メモリ管理の動向

富士通　小崎資広
<kosaki.motohiro@jp.fujitsu.com>

Who am I?

- 2008年にLKMLデビュー
- 2008年以降について集計するとvmscan.cを一番いじった人
- Linuxのメモリ管理界隈でSplit-LRU VMの共同開発者として有名（ようするに無名）
- @ITでKernel watchというLinuxの解説記事を連載している。LKMLのメールを全部読んでいる数少ない日本人の中の一人
- 2008年のLKMLでのコミットレート
  - Signed-off-by数がTOP10%にぎりぎり入るぐらい
  - mm/ ディレクトリ以下に限定すると10位
  - Reviewed-by 数はLKML全体で7位

言葉の壁？

... once again demonstrating that Aussies a sense of humor beyond the grasp of the rest of us mere **mortals**.

-- Paul Jackson

2008年のメモリ管理トピックス

- –mm tree gone
- Split-LRU VM
- Lockless pagecache
- MMU notifier
- Mem-cgroup
- Reclaim bail out
- SLQB

-mm tree gone

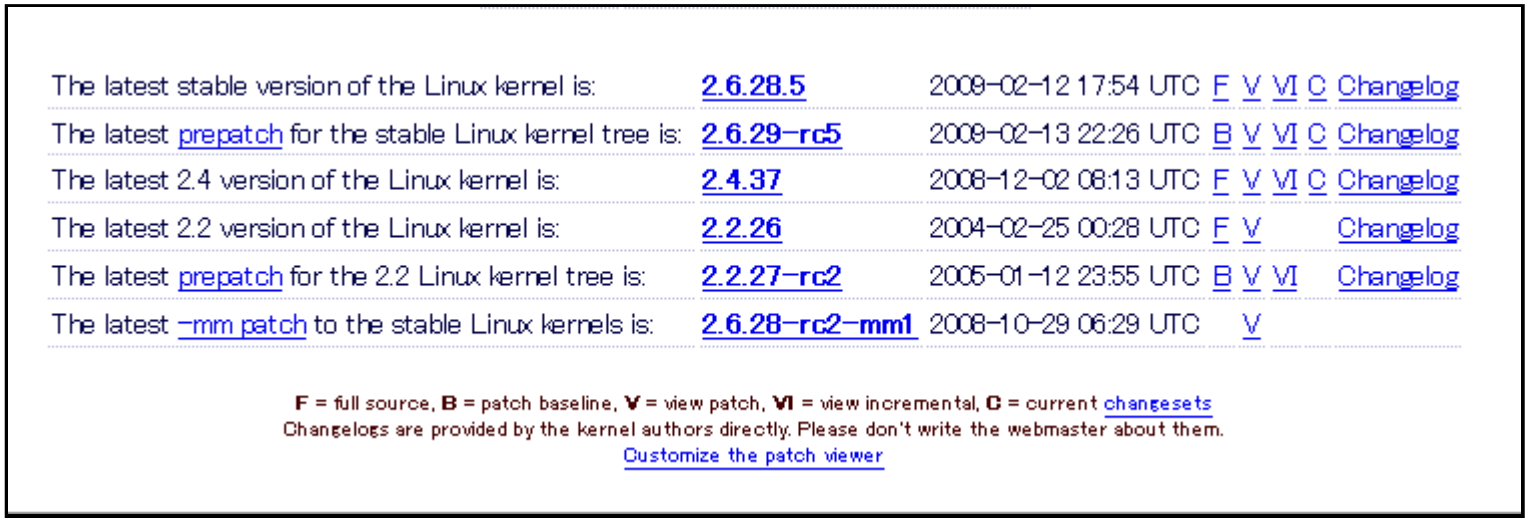

The latest stable version of the Linux kernel is:	2.6.28.5	2009-02-12 17:54 UTC	F	V	VI	C	Changelog
The latest prepatch for the stable Linux kernel tree is:	2.6.29-rc5	2009-02-13 22:26 UTC	B	V	VI	C	Changelog
The latest 2.4 version of the Linux kernel is:	2.4.37	2008-12-02 08:13 UTC	F	V	VI	C	Changelog
The latest 2.2 version of the Linux kernel is:	2.2.26	2004-02-25 00:28 UTC	F	V			Changelog
The latest prepatch for the 2.2 Linux kernel tree is:	2.2.27-rc2	2005-01-12 23:55 UTC	B	V	VI		Changelog
The latest -mm patch to the stable Linux kernels is:	2.6.28-rc2-mm1	2008-10-29 06:29 UTC		V			

F = full source, B = patch baseline, V = view patch, VI = view incremental, C = current changesets
Changelogs are provided by the kernel authors directly. Please don't write the webmaster about them.
Customize the patch viewer

- -mm は従来α版カーネルの役割を果たしてきた
- 最終更新が4ヶ月前
- mmotm（mm on the moment）に移行
- 大きな混乱は起こっていない

きっかけ

- ここ数年はメモリ管理の変更は少なかった
- メインライン向けのパッチが-mmにも適用できる
- Mmotm自体は前からあったが誰も使わず
- 去年、6月末にlockless pagecacheとSplitLRU VMがほぼ同時にマージ
- パッチコンフリクトで-mm treeが壊れる。panic頻発
- 次々作られるパッチ。-mmとmmotmの差が広がる
- メモリ管理開発者がmmotmベースのパッチを投稿するようになる
- ますます-mmツリーのリリース頻度が落ちていく

Split LRU VM

- 従来2本だったページ管理用のLRUリストを5本に分けるパッチ(ゆえにSplit LRU)
- ページ回収処理のスケーラビリティーを改善

多すぎるページ数問題

- システムのメモリ量はどんどん増える
- x86_64は4kページあたり64byteのstruct page。つまり1GBあたり16MBのstruct page。1TBなら、なんと16GB。
- この巨大なLRUリストで捜査していかないとページ回収できない
- リスト走査はキャッシュヒット率低い
- 回収速度はどんどん悪化

回収できないページが多すぎる

- DBによっては、大量の共有メモリを使う。
  搭載メモリの8割が共有メモリに使用されたりする
- Linuxはメモリプレッシャーが低いうちは要Swap I/Oページは回収対象にしない
- キャッシュミスしながらページをチェックすると、8割の確率で捨てられないページ。それを何百万回もループ回す。速度が出るわけがない
- MlockされたページをつかうオンメモリDBも流行ってるけど、結果は同じ

従来のLRU

いろいろな種類の回収ページが1つのリストに混じっている

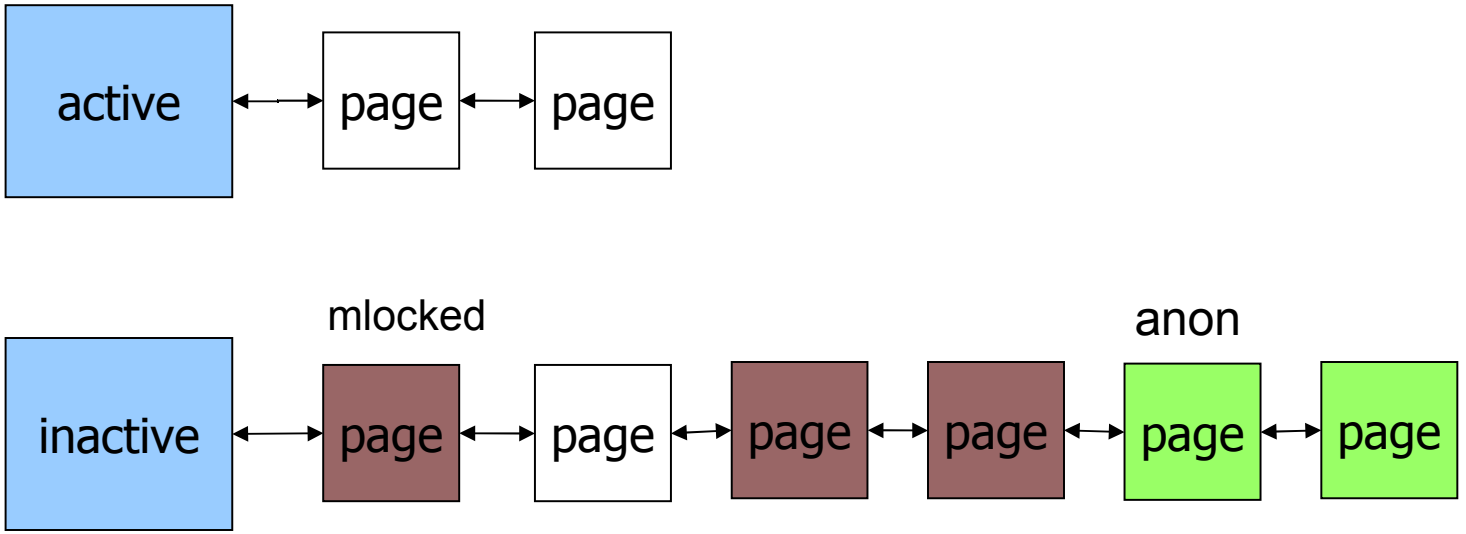

Mlocked pageは常に回収できない。
anon pageは低プレッシャーの時は
回収すべきではない。

Split LRU

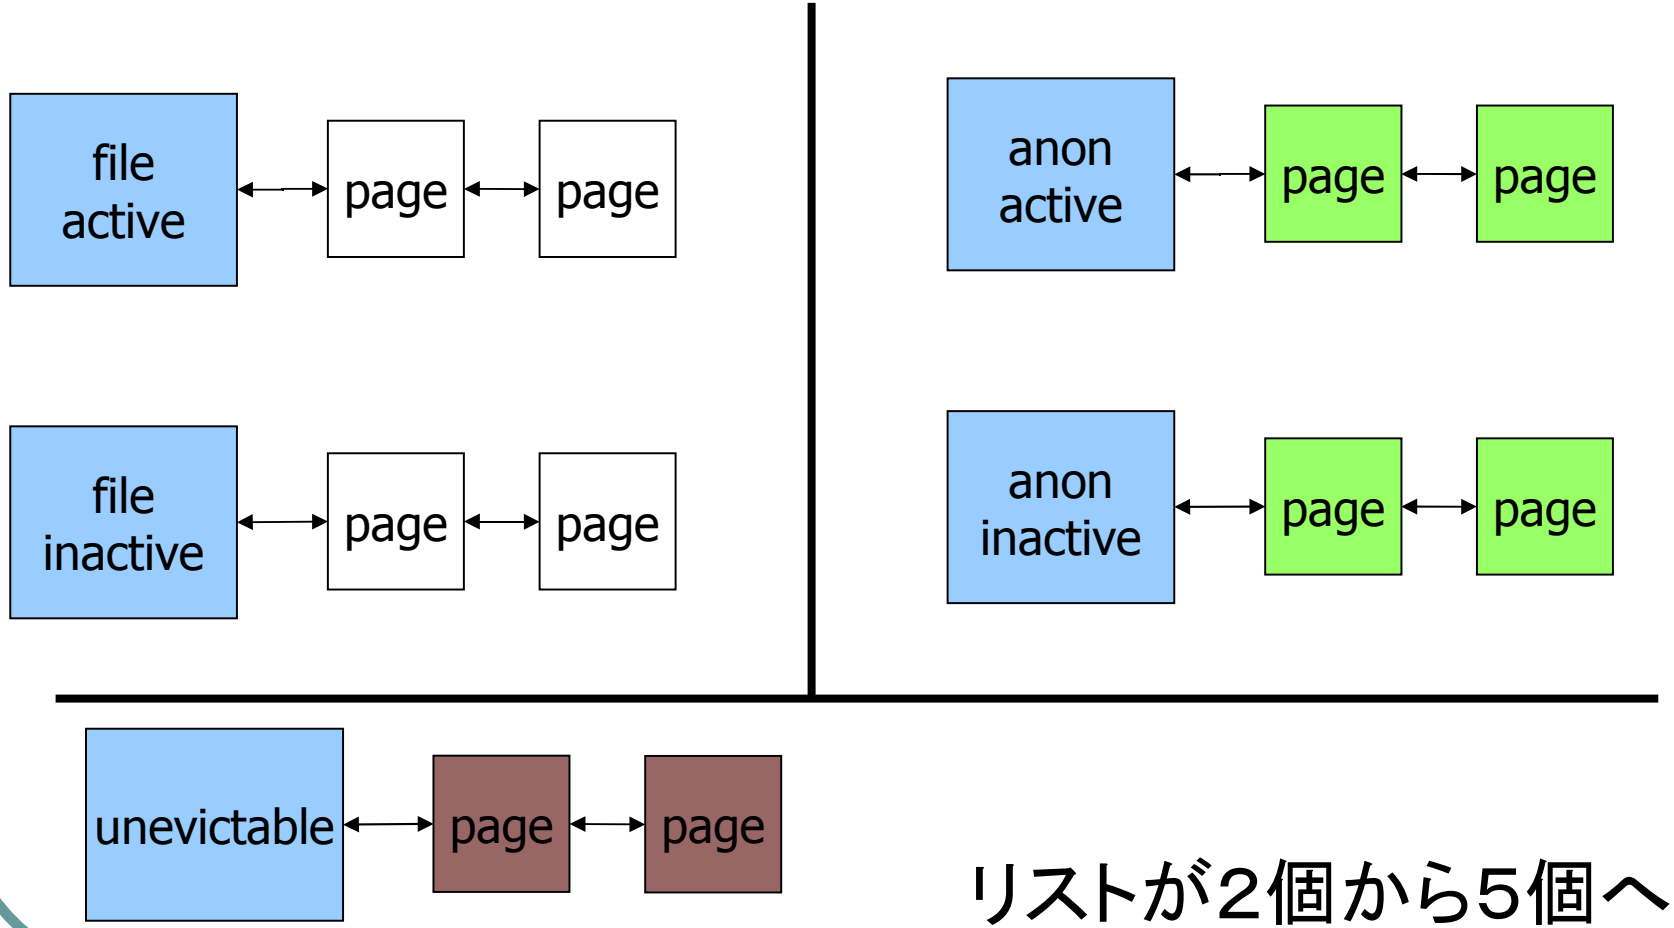

リストが2個から5個へ

スキャン量のバランシング

- LRUを分けたので、anonかfileかのどちらを優先してスキャンするのか方針が必要
- 平均して、スワップアクセスは通常ファイルの3倍遅い。スワップアウトよりファイルキャッシュ破棄を優先したい
- しかし、tmpfsのキャッシュが不要になることはよくある。anonをまったくスキャンしないのはNG
- Workloadに応じて動的に比率が変わるのが賢い
- 最近のスキャン数：最近の実際に捨てたページ数の比を使って調整

結果

> Hi Rick,
>
> I just want to let you know your improvements in the
> Memory manager work awesome on s390 when using
> kvm.
> Before, we were running into a limitation in vmscan
> with **80 Websphere** servers running in a 45gig host.
> Now we're limited by the bandwidth of the swap target
> **200 Websphere** servers on the same host work well.

Lockless pagecache

- 従来多CPUはハイエンドマシンにのみ存在。ハイエンドマシンは用途が限定的
- 時代はメニーコア。CPU数が増えればロック競合は増える
- 多CPUがローエンドに降りてきた
- lockless化への要求が増している
- 保守が難しくなるので明白な性能メリットがないとマージされない

Lockless pagecache

- 仮想OSのOSイメージや、通常ファイルとしてデータをストアするDBなど巨大ファイルが一般的に
- ファイル単位にロックがあり、競合が発生しやすかった

rwlock starvation problem

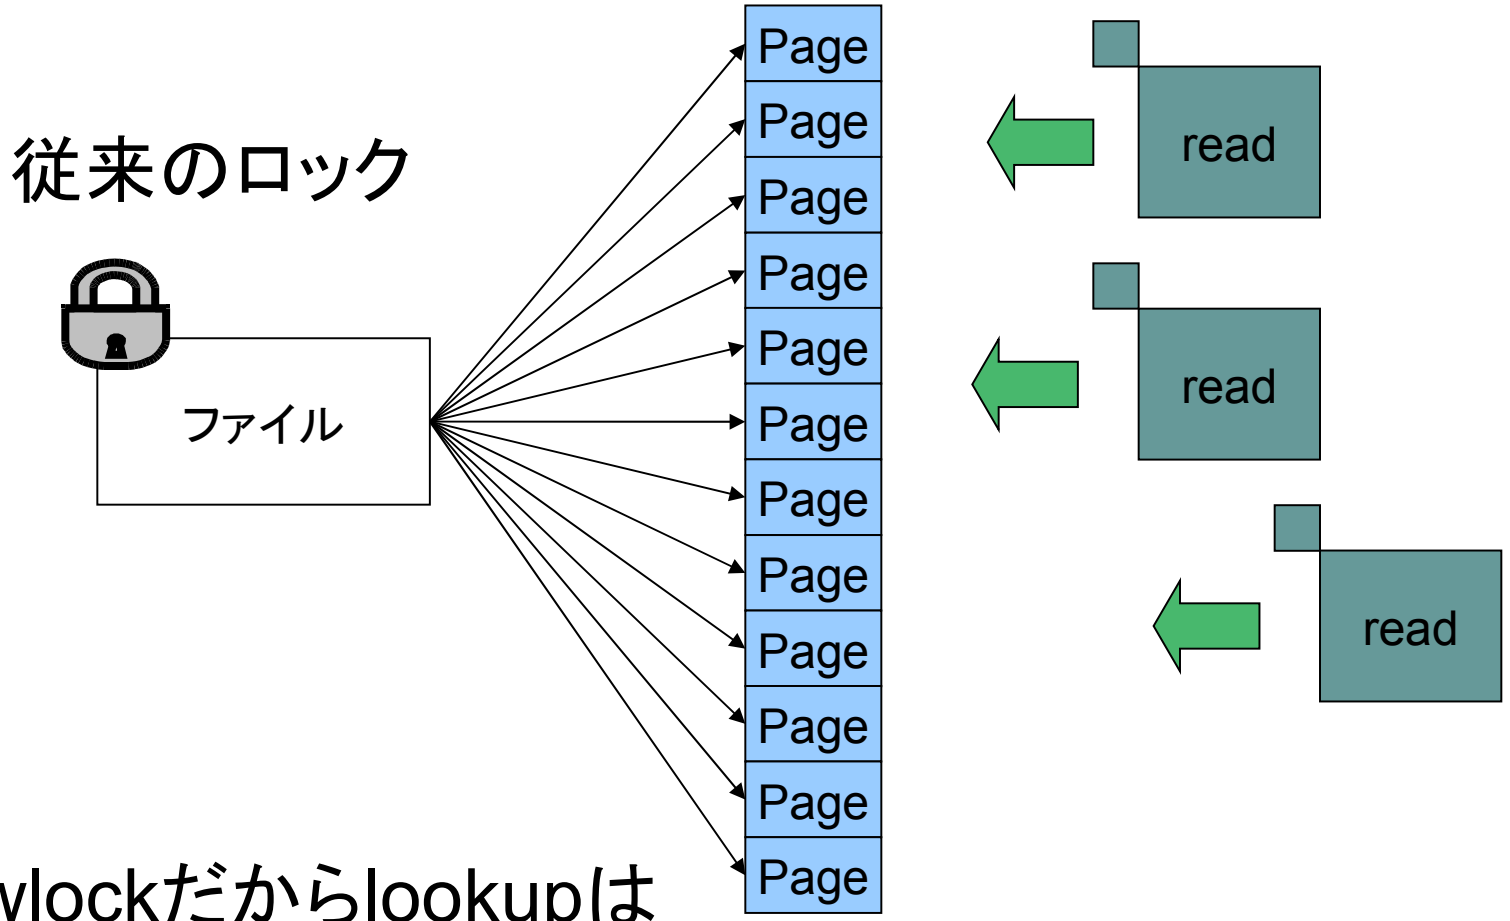

rwlockだからlookupは
複数同時に可能

rwlock starvation problem

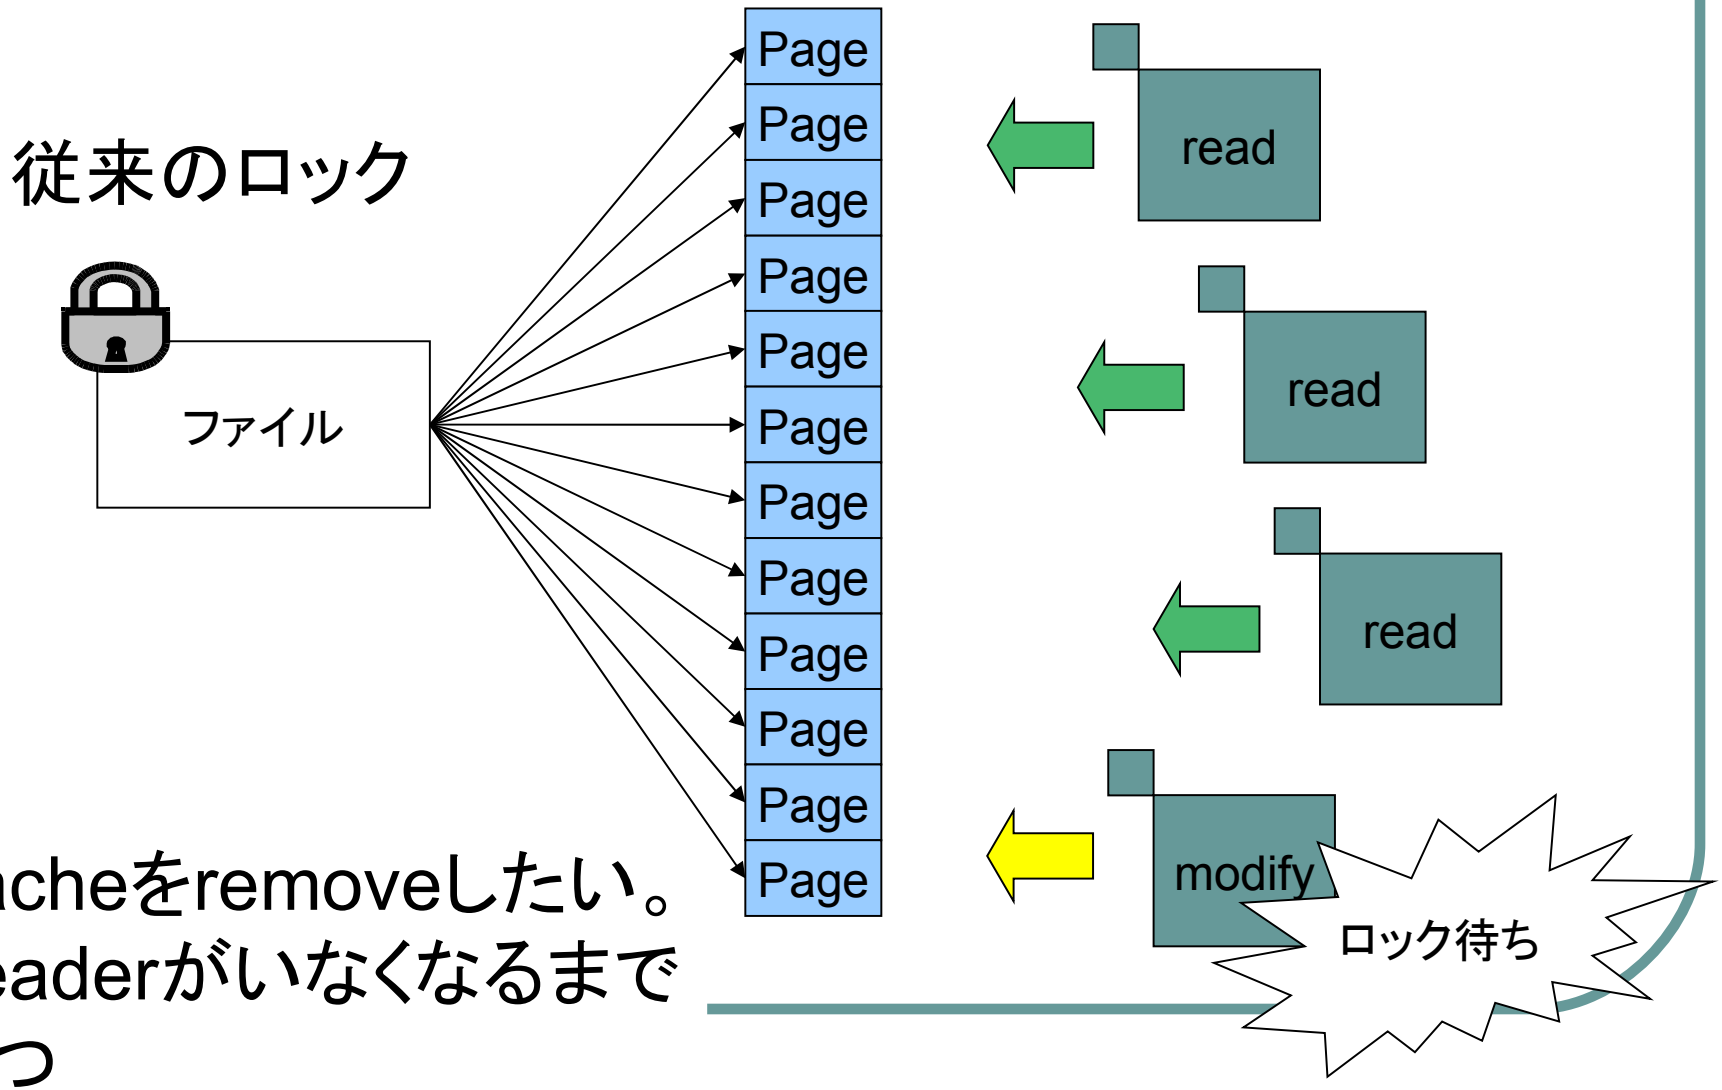

Cacheをremoveしたい。
Readerがいなくなるまで
待つ

rwlock starvation problem

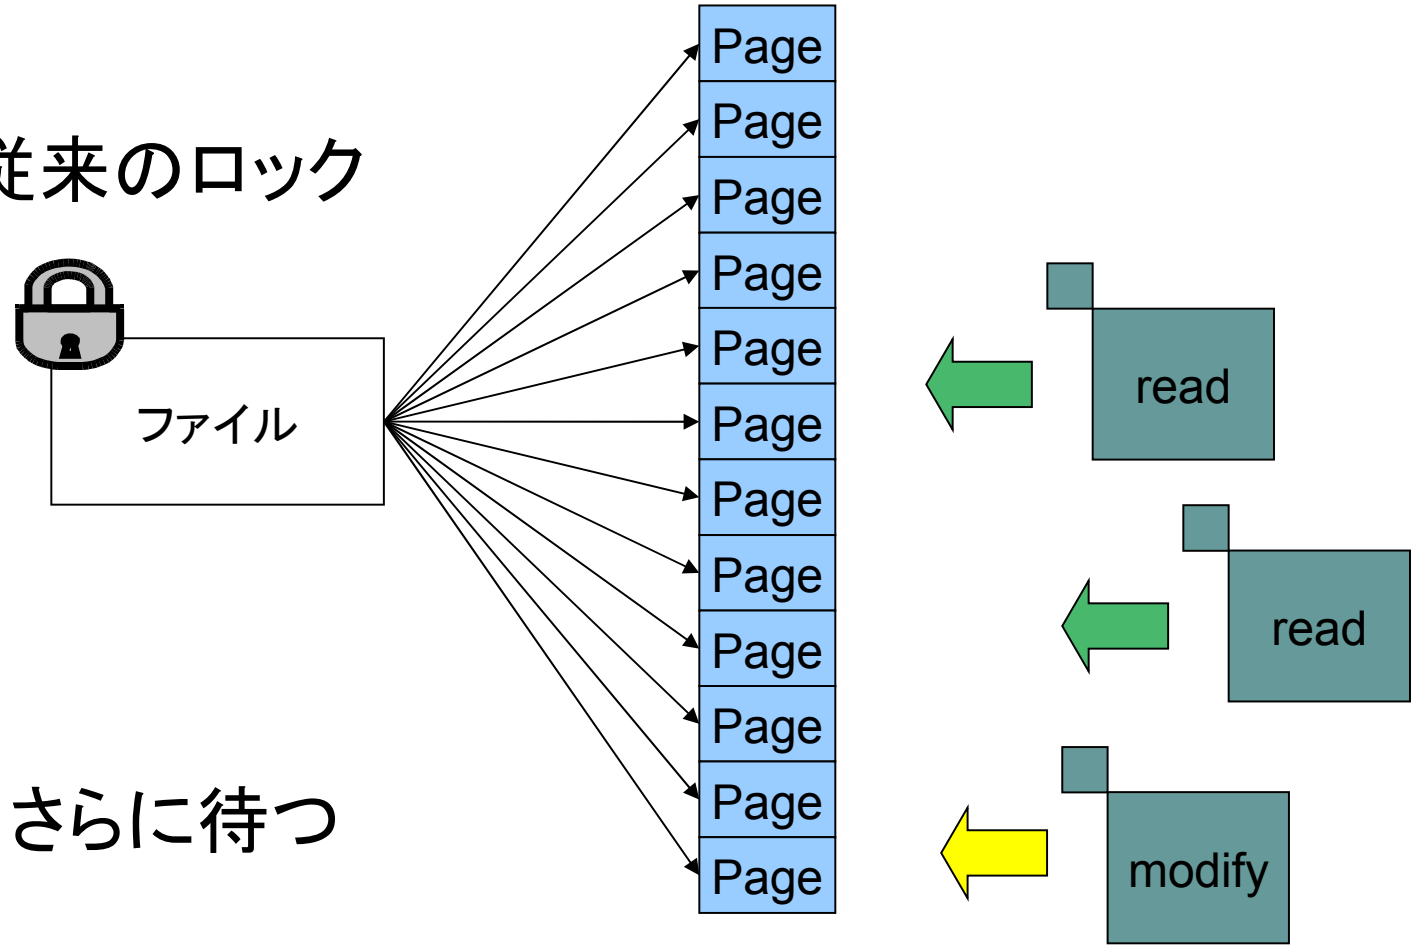

rwlock starvation problem

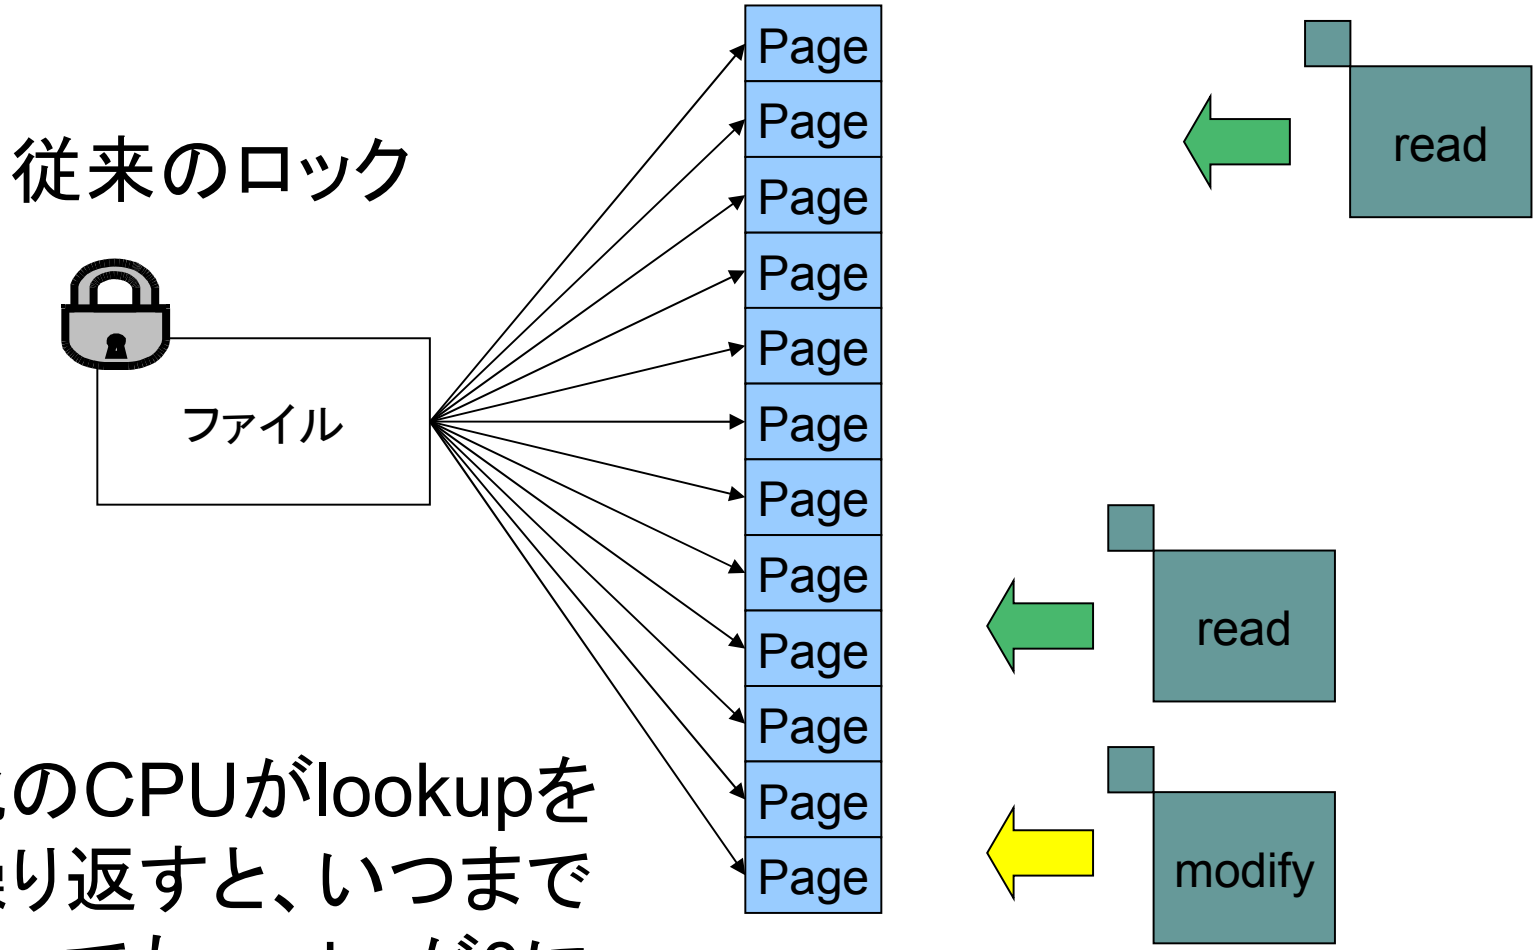

他のCPUがlookupを繰り返すと、いつまでたってもreaderが0にならない

何が起きるか？

- メモリ枯渇時にファイルキャッシュを回収する
- Cacheが外せないとメモリの空きが増えない
- メモリ回収がwrite lock starvationで待たされる
- 結局処理が進まなくなる
- メモリ不足が深刻化して、reader側の数が減ると解決、ライブロックにはならない。しかし、レイテンシは大きく悪化
- この部分をlockless化して競合を排除

RESULT

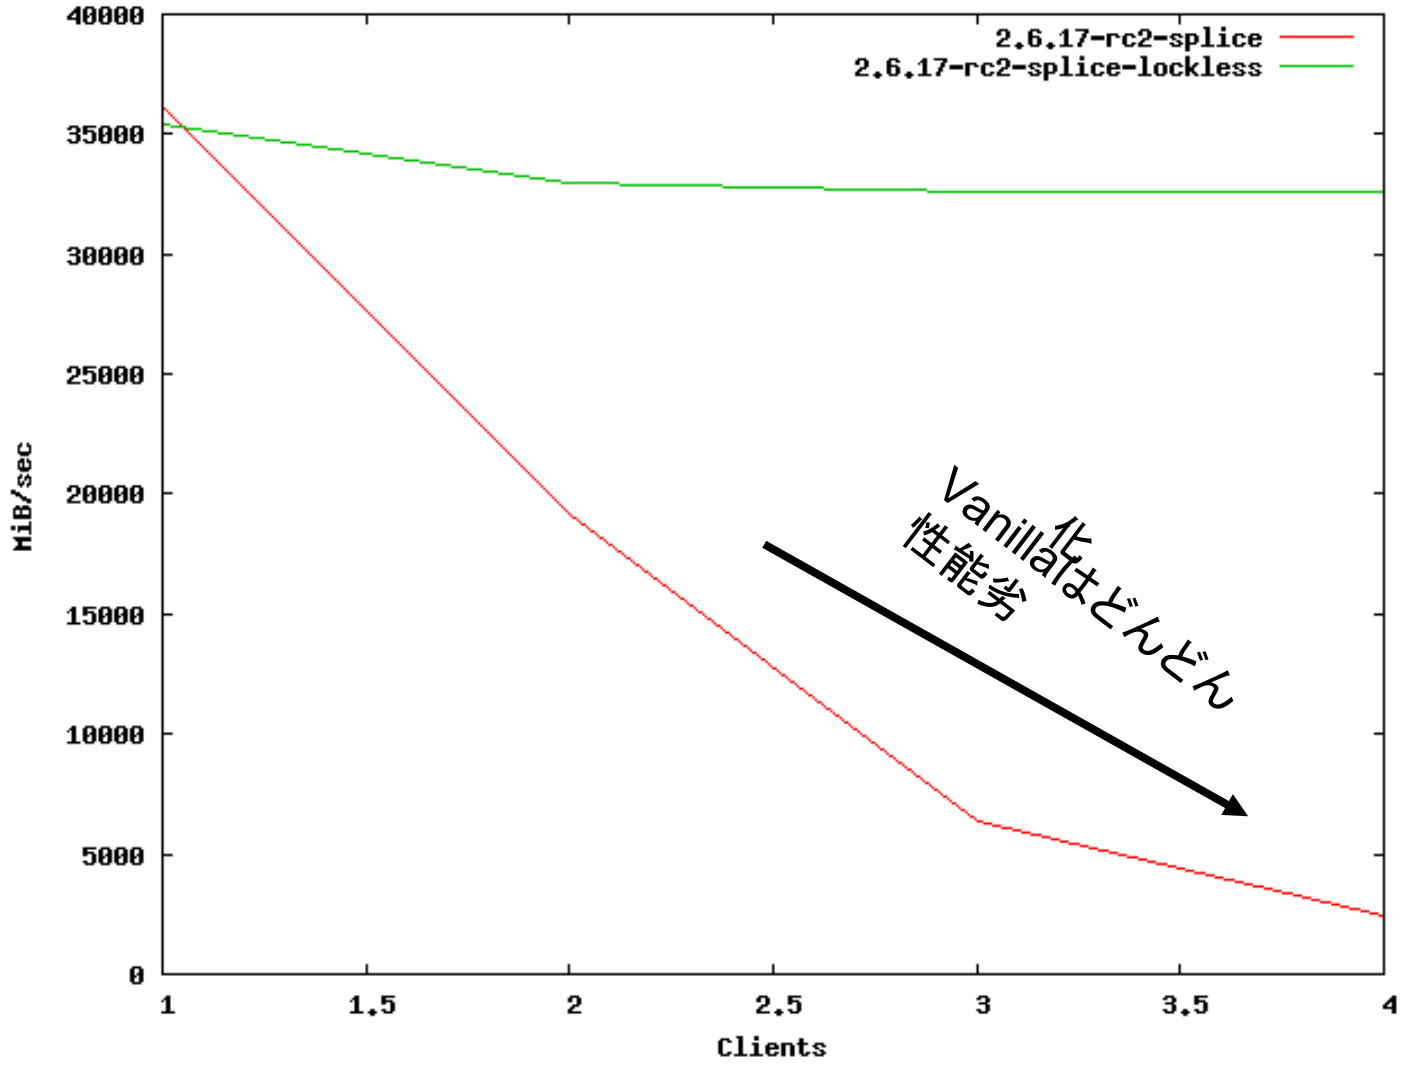
2.6.17-rc2-splice
2.6.17-rc2-splice-lockless
MiB/sec
Clients
40000
35000
30000
25000
20000
15000
10000
5000
0
1
1.5
2
2.5
3
3.5
4
Vanilla化はどんどん
性能劣
約33G
約2.5G

MMU notifier

- 時代は仮想化。仮想化支援も流行の1つ
- 従来、KVMではGuestに割り当てたページをswap-outできなかった
- このパッチはKVM Guestのswap-outを可能にする
- Hostのswap-out時にKVMにspte(secondary pte)を無効にするための通知を送信する

KVM spte (secondary pte) 基礎

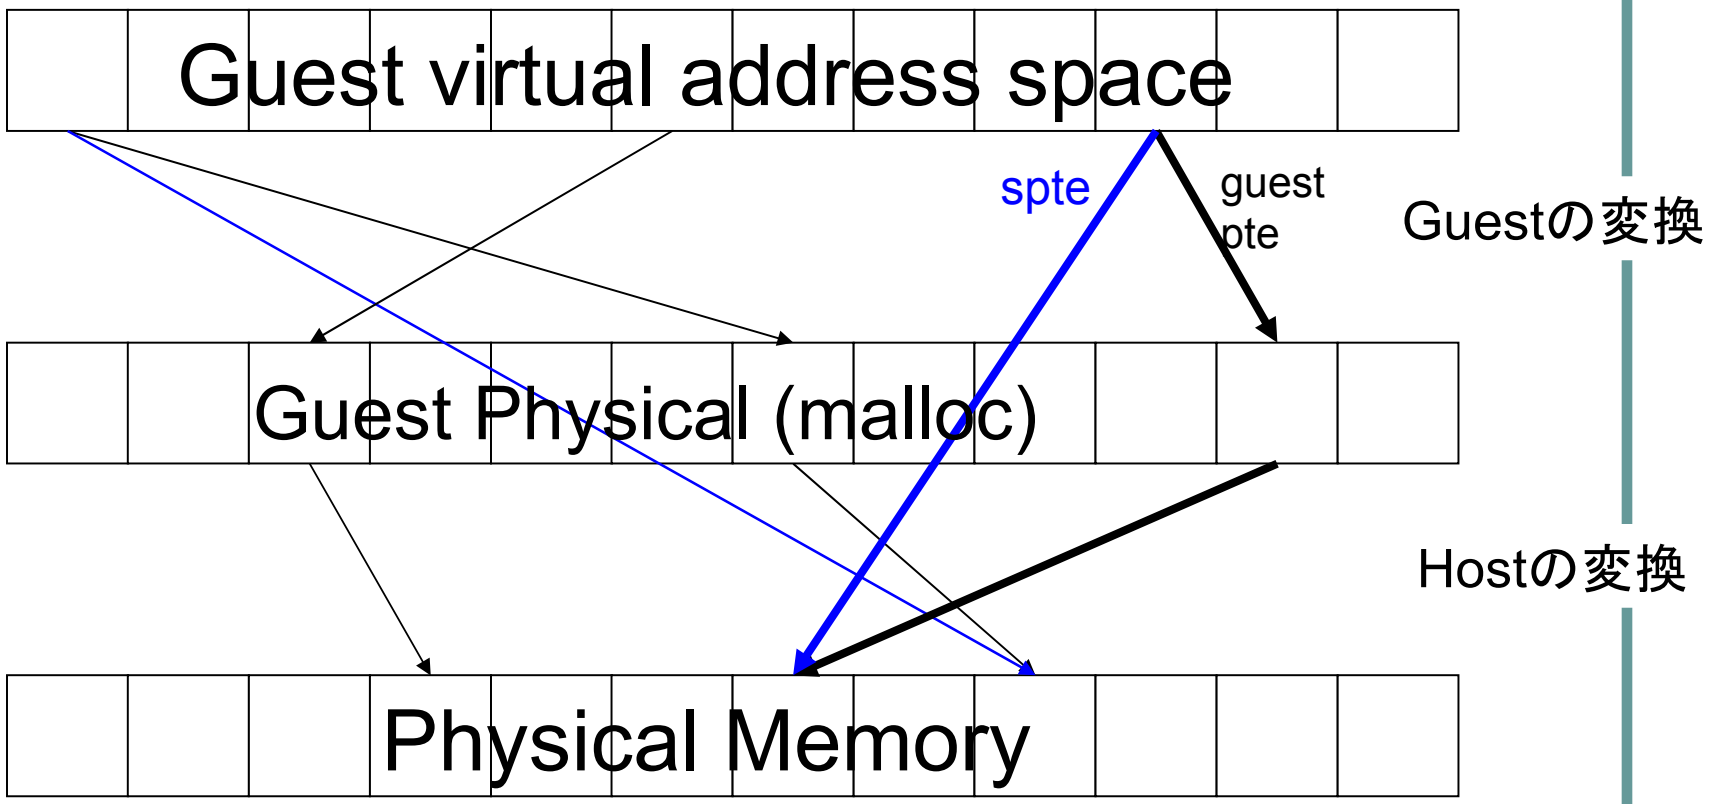

毎回2段階の変換は遅い。Guest virtual -> Physical の変換テーブルを隠し持つ。それがspte（青）

KVM spte cont.

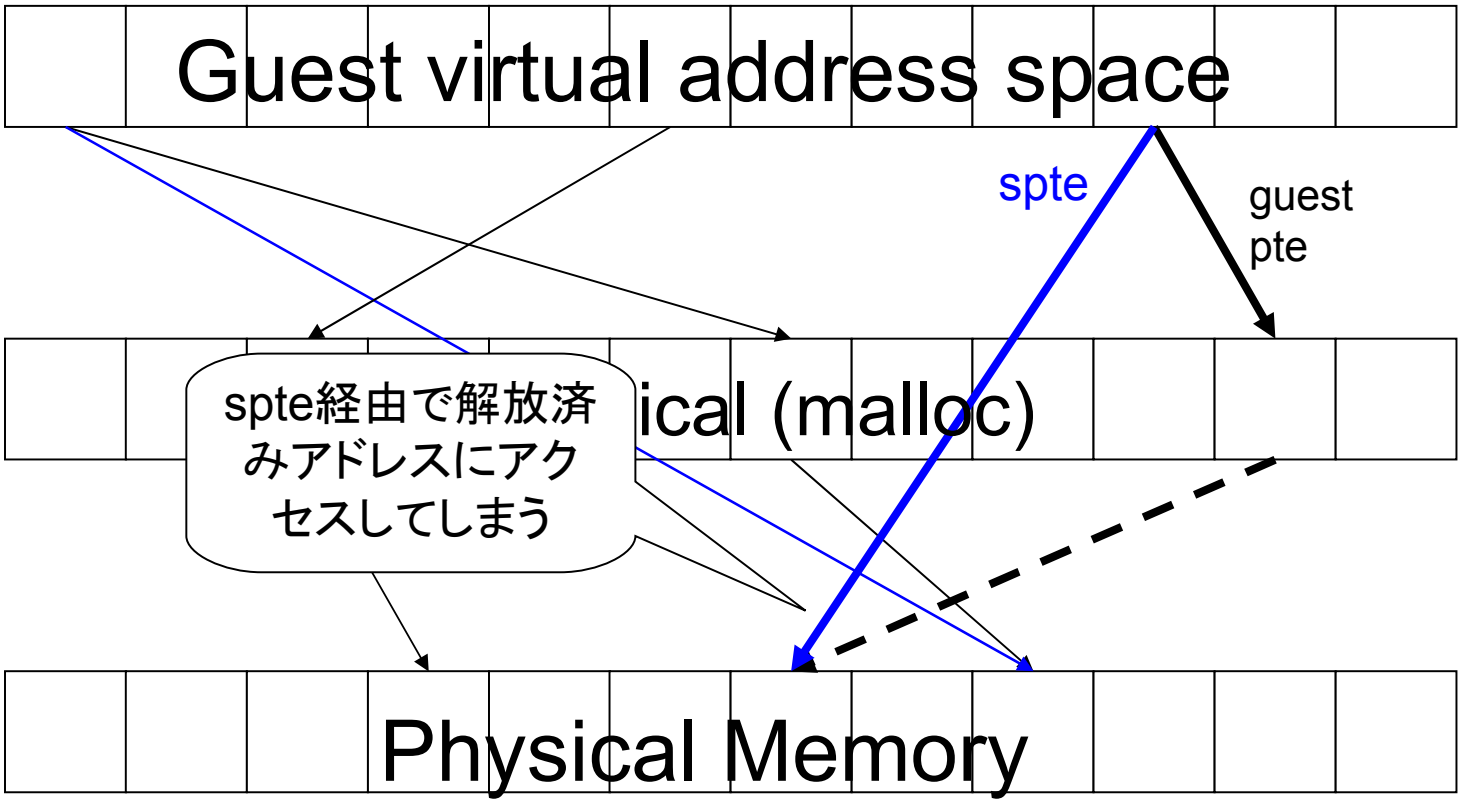

Guest Physical->Physical 変換はHost側でunmapできるが、
spteはHostからは見えない。このままでは不正参照発生

KVM spte cont.

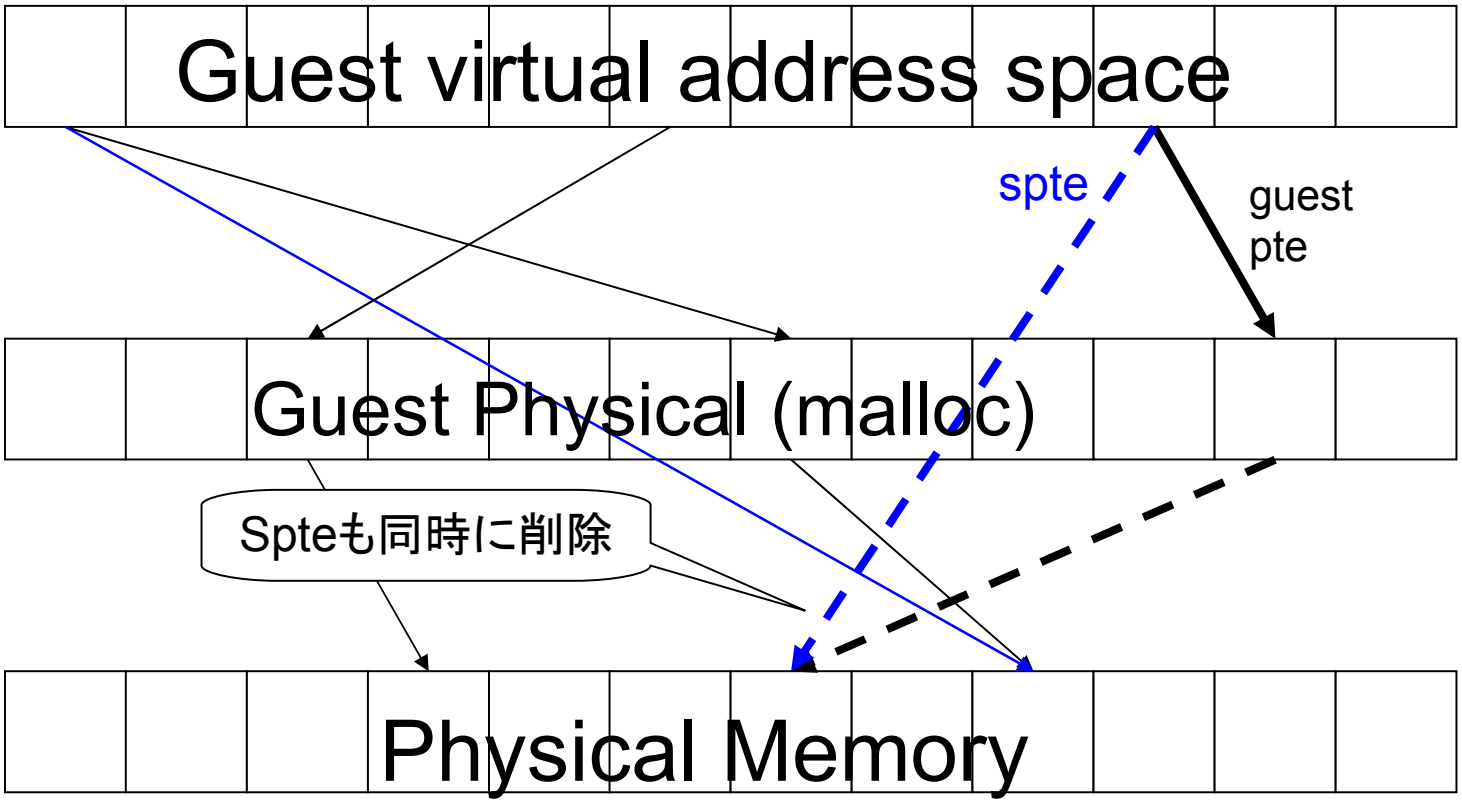

Guest Physical(host virtual) unmap時にKVMに通知。
KVMはspteを無効化。Guestアプリからは透過的

Mem-cgroup

- 3ヶ月前に聞いたばかりよね？

Reclaim bail out

- ページ回収時に回収しすぎるケースがあった。
- 活発なworkload（ゲームとか）を実行中はほとんどのpageに参照bitがたっている場合がある
- その場合、なかなか回収できないのでVMはスキャン量を上げていく
- トライするスキャン量が上がった後、回収可能ページが大量に見つかると非常に多くのページを回収してしまう
- スキャン量だけではなく回収量によってもreclaim中止すべき。
- 一見、何も問題ない提案に見えるが・・・

NAK！理由は忘れた！

There was a reason for not doing this, but **I forget** what it was. It might require some changelog archeology.

-- Andrew Morton

開発者は納得しない

- 侃々諤々の議論のあと、理由なしのNAKはダメだよね。という話になりマージすることに
- Akpm: finger crossed（神に祈るわ）
- ところで、-mmにマージされるとパッチ作成者と関係者に通知メールが飛んでくる
- それを見ると・・・・

patch descriptionに加筆

akpm: a historical interlude...

We tried this in 2004:

:[PATCH] vmscan.c: dont reclaim too many pages
(snip)

And we reverted it in 2006:
(snip)

And we haven't demonstrated that whatever problem caused that reversion is not being reintroduced by this change in 2008.

いや、実は・・・

> I have ML archive at that time and I think
> I can explain why not reintroduced.
> please wait soon.

thanks - I was hoping you would ;)

結果

Hackbenchでメモリを使い切るぐらい大量にプロセスを生成
（単位：秒）

	vanilla	bail out	
avg	185.4	142.0	(30% up!)
std	74.2	55.9	
min	46.1	62.5	
max	305.0	227.8	

SLQB

- いい加減SLABを捨てたい
- SLUBが未だにSLABに負けるケースがある。
- SLQB：SLUBより高速なアロケータだと表明
- パラレルに進む様々な議論。とても追えない
- ベンチマーク競争大流行。SLUB, SLQBともにどんどんコードが変わる。
- 勝負の行方は不透明。しかし、どちらが勝ってもユーザにはメリットあり

例：High order allocation 是非論争

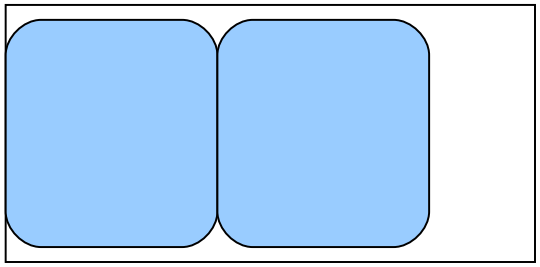

Page_size÷object_sizeが端数が出る
ことがある

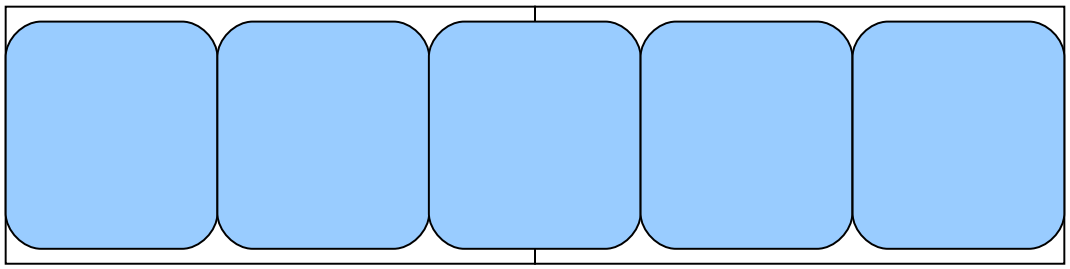

複数のページをくっつけると、
端数を減らすことが出来る

何ページ用意するのが最適か？

Benchmarks

Benchmarks are **essential**, please. Good ones.

-- Andrew Morton

Questions?

なんでマージしないの？

Yes, if this is really in use by everybody,
then **not merging it is kind of pointless**.

-- Linus