

## システムソフトウェア研究の最前線

慶應義塾大学 河野健二



## 自己紹介



- 河野健二（慶應義塾大学理工学部情報工学科）
  - 東大助手、電通大講師、慶應義塾大学准教授を経て、同教授
- 専門分野
  - オペレーティングシステムおよびシステムソフトウェア
    - ディペンダブル・コンピューティングにも少し浮気
- 主な論文
  - IEEE Trans. on Computers, USENIX ATC, ACM EuroSys, IEEE DSN, ACSAC, IEEE ICDCS, ACM VEE, ECOOP...
- 受賞
  - 2000年 情報処理学会山下記念研究賞
  - 2000年、2009年、2010年、2013年 情報処理学会論文賞
  - 2014年 日本ソフトウェア科学会ソフトウェア論文賞
  - 2015年 IBM Faculty Award
  - 2015年 ACM Service Award
  - 2016年 日本ソフトウェア科学会基礎研究賞

## システムソフトウェアの研究トピック



- ACM SIGOPS == 国際的な研究コミュニティ
  - SOSP/OSDI には毎年 600 名程度集まる
  - アクティブな研究者は 150名ぐらい？
- 研究トピックは多岐に渡る
  - Many-core/Multi-core 向けのオペレーティングシステム
    - GPU のスケジューリング、GPUの仮想化など
  - ライブラリOS、仮想化支援ハードウェアによるその支援
  - NVM(不揮発性メモリ)を利用したストレージ、KVS, FS
  - システムソフトウェアのバグ解析
    - Linux や Apache, MySQL 等のバグ解析
  - などなど

## システムソフトウェア研究の楽なところ



- システムソフトウェアは中間管理職
  - “アプリケーション”という名のわがまま上司
  - “ハードウェア”という名の身勝手な部下

- どこが楽なの？？？



## システムソフトウェア研究の楽なところ



- 研究テーマを考える必要がない
  - 上司のわがままを聞いてあげればよい
    - アプリケーションの進化が新しいテーマをもたらしてくれる
  - 部下の身勝手に付き合ってあげればよい
    - ハードウェアの進化が新しいテーマをもたらしてくれる
- 「もうやることない」と思っても向こうから研究テーマがやってくる

## 研究テーマの移り変わり



- 私自身の経験から：
  - 1994～2000年ぐらいまで：
    - LANやPCクラスターを前提とした closed な分散システムの研究
  - 2000～2010年ぐらいまで：
    - Peer-to-Peer などの Internet-scale の分散システムの研究
  - 2005年～現在まで：
    - 仮想化をベースとしたクラウドのための基盤技術の研究
  - 2013年～現在まで：
    - GPU や non-volatile memory など新しめのデバイスのための基盤

## 研究方法の移り変わり

- 私自身の経験から:
  - 1994
  - 1999
  - 2005
  - 2014
  - 現在
- 1994～2000年ぐらいまで:
  - “空想”でモノを作っていればよかった
  - きつこうい機能があると便利だろうな
  - しよぼい実装にしよぼい実験で許された
  - スクラッチからプロトタイプを作る
- 2000年ぐらい～現在まで:
  - “現実”のシステムの“現実”の問題を解け
  - 問題が存在することを**定量的**に示すことからスタート
  - 提案方式を“現実”のシステムに“組み込む”必要あり
  - しよぼい実験は許されない

## システムソフトウェア研究の辛いところ

- “空想”の問題を解いても評価されない
- “正しさ”を証明する方法がない
- “良さ”を客観的に比較する方法がない
- 研究に対する評価が厳しい
  - 査読は減点法になってしまう
  - 文句をつけられる箇所があったら reject というノリ

## どうやって辛さを乗り切るのか? (その1)

- “空想”の問題を解いても評価されない
- 実際のシステムで起きている問題を見つけろ!
- いろいろな視点から性能評価をやってみる
  - まずは人為的なベンチマークで極限状況を調べる
  - 直感に反する結果が出ていないかどうか調べる・考える
  - 直感に反する結果を見つけたら...
    - 何が起きているのか詳細に調べていく
  - 原因がわかったら...
    - 同じ現象が起きる実アプリケーションを探す

## Containers or Hypervisors, Which is Better for Database Consolidation?

in collaboration with  
Asraa Abdulrazak Ali Mardan

## Introduction

- Virtualization becomes an essential building block in today datacenters
  - Meeting growing demands of resources by providing resources sharing and consolidation
  - Brings significant cost savings
- Major virtualization technologies
  - Hypervisor-based solution like KVM, Vmware ..etc
  - OS-level Virtualization or containers such as LXC, Docker..etc


## Containers vs Hypervisors

- Trade off between performance and isolation
  - Container provides near native performance with no virtualization overhead
  - Hypervisor provides strong isolation

## Disk I/O Performance




- 期待通り、コンテナのほうが性能がよい
  - LXC というコンテナ, KVM というハイパーバイザを利用



## Disk I/O Performance Isolation



- Containers provide good performance isolation
  - Two VMs/containers are launched
  - The one VM/container given 70% share, the other 30%



## Research Question




- Question:
  - Which is better for database consolidation?
    - Containers or Hypervisors?
- Answer:
  - Looks containers are better because of:
    - Better disk I/O performance
    - Comparable disk I/O isolation
- となるんだったら面白くない
  - 誰もが想像できる結果
  - 深く調べるまでもない

## Answer: 予想とは逆の結果




- Hypervisors are better for DB consolidation
  - Provide better **throughput**



## Answer: 予想とは逆の結果



- Hypervisors are better for DB consolidation
  - Provide better throughput & **isolation**



## どうやってこんな現象を見つけたのか？



- 研究者の期待に反する結果が得られたのが面白い
  - コンテナと VM の構造から想像すれば、コンテナのほうが(少なくとも)性能はいいはず
- 最初の動機は単純
  - 最近、コンテナって流行ってるよね
  - ハイパーバイザより性能がいいっていうけど、どれくらいいいんだろうね？
  - とりあえず、測ってみるか...
- システムソフトウェア研究の楽なところ
  - テーマは向こうからやってくる

## 実際には・・・



- 数百通りのパラメータの組み合わせで実験
  - (動きの解析しやすい) 簡単なベンチマークを使う
  - とにかく brute-force で頑張る
  - 結果は出ると無邪気に信じる
    - 学生は半ベソでした・・・
- fsync の頻度が高いとコンテナの性能が低下する
  - fsync: ファイルの更新をディスクに反映する処理
  - コンテナではジャーナリングの競合が起きるのが原因
  - この辺りの分析は experience と expertise の勝利
- fsync を多用する実アプリケーションを探す
  - データベースなんかどうだろう？
  - We made it!!!!

## どうやって辛さを乗り切るのか? (その2)



- “空想”の問題を解いても評価されない
- 実際のシステムで起きている問題を見つけろ！
- 報告されている問題を**全部**調べる
  - 先入観は排除せよ
    - フィルタリングしたり絞り込んだりしては**いけない**
  - 先入観があると“想定範囲内”の問題しかみつからない
    - 驚きを伴ういい仕事になりにくい

## Linux のバグから学ぶ

～バグのフィールド調査からコード検査器の実現まで～

慶應義塾大学 河野健二



## 本日の話題



- Linux ってバグがないわけではない・・・
  - でも Linux って社会のインフラになってます
- Linux のバグを駆逐しよう
  - OS 固有の知識を活かしたコード検査
    - OS に典型的なバグ・パターンを静的に検出する
      - スルポインタかどうかの検査忘れ
      - unlock や free などの呼び出し忘れ
      - 暗黙の約束事を忘れている
        - ※ ブロックしてはいけない関数の中でブロックする関数を呼び出す
- Linux に固有のバグって？
  - これまでは Linux 開発者の経験と勘が頼り
    - Linux には “○○” というバグが多い
    - その “○○” っていうバグをとるコード検査器を作りました

## 本日の話題

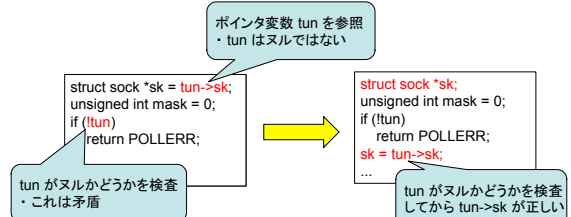


- コード検査器の実現は古典芸能の職人芸
  - ワシの経験と勘が頼りじゃ
- 経験と勘にたよらないコード検査器
  - 膨大なバグ修正記録を活用
    - ソフトウェア工学におけるビッグデータ
  - 37 万件を超える Linux のコード修正記録を分析
    - 自然言語処理によるパワープレイ
    - Amazon EC2. 100 インスタンスで 1 ヶ月.
  - Linux に典型的なバグ・パターンの抽出
  - 割込み関連のバグ・パターンについてコード検査器を実現
  - 最新の Linux においても複数のバグを発見

## Example of Linux Bugs (1)



- 初歩的なバグでさえ、まだまだ残っている
  - 例: “スルポインタ参照” のバグ
    - tun/tap: Fix crashes if open() /dev/net/tun and then poll() it.
    - Author: Mariusz Kozlowski <m.kozlowski@tuxland.pl>



## Linux における“簡単な”バグ




- 簡単な静的解析で見つかるバグを調査 [Palix et al. 2011]
  - Null (ヌル検査忘れ):
    - ◆ Null を返すかもしれない関数の返値のチェック忘れ
  - Inull (Inconsistent null check):
    - ◆ ポインタ参照をした後にヌル・チェック
      - さきほどのバグの例
  - Block (Calling blocking func in non-blocking context)
    - ◆ ブロックしてはいけないコンテキストでブロックする関数を呼ぶ
      - 例: スピンロックを保持したまま、ロックを獲得する
      - 例: ファイルシステムから・・・
  - など 12 種類のバグを検査

## Linux でも“簡単な”バグがたくさんある



- どのバージョンでもほぼ 700 個のバグがある
  - Linux 2.6.0 ~ 2.6.33 までの調査 [Palix et al. 2011]



## Example of Linux Bug (2)



- “簡単”ではないバグの例
  - 静的なコード検査では見つかるのが難しいもの
    - ◆ 関数にまたがった解析が必要なケース
    - ◆ 割込みなどの非同期的な振る舞いが絡むケース
    - ◆ などなど
  - 割込みのタイミングに依存するバグ
    - デバイスの取り外し処理
      1. デバイスの割込みを解除する
        - 割込みを受け付けないようにする
      2. デバイス管理のためのデータ構造を開放する
    - 複雑なコードでは・・・
      - ◆ 1. と 2. の処理の順番がひっくり返ってしまうことがある

## Example of Linux Bug (2)



- OS らしいバグ: 割込みのタイミングに依存するバグ

```
void usb_remove_hcd(struct usb_hcd *hcd)
{
    ...
    Interrupt occur
    ...
    remove_debug_files(ohci);
    ohci_mem_cleanup(ohci);
    if (ohci->hcca) {
        ...
        ohci->hcca = NULL;
        ohci->hcca_dma = 0;
    }
    hcd->state = HC_STATE_HALT;
    if (hcd->irq >= 0)
        free_irq(hcd->irq, hcd);
    usb_deregister_bus(&hcd->self);
    hcd_buffer_destroy(hcd);
}
drivers/core/hcd.c
```

```
static irqreturn_t ohci_irq(struct usb_hcd *hcd, struct pt_regs *ptregs)
{
    ...
    Nullポインタ参照
    if ((ohci->hcca->done_head != 0)
        && !(hc32_to_cpup(ohci, &ohci->hcca->done_head)
            & 0x01)) {
        ...
    }
}
drivers/usb/host/ohci-hcd.c
```

Linux 2.6.18  
id: 71795c1df30b034414c921b4930ed88de34ca348  
で報告されている

簡単な静的解析では見つからない

## Example of Linux Bugs (3)



- Many Linux device drivers assume device perfection [Kadav et al. 2009]
- Example: Infinite polling
  - Driver waiting for device to enter particular state
  - If device not working correctly, the loop never ends. Hang

```
static int amd8111e_read_phy(.....)
{
    ...
    reg_val = readl(mmio + PHY_ACCESS);
    while (reg_val & PHY_CMD_ACTIVE)
        reg_val = readl(mmio + PHY_ACCESS);
}
AMD 8111e network driver(amd8111e.c)
```

## Example of Linux Bugs (3)




- Solution: add the code for timeout
  - If timeout occurs, recover code is invoked

```
static int amd8111e_read_phy(.....)
{
    ...
    timeout = 0;
    reg_val = readl(mmio + PHY_ACCESS);
    while (reg_val & PHY_CMD_ACTIVE) {
        reg_val = readl(mmio + PHY_ACCESS);
        if (timeout++ >= 200)
            __shadow_recover();
    }
}
AMD 8111e network driver(amd8111e.c)
```

## Eliminating bugs



- Bugs in software have to be eliminated
  - To avoid security issues and low availability
  - Developers do a lot of debugging efforts
    - ◆ Code review, testing, maintenance etc.
- Static code checkers help developers find *typical* bugs



## Why "typical" bugs?



- Focusing on typical bugs is reasonable
  - People make the same mistakes as others have done
- Examples of typical bugs:
  - Pair API misuses e.g., alloc/free, lock/unlock
    - ◆ [Saha et al. '13], [Palix et al. '11]
  - Unhandled device failures e.g., infinite polling
    - ◆ [Kadav et al. '09]

## Who writes what checkers?



- Knowing typical bugs is difficult
  - Bugs are human mistakes
    - ◆ Hard to predict typical developers' behaviors
  - Many bugs are domain-specific
    - ◆ >50% of bugs in Linux file systems are violations of file system semantics [Lu et al. FAST'13]
    - ◆ Hard to understand semantics in large-scale software

## Learning from bug repositories



- Challenge: Recognizing many & similar patterns
  - Hard to understand & summarize many documents
- Bugs are often documented in English
  - E.g., >370,000 patches in Linux kernel
  - Developers can extract typical bugs



## Goals




- Use machine learning to extract typical patch documents in Linux kernel
  - Many & similar patches are extracted
- Extract bug patterns from the extracted typical patch documents
- Develop checkers for the extracted bug patterns
- Apply the checkers to the latest Linux kernel

## Extracting many & similar patches



- Natural language processing calculates the similarity of patches
  - Latent Dirichlet allocation (LDA) [Blei et al. '03]
- Clustering groups similar patches
  - Recursively divides clusters by 2-means
  - Enables us to extract large groups (5,000 - 10,000) of similar patches



## LDA in short



- LDA infers latent topics in documents
  - A document is regarded as probability sets of topics
    - ◆ The similarity of two documents is the distance between the probability sets for them
  - Keywords characterizing patches can be obtained

In function devkmsg\_read/write/lseek/poll/open()..., the function `raw_spin_lock/unlock` is used, there is **potential deadlock** case happening. CPU1: thread1 doing the cat /dev/kmsg: `raw_spin_lock(&logbuf_lock);` while (user->seq == log\_next\_seq) { when thread1 run here, at this time one **interrupt** is coming on CPU1 and running based on this thread, if the **interrupt** handle called the printk which need the `log_buf_lock spin` also, it will cause **deadlock**.

$$\text{LDA: } p(D|\alpha, \beta) = \prod_{d=1}^D \prod_{n=1}^{N_d} \sum_{k=1}^K p(z_{dn}=k) p(w_{dn}|z_{dn}, \beta) p(\theta_d|\alpha) \\ p(\theta, z|w, \alpha, \beta) = \frac{p(w|\alpha, \beta)}{p(\theta, z, w|\alpha, \beta)}, \quad p(w|\alpha, \beta) = \int p(\theta|\alpha) \left( \prod_{n=1}^N \sum_{k=1}^K p(z_n=k) p(w_n|z_n, \beta) \right) d\theta$$

topic A: 0.113, topic B: 0.055, topic C: 0.04 topic D: 0.038, topic E: 0.038, topic F: .....  
Keywords: **lock**, **unlock**, **spin**, **lock**, **protect**,

## Analyzing Linux patch documents



- 370,403 patch documents are analyzed
  - Linux 2.6-rc2 ~ 3.12-rc5 (April 2005 – October 2013)
  - Merge commits are excluded
  - Analyzer has been implemented on Hadoop MapReduce
  - LDA from Apache Mahout
- Result: 66 clusters
  - Linux had topics for general software bugs, OSs, devices, CPU platforms, etc.

## Result 1/3: common bugs



- Clusters for bugs in general software
  - Null dereferences, memory leaks, lock/unlock
  - Typical software bugs in the Linux kernel
- Example document: memory leak
  - Topic keywords: memory, leak, cpu, hotplug
  - Misuse of `kmalloc()` and `kfree()`

commit 003615301, 2nd paragraph

USB: io\_ti: fix port-data memory leak  
Fix port-data **memory leak** by moving port data allocation and deallocation to `port_probe` and `port_remove`.

## Result 2/3: hardware



- Clusters for CPU platforms and devices
  - ARM, X86, GPU, USB, NIC, etc.
  - Major hardware-specific issues
- Example document: ARM
  - Topic keywords: arm, mach, h, asm
  - Problems deriving from ARM features

commit 9cff337, 3rd paragraph

So far as I am aware this problem is **ARM specific**, because only **ARM** supports software change of the CPU (memory system) byte sex, however the partition table parsing is in generic MTD code.

## Result 3/3: common OS features



- Clusters for common OS features
  - Interrupt handling, buffer cache, DMA, etc
  - Typical implementation issues in OSs
- Example document: interrupt handling
  - Topic keywords: irq, interrupt, msi
  - Problems around masking interrupts

commit ea6dedd, 2nd paragraph

The current OMAP GPIO IRQ framework doesn't use the `do_edge_irq`, `do_level_irq` handlers, but instead calls `do_simple_irq`. This doesn't handle **disabled interrupts** properly, so drivers will still get **interrupts** after calling `disable_irq`. ....

## Extracting bug patterns from a cluster



- The cluster for interrupts are expected to typical bugs in OSs
  - The cluster remains too large (5,334 patches)
- Topic keywords help us extract interesting sub-clusters
  - A sub-cluster with keyword "free" is expected to have bugs around free and interrupts
- The sub-cluster with keyword "free" contains 364 patches
  - 160 are identified as bugs

Result: the misuse of free\_irq() is common 

| Description                                        | Num. |
|----------------------------------------------------|------|
| 1: free_irq() with inconsistent device ID          | 41   |
| 2: missing free_irq() on initialization error path | 25   |
| 3: free_irq() with invalid irq                     | 25   |
| 4: missing free_irq() on module unloading          | 13   |
| 5: double free_irq()                               | 9    |
| 6: freeing other src before free_irq()             | 7    |
| 7: freeing pages with interrupt disabled           | 7    |
| 8: missing free_irq() before suspend               | 6    |
| 9: freeing shared irq with interrupt enabled       | 5    |
| Other (most contain free and irq)                  | 22   |
| Total                                              | 160  |

- ### Developing checkers
- A domain-specific checker for free\_irq() misuse
    - Checks the consistency of two arguments
      - ◆ Interrupt number and device ID
    - Checks a typical life cycle of PCI device drivers
      - ◆ Probe, suspend, resume, remove, shutdown, etc.
    - Runs on the Clang static analyzer

### Checking Linux 3.15

- 2 bugs are found across 593 PCI drivers

```

1204  /* We must finish initialization here */
1205
1206  if (!socket->ch_irq || request_irq(socket->ch_irq, venta_interrupt, IRQ_SHARED, "venta", socket)) {
1207      28 -- Taking false branch --
1208      } else {
1209          socket->socket_features |= SO_SOCKET_SHARED;
1210      }
1211
1212  /* Register it with the pci/cia layer */
1213  ret = pci_register_driver_socket(socket->socket);
1214  if (ret != 0) {
1215      29 -- Assuming 'ret' is not equal to 0 --
1216      } else {
1217          }
1218
1219  cleanup:
1220  (cleanup(socket->base));
1221  release:
1222  pci_release_regions(dev);
1223  disable:
1224  pci_disable_device(dev);
1225  free:
1226  kfree(socket);
1227  out:
1228  return ret;
1229  }
  
```


- 1, request\_irq() succeeded
- 2, pci\_register\_socket() fails
- 3, Freeing src although interrupts may be delivered
- 4, A device probe fails without free\_irq()

- ### どうやって辛さを乗り切るのか? (その3)
- “正しさ”を証明する方法がない
    - 例えば、アルゴリズムの正しさを証明できない
    - 実装の正しさはもっと証明できない
  - “良さ”を客観的に比較する方法がない
    - Linux と Windows. どちらがより良い OS か比較できない
  - パワープレイで（査読者を）黙らせるしかない
    - “正しい”ことを示すかわりに・・・  
たくさんベンチマークを動かしてみせる
    - “良さ”を示すかわりに・・・  
たくさんのシステムと比較実験をしてみせる



## Towards Multi-tenant GPGPU: Event-driven Programming Model for System-wide Scheduling on Shared GPUs

in collaboration with  
Yusuke Suzuki\*  
Hiroshi Yamada\*\*, Shinpei Kato\*\*\*

\* Keio University  
\*\* Tokyo University of Agriculture and Technology  
\*\*\* University of Tokyo










### 実験, たいしたことないじゃん

- それはプレゼンだから
- 実際の論文では...









Figure 11: Execution times of GPU tasks with 1, 3, and 7 throttles.

Figure 13: Execution times of GPU tasks with 1, 3, and 7 throttles. 66% of GPU computing resource is assigned to GPU tasks.



## Take-Away Message & Conclusion

### ■ システムソフトウェア研究の変遷

#### ■ 研究テーマは自然に決まる

- ◆ システムソフトウェアは・・・
  - － 上司(アプリ)にゴマするイエスマン
  - － 部下(ハード)のワガママは全部聞く

無能な中間管理職でよい

#### ■ 研究のやり方はどんどんシビアになっている

- ◆ 実システムで起きている現実の問題に目を向ける
  - － 問題発見のための努力を惜しまない
- ◆ 提案方式は、既存システムに組み込んでナンボ
- ◆ 性能評価は徹底的に！
  - － できる実験は全部やる