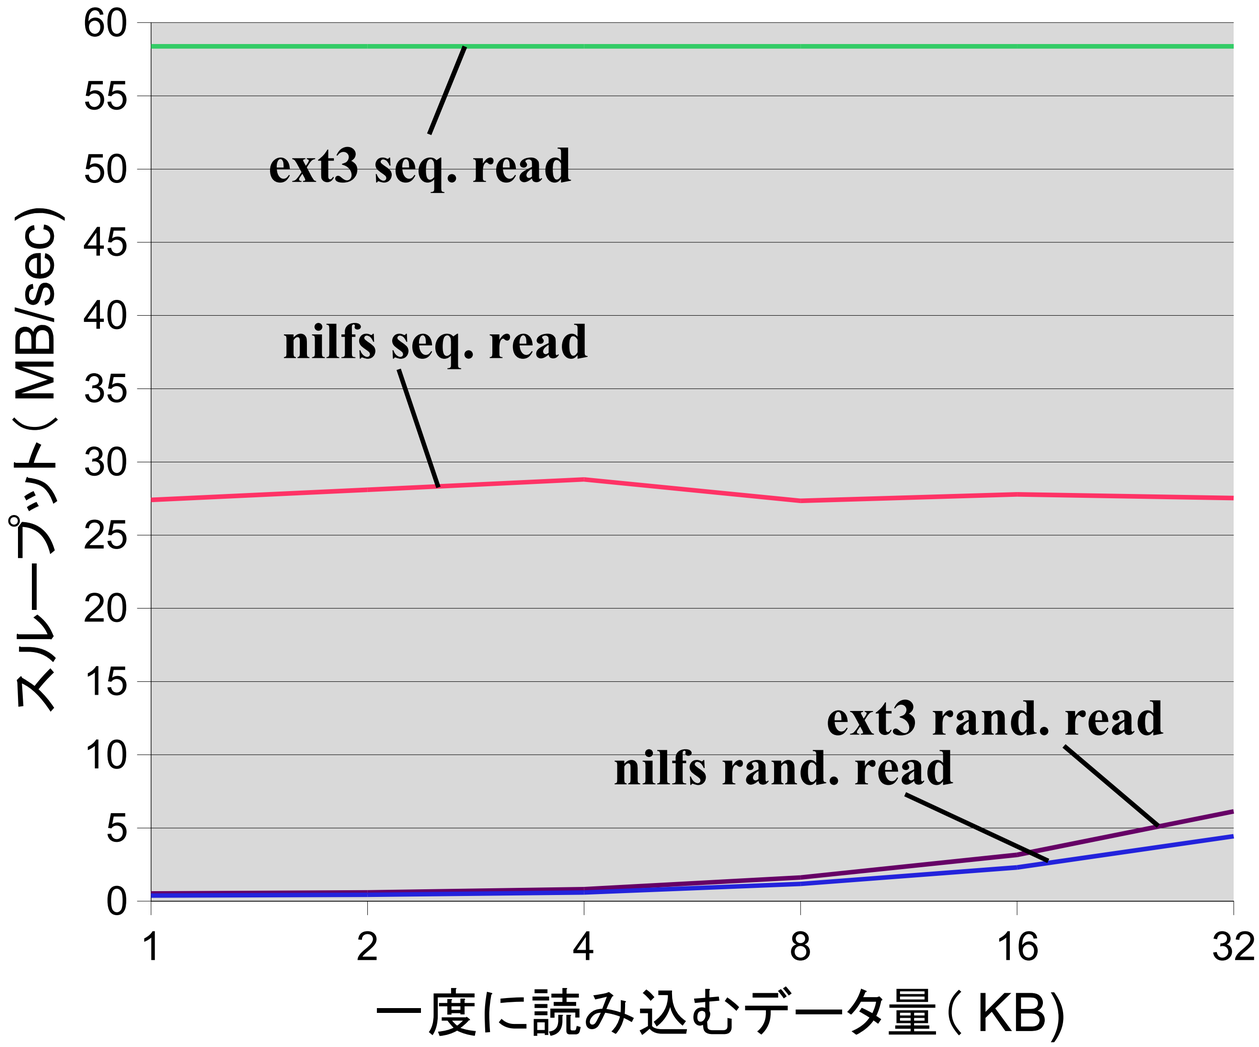

- ファイルサイズは 512MB
- 先読み設定はデフォルト (read_ahead_kb=128kb, hdparm read_ahead=256kb)
- キャッシュの影響を排除するため，ファイル作成後 umount/mount を実施

B-Tree の先読みや，論理セグメントの一定サイズごとの分割による局所化，その他のチューニングを検討中

開発環境

- CVS
- LXR (LXR Cross Referencer)
  - カーネル内部調査や，関数仕様の確認に必須
  - Linux バージョン更新の追従に必須
- Pukiwiki
  - 検討仕様の整理，ノウハウ蓄積，bugtrack に活用

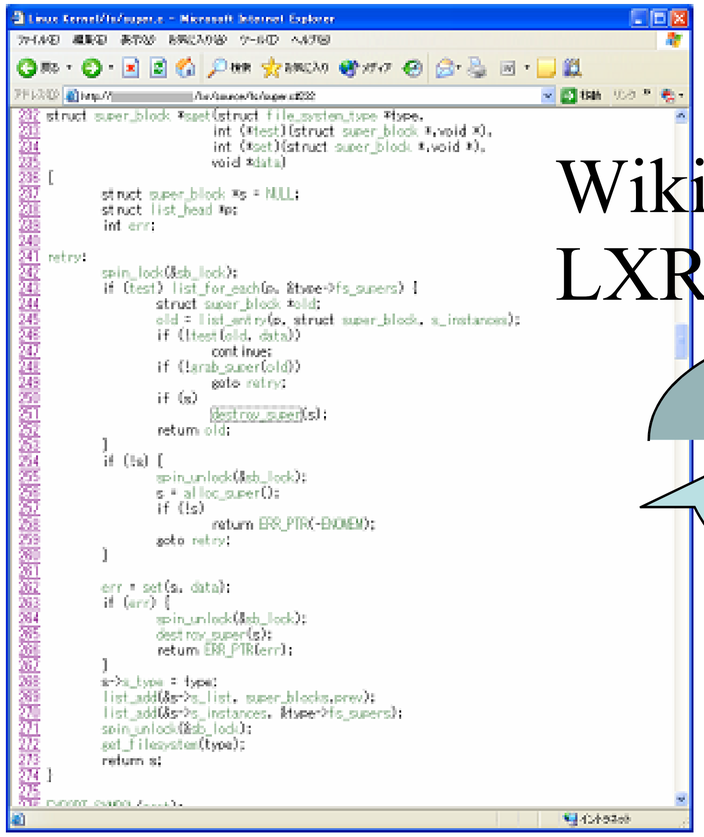

Wiki との連携により
LXR を補完

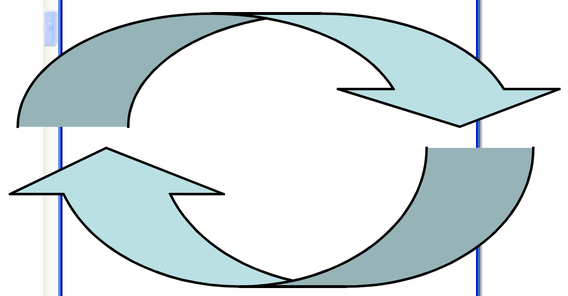

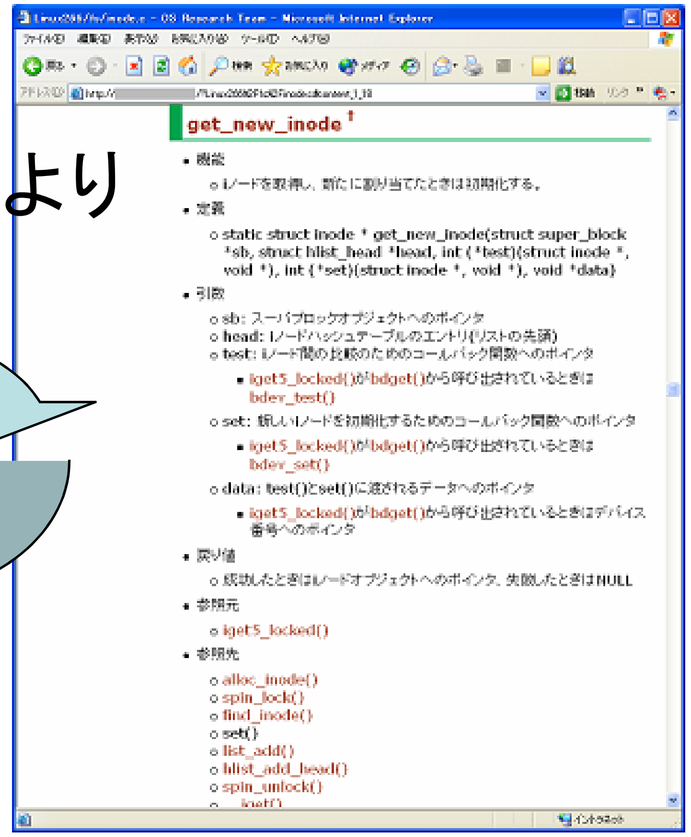

デバッグ環境

- kgdb
  - Linux カーネルのバージョンに追従せず
- qemu (emulator)
  - spinlock のデッドロック解析には役立った
  - SMP に起因する問題，タイミング問題などに適用できない
- printk()
  - 大量のメッセージ出力により，欠落が発生
  - /proc/kmsg の cat，リダイレクションが良好

デバッグ経験

- 典型的なバグ
  - 参照カウンタの増減ミスによるメモリリーク，メモリ逼迫
  - スピンロックやセマフォのデッドロック
    - put/get, lock/unlock 系操作をマクロでデバッグ版に置換し，網羅チェック
    - スピンロックは正しい使い分けが重要 (spin_lock, spin_lock_irq, spin_lock_irqsave,...)
- はまった落とし穴
  - inode からブロックサイズを得るには i_blksize ではなく, i_blkbits を使う (i_blksize は Disk I/O の最適サイズ)
  - alloc_page() で得たページは __free_page() で返す. free_page() は __get_free_page() で得たページの解放用 (一ヶ月リークがとれませんでした. やめてよね ...)

まとめ

- Linux ログ構造化ファイルシステム nilfs を開発
  - 信頼性・可用性と性能の両立に期待
  - 追記性を活かした高速なスナップショット機能を搭載
  - ジャーナルFSでないもう一つの選択肢を提供
- nilfs v1 を GPL で近日公開予定

今後の課題

- GC 実装
- バグ取り / チューニング
  - ディレクトリの B-Tree 化
  - B-Tree 対応先読み
  - シークを 1 回でも減らすならなんでも ...
- ユーザインタフェース
  - fsck
  - スナップショット関連（ 時間軸ツール : tls, tdiff, tgrep...）
- スナップショットの動的拡大 / 縮小
- GRUB 対応
  - スナップショットからのブート
- スナップショットを含んだバックアップ
- df，ディスクフル問題
- セキュリティ
- ...

『Linux 用ログ構造化ファイルシステム』

ご清聴ありがとうございました.