https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの性能測定とチューニング

佐藤　広生 <hrs@FreeBSD.org>

東京工業大学/ FreeBSD Project

2016/11/29

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

自己紹介

- 名前：佐藤 広生
  - FreeBSD src + ports + doc committer (2000-)
  - FreeBSD コアチームメンバ、リリースエンジニア(2006-)
  - FreeBSD Foundation 理事(2008-)
  - その他の＊BSD／オープンソース関連の活動いろいろ
  - 東京工業大学助教(2009-)

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

お話しすること

- ZFSを使ってみた/ているけれど...
  - キャッシュ容量はどう決めれば良い？
  - ハードウェアの性能限界が出せていない気がするけれど、性能ってどう調べれば良いの？
  - なんかUFSの方が性能的にマシだったような...
- ZFSの構造と性能の調べ方を知りましょう
- FreeBSDに限らず使えます
  (ただしOracle Solarisを除く)

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

お話しすること

- システム管理者が知っておくべき
  - ZFSの構造
  - DTraceを使ったボトルネック分析
  - チューニングパラメータ

...を解説します。

- DTraceを使うので、チュートリアル資料をスライドの後ろの方に付けてあります

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

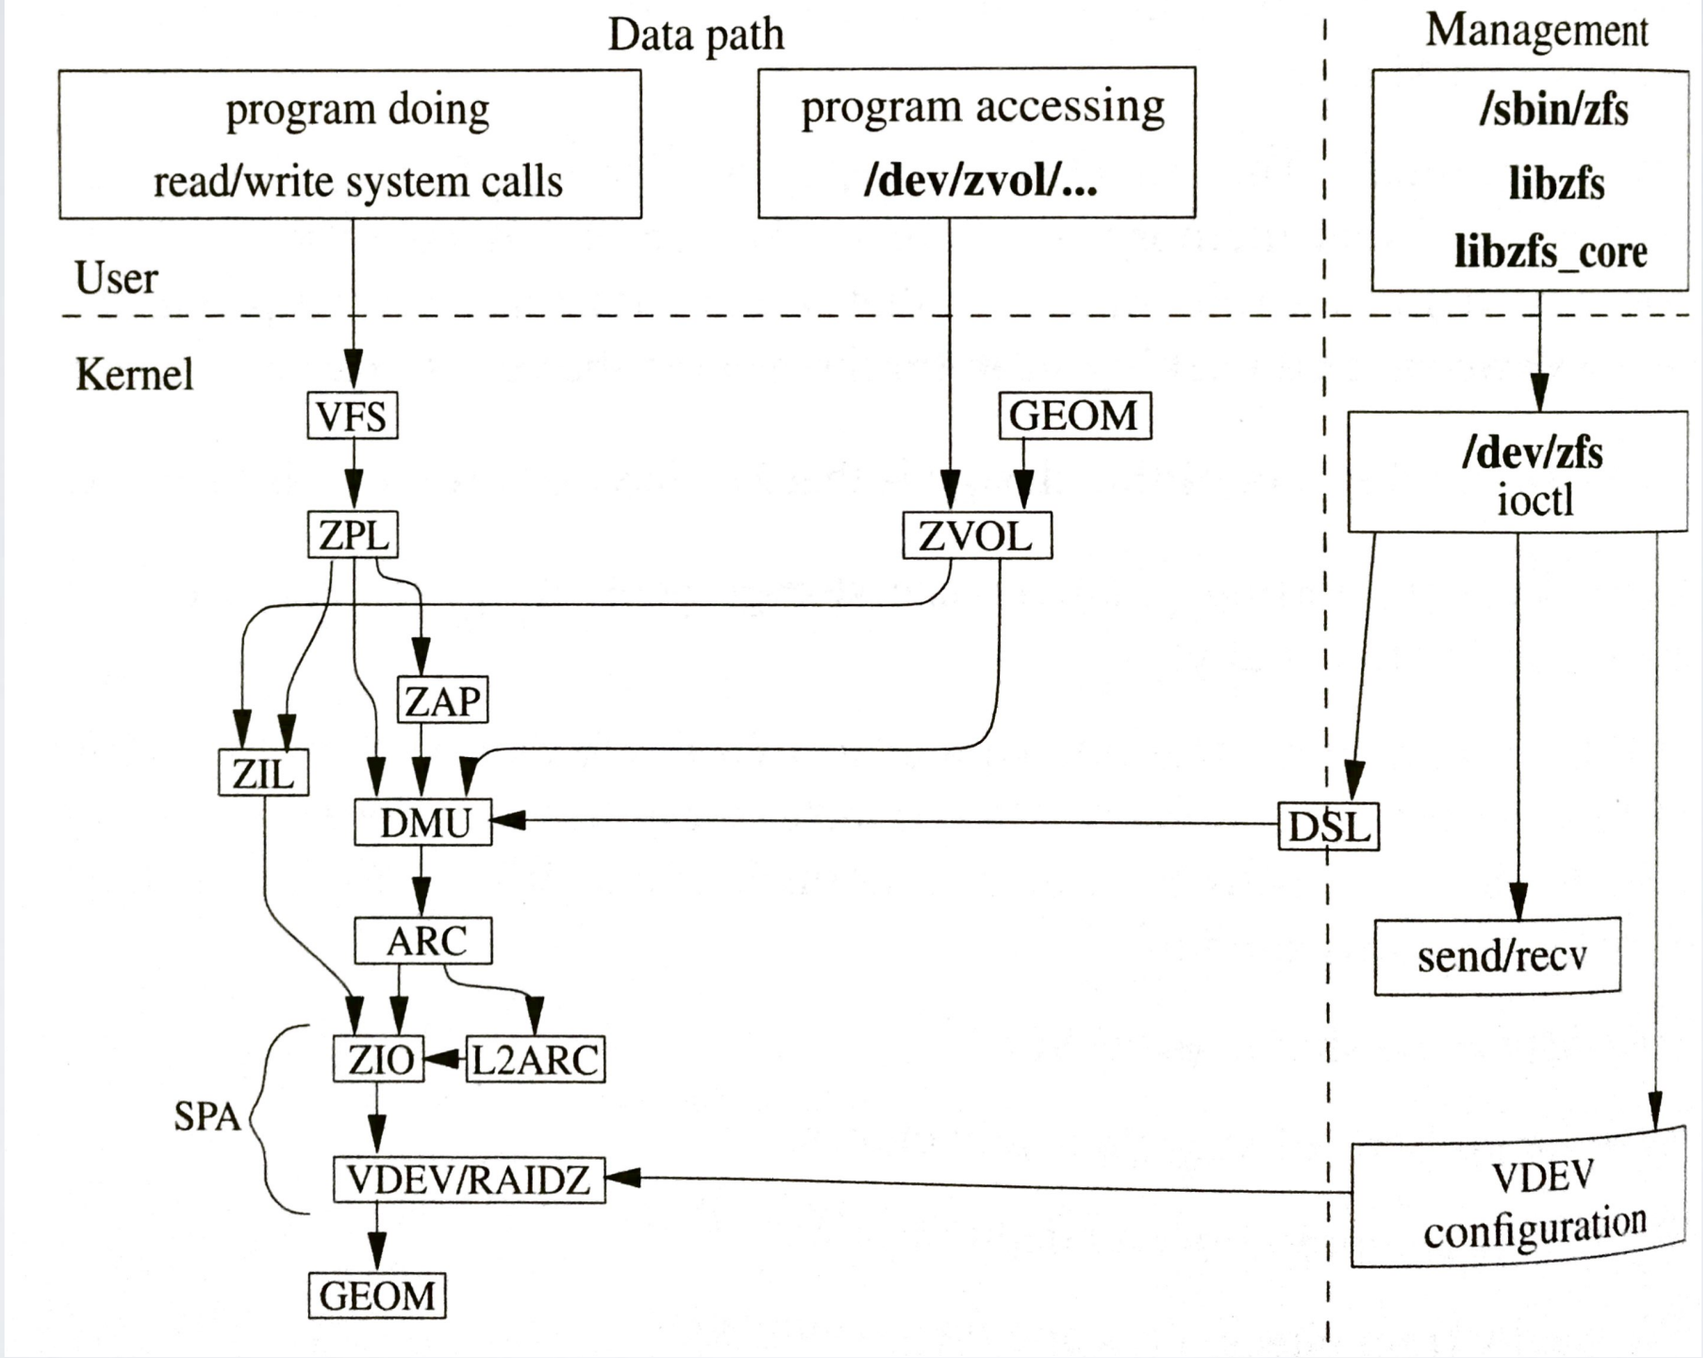

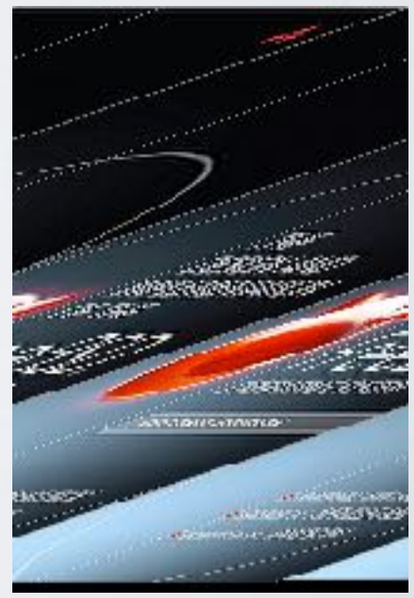

D&I 本, p.526

ZFSの構造

- 理解しよう：「ZFSのデータ処理は3層構造」
  - 1層目：POSIX API（znode）
  - 2層目：DMU（dnode）
  - 3層目：SPA（ブロックポインタ）

- 参考：UFSはvnode, inode, ブロックポインタ
- 「dnodeが複数のデバイスにまたがる点」が異なる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

ユーザランド
アプリケーション

ZFSの入り口
（２つある）

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

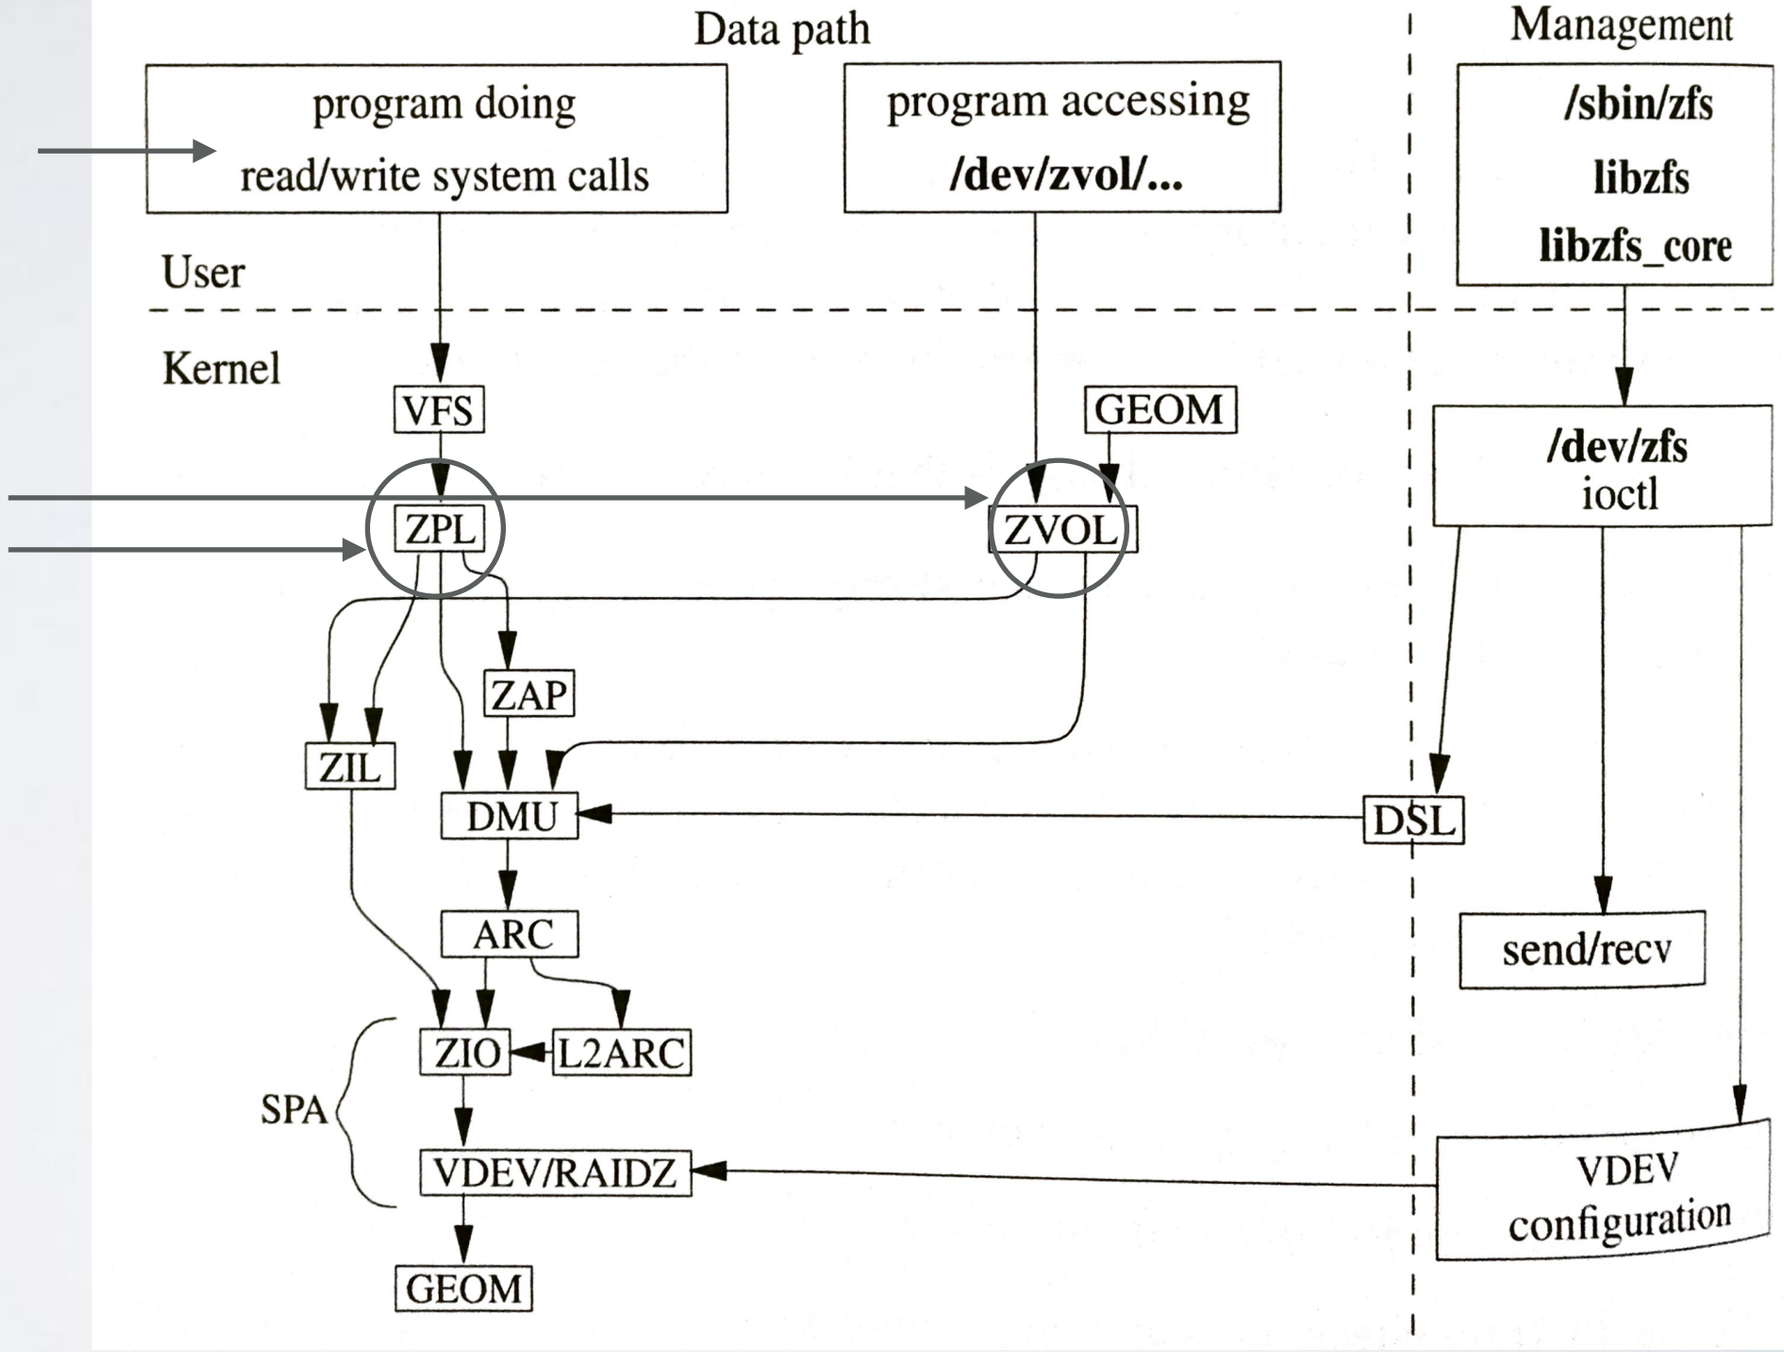

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

ユーザランド
アプリケーション

ZPL
POSIXの定義する
「ファイル」や
「ディレクトリ」の
構造をアプリケーションに
見せる処理をする。

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

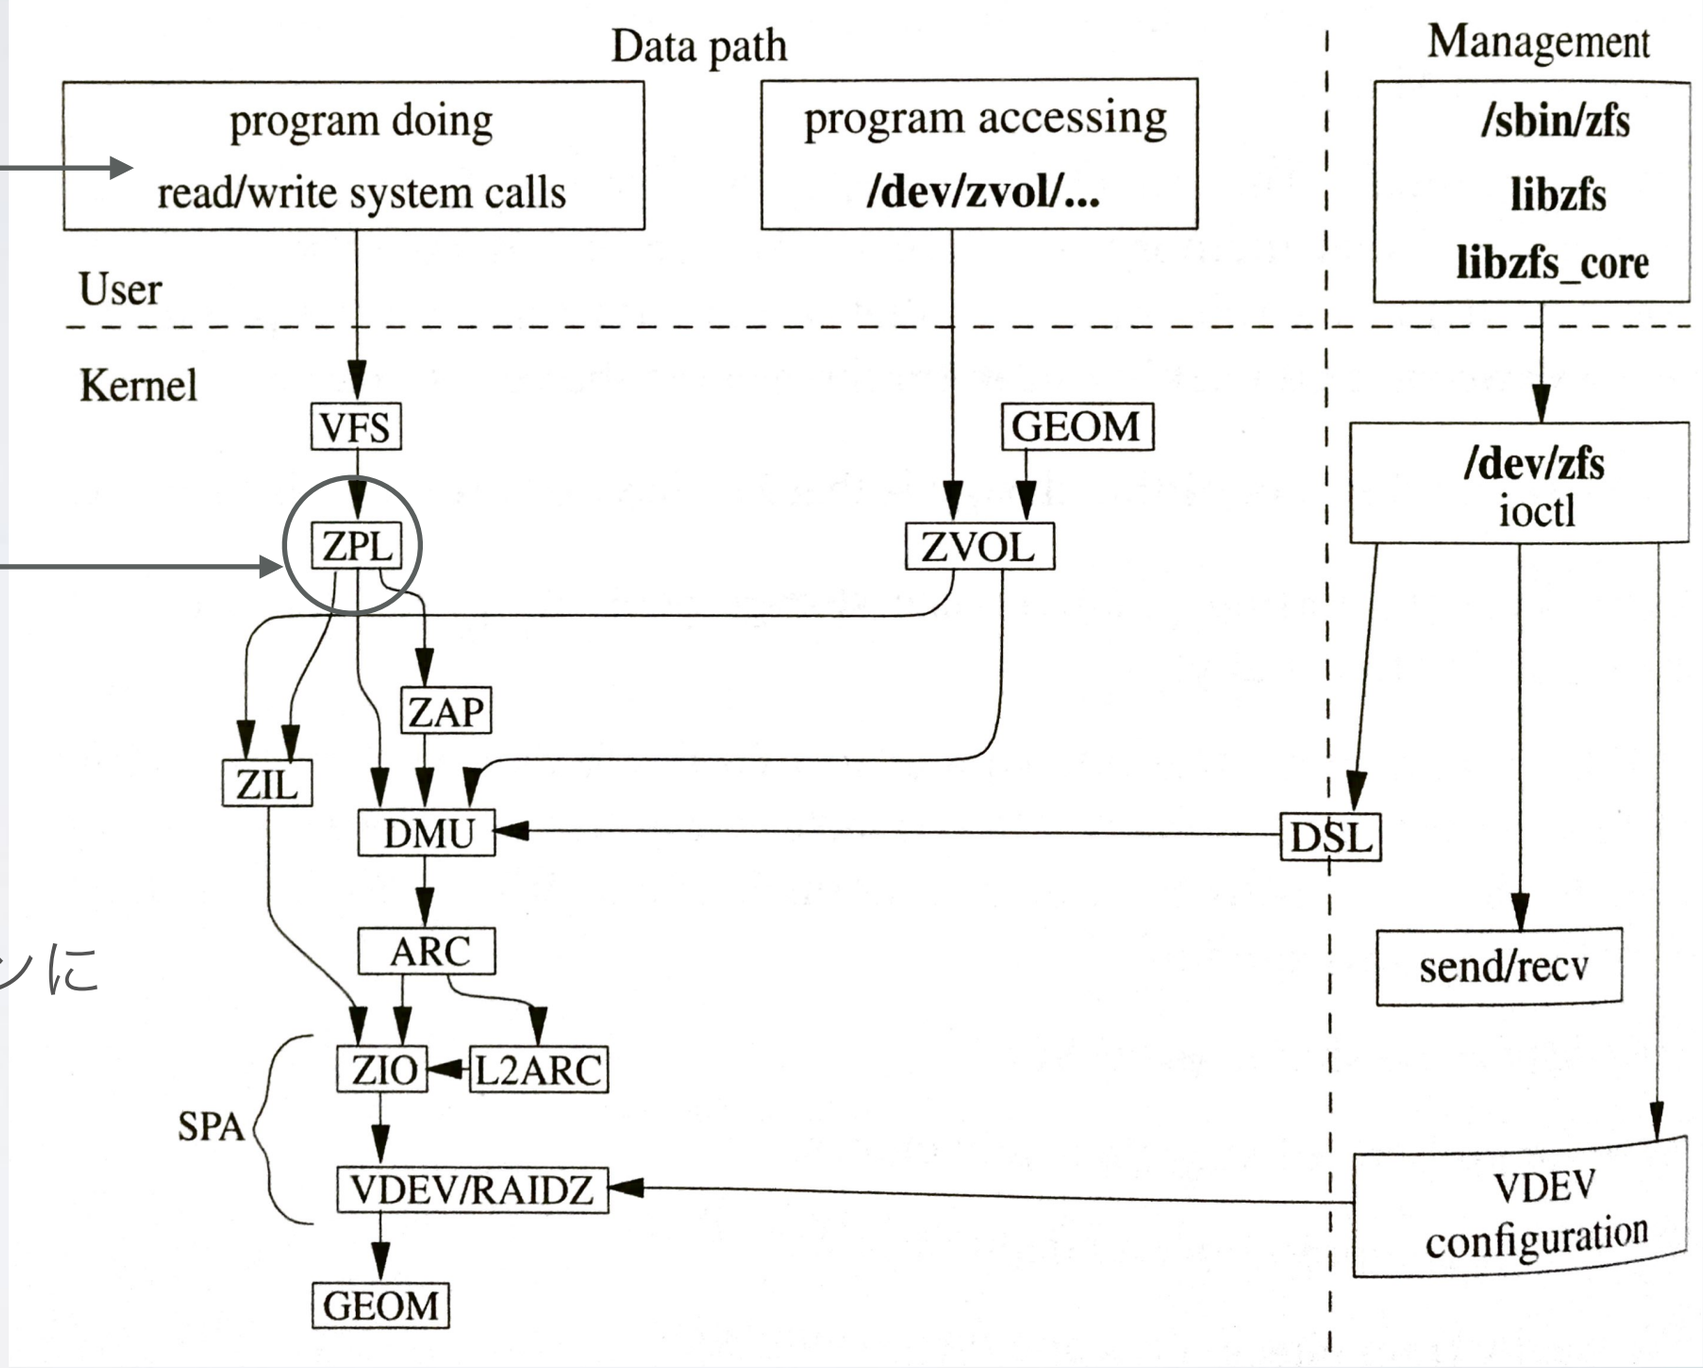

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

ユーザランド
アプリケーション

ZVOL

/dev/da0 のように
ブロックデバイスとして
見える姿を処理する。

実際には"/dev/zvol/xxx"という
名前で見える。

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

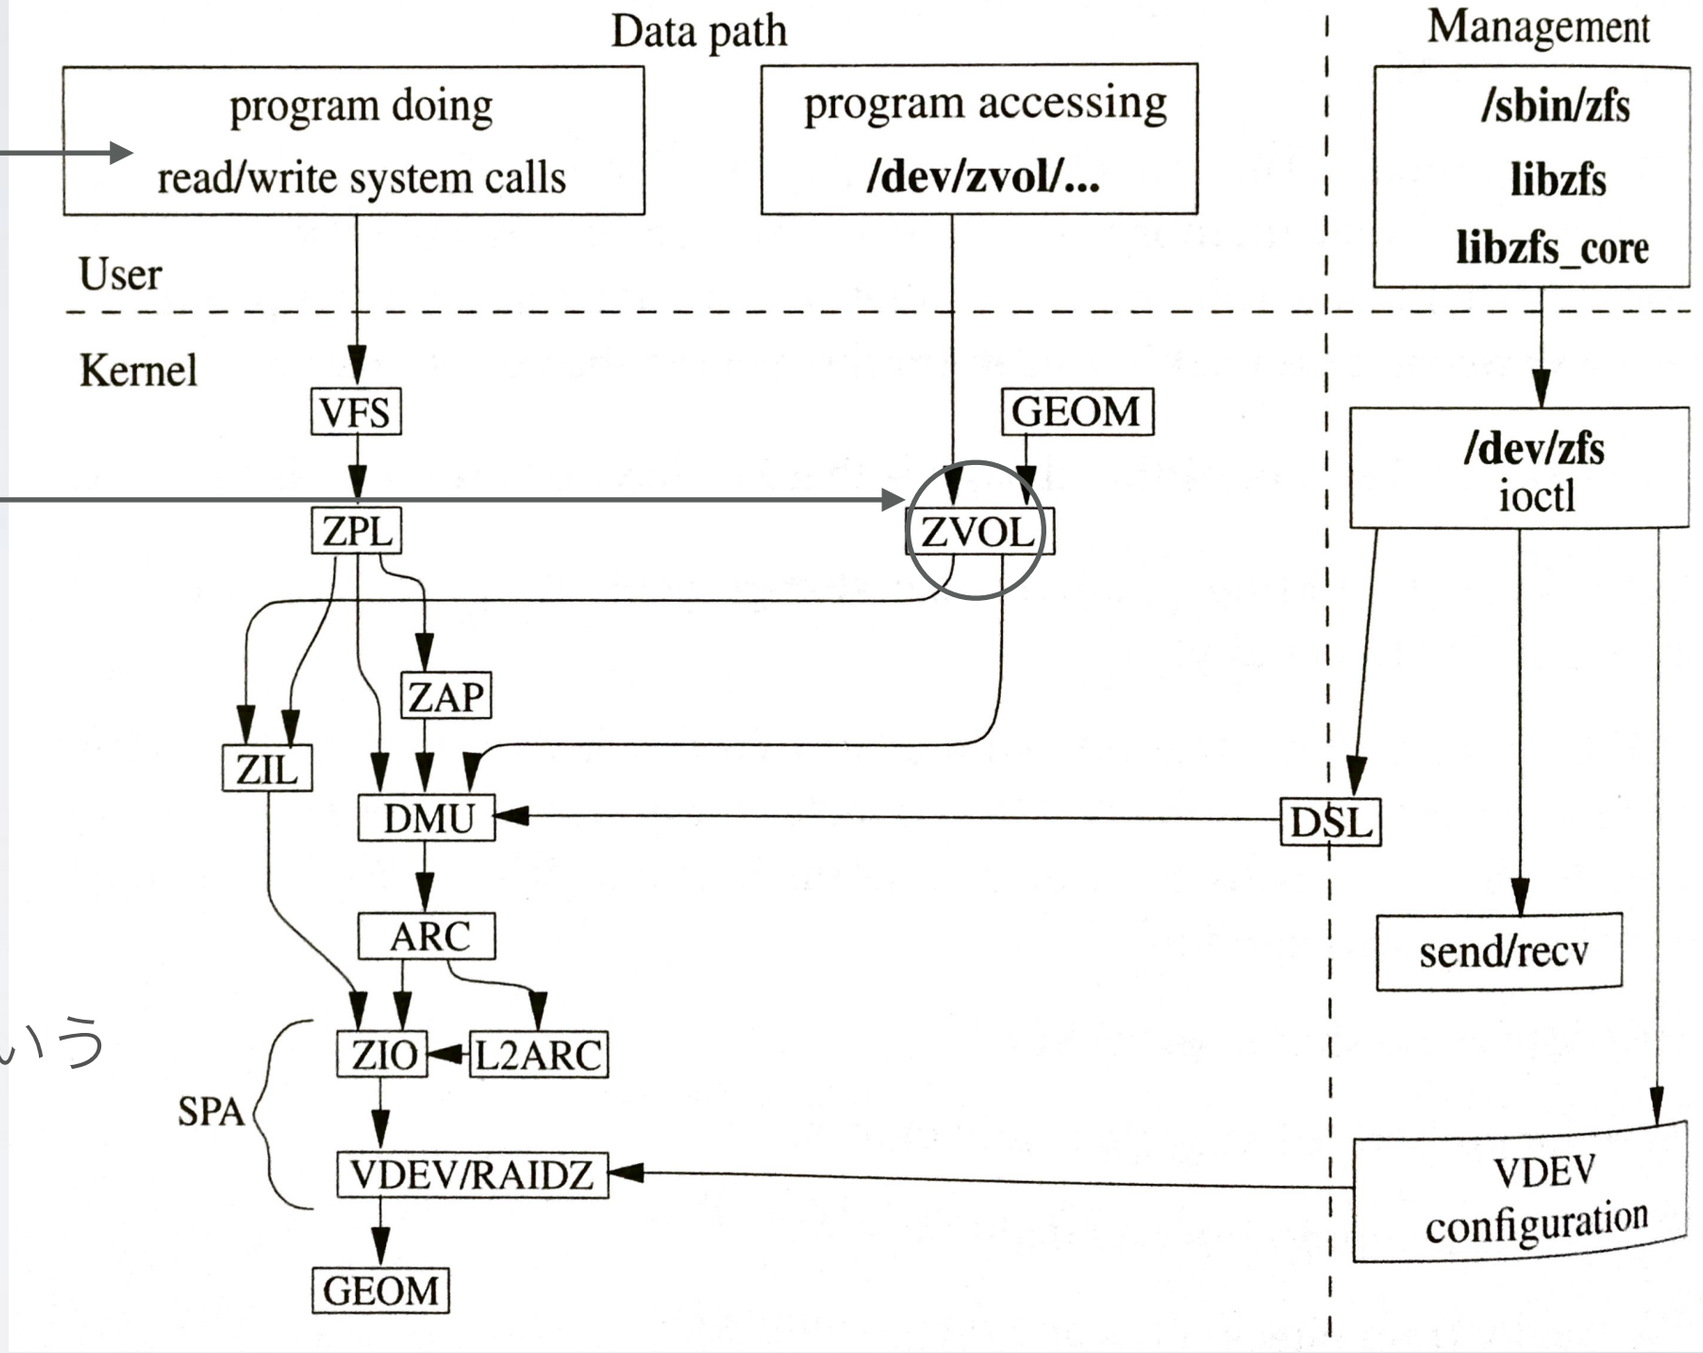

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

ZAP メタデータ処理

ZAPは、key-valueペアの処理を担うところ。
ディレクトリや属性などはここで処理される。

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

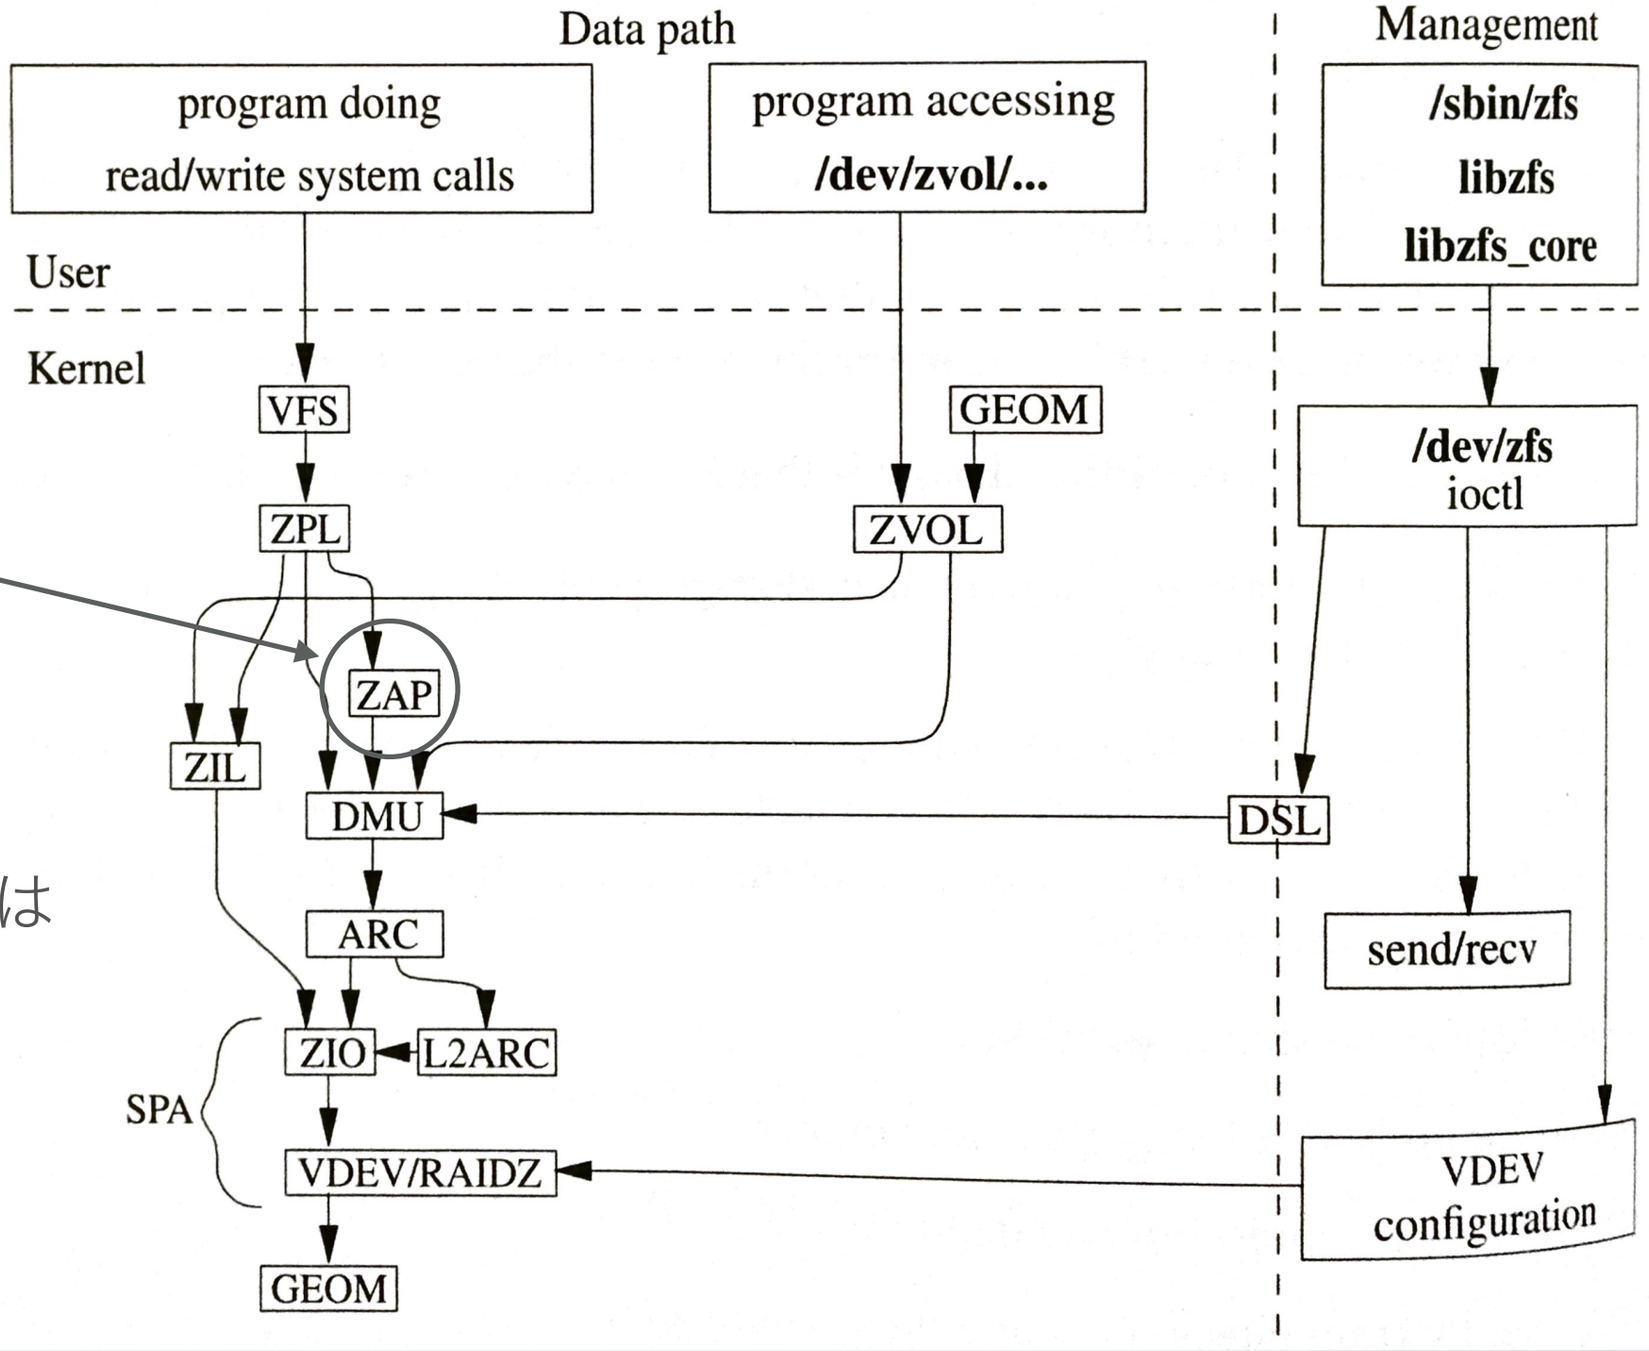

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

DMU

DMUは、ストレージプールを
管理する部分。
仮想メモリのMMUと同じような
発想だと思っていて良い。

DMUの上側は、HDDなどの
デバイスの存在を意識せず、
データはプールの論理ブロック番号で管理される。

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

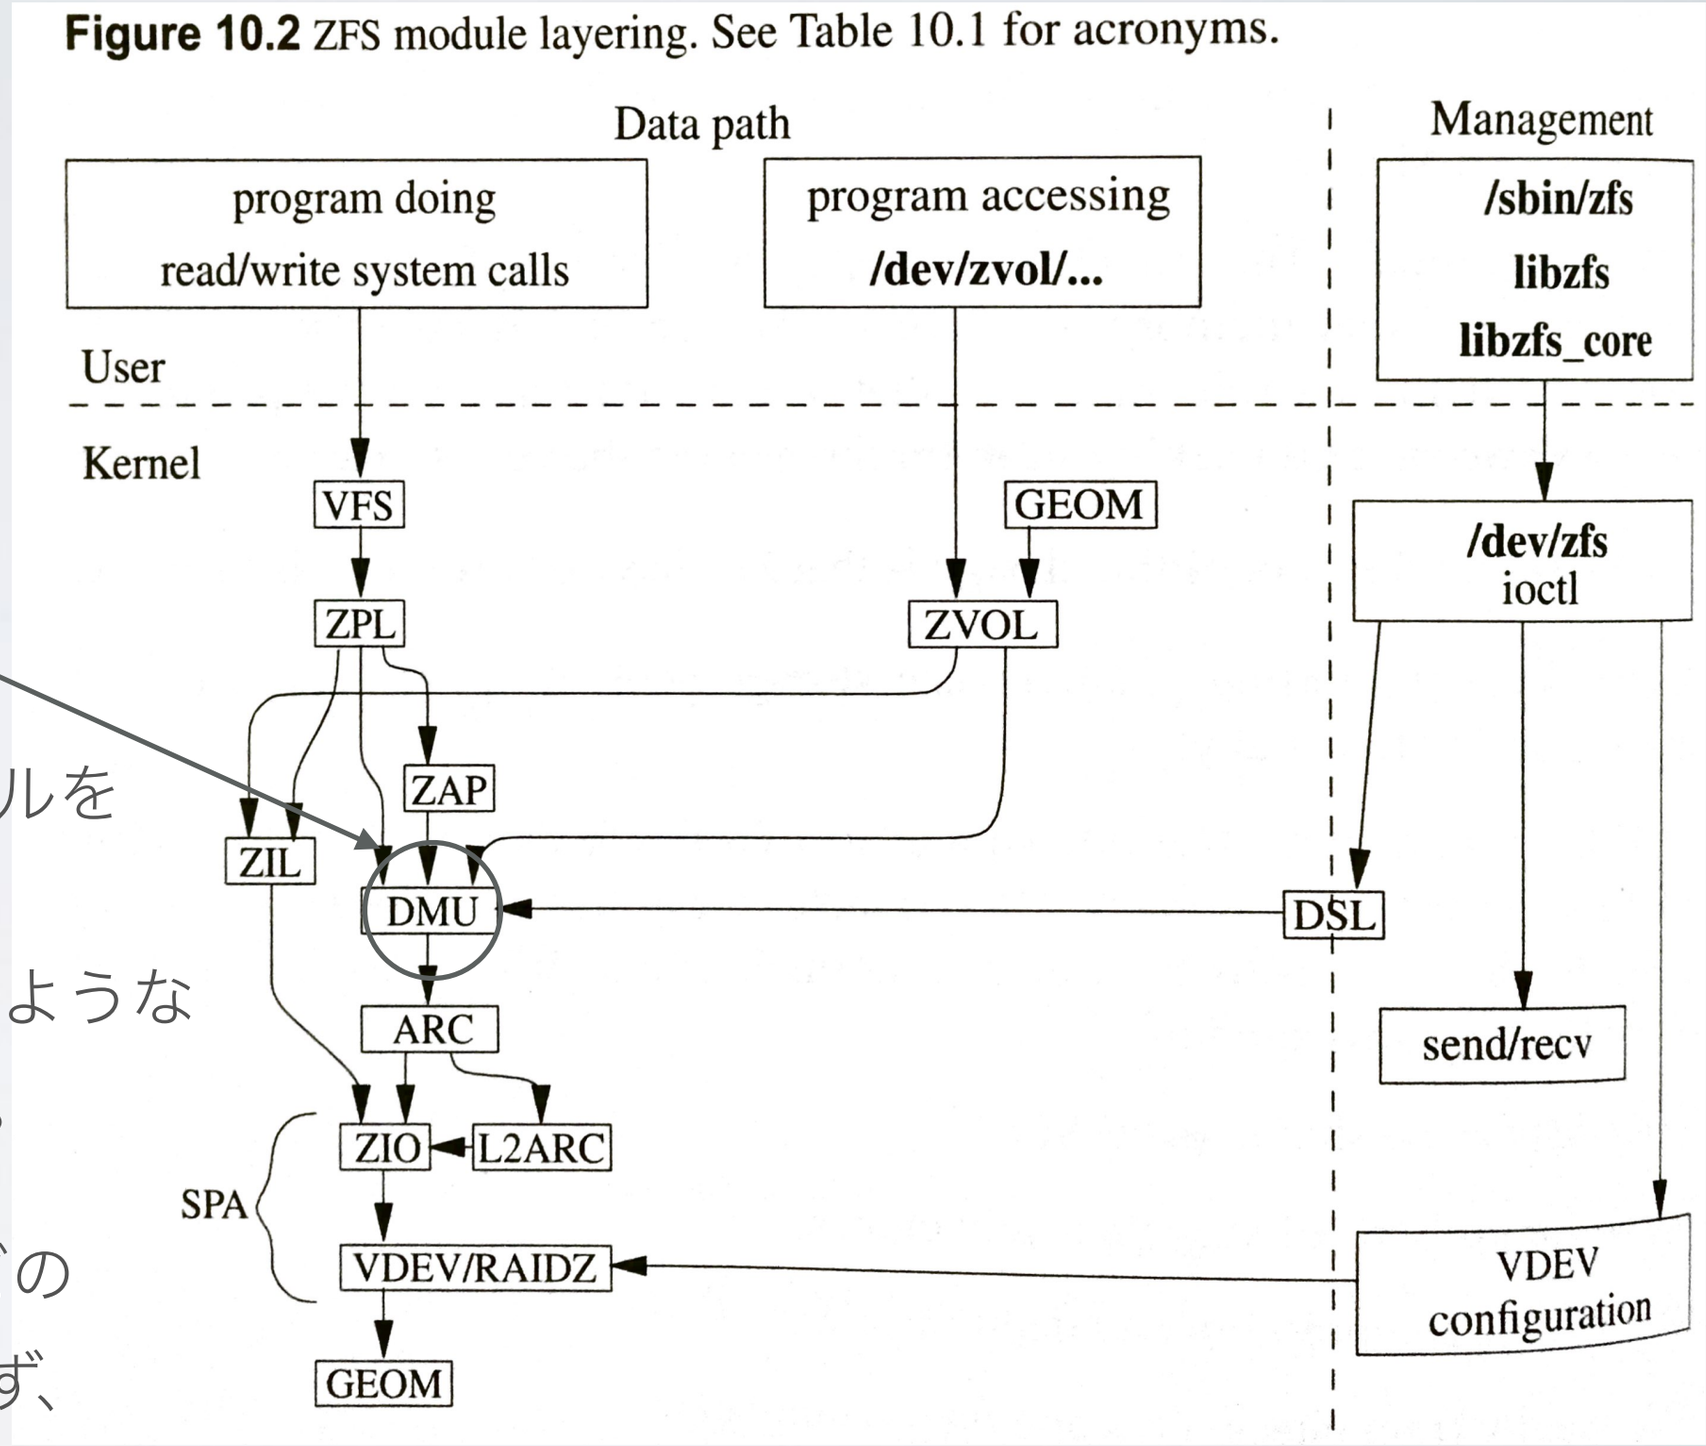

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

- DMUが管理している領域のイメージ
  ＝ 複数の領域を集約して、上位層に対して連続領域に見せる

DMUはdnodeで管理
（inodeみたいなもの）

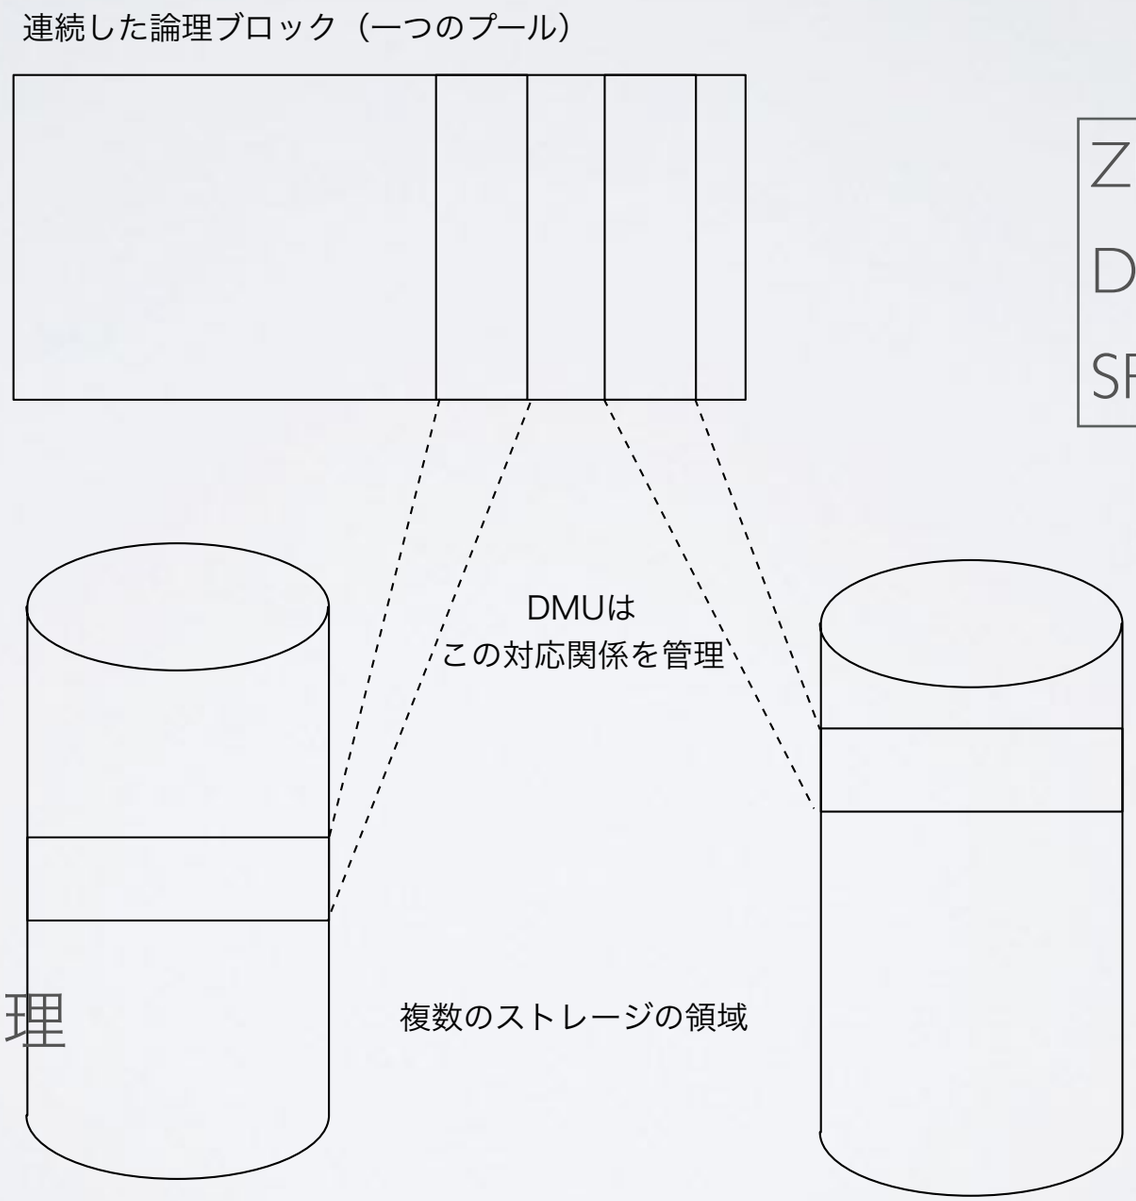

ZPLはznode,
DMUはdnode,
SPAはブロックポインタ

ストレージの領域は
ブロックポインタで管理
（SPAと呼ぶ）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

SPA

SPAは、DMUで読み書きが
必要になった領域に対して、
それを disk I/O に翻訳して
I/O リクエストを発行する部分。

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

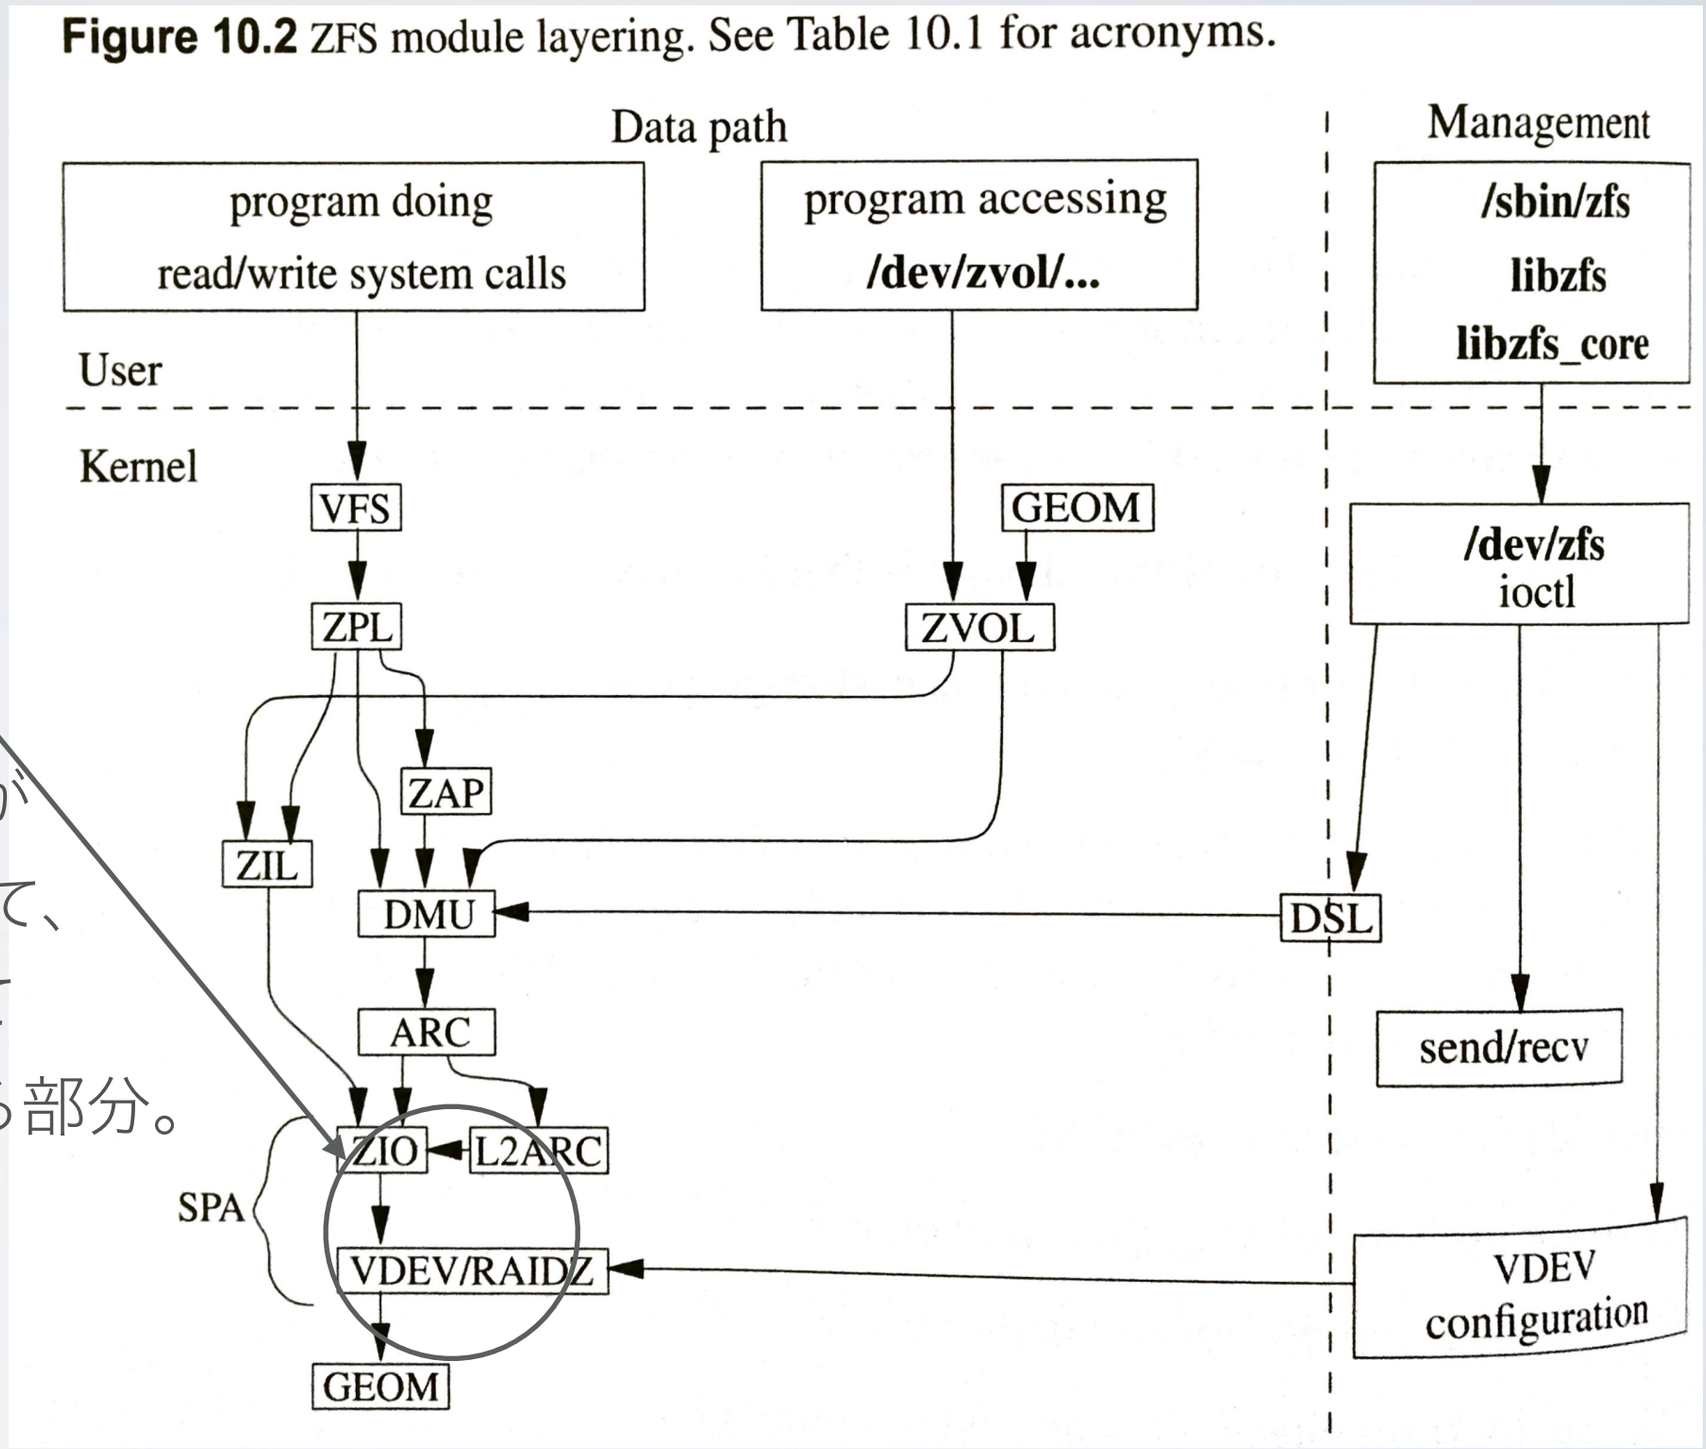

ZFSの動作の特徴

- アプリケーションからのファイルアクセスは、
  DMUを通過してディスクのI/O要求に翻訳される

- DMUは、「連続する論理ブロック（＝zpool）」を
  メモリ空間に割り当てる。
  ☆アプリケーションがzpool領域を操作 ＝ メモリの操作

- メモリ空間への操作は、SPAによってdisk I/O に変換
  （キャッシュにデータがあればI/Oなしでデータを送る）

- 仮想メモリっぽい動作（でかいmmap()のようなもの）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

- 理解しよう：「ZFSのデータ処理は3層構造」
  - 1層目：POSIX API（znode）
  - 2層目：DMU（dnode）
  - 3層目：SPA（ブロックポインタ）

- アプリケーションからのアクセスが
  ディスク入出力に反映されるまでの間、
  データはDMU・SPAという2つの層を流れる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの構造

もうちょっと
厳密な表現

interface

object-based
transaction

transactional object

transaction group
commit

pooled storage

Figure 10.2 ZFS module layering. See Table 10.1 for acronyms.

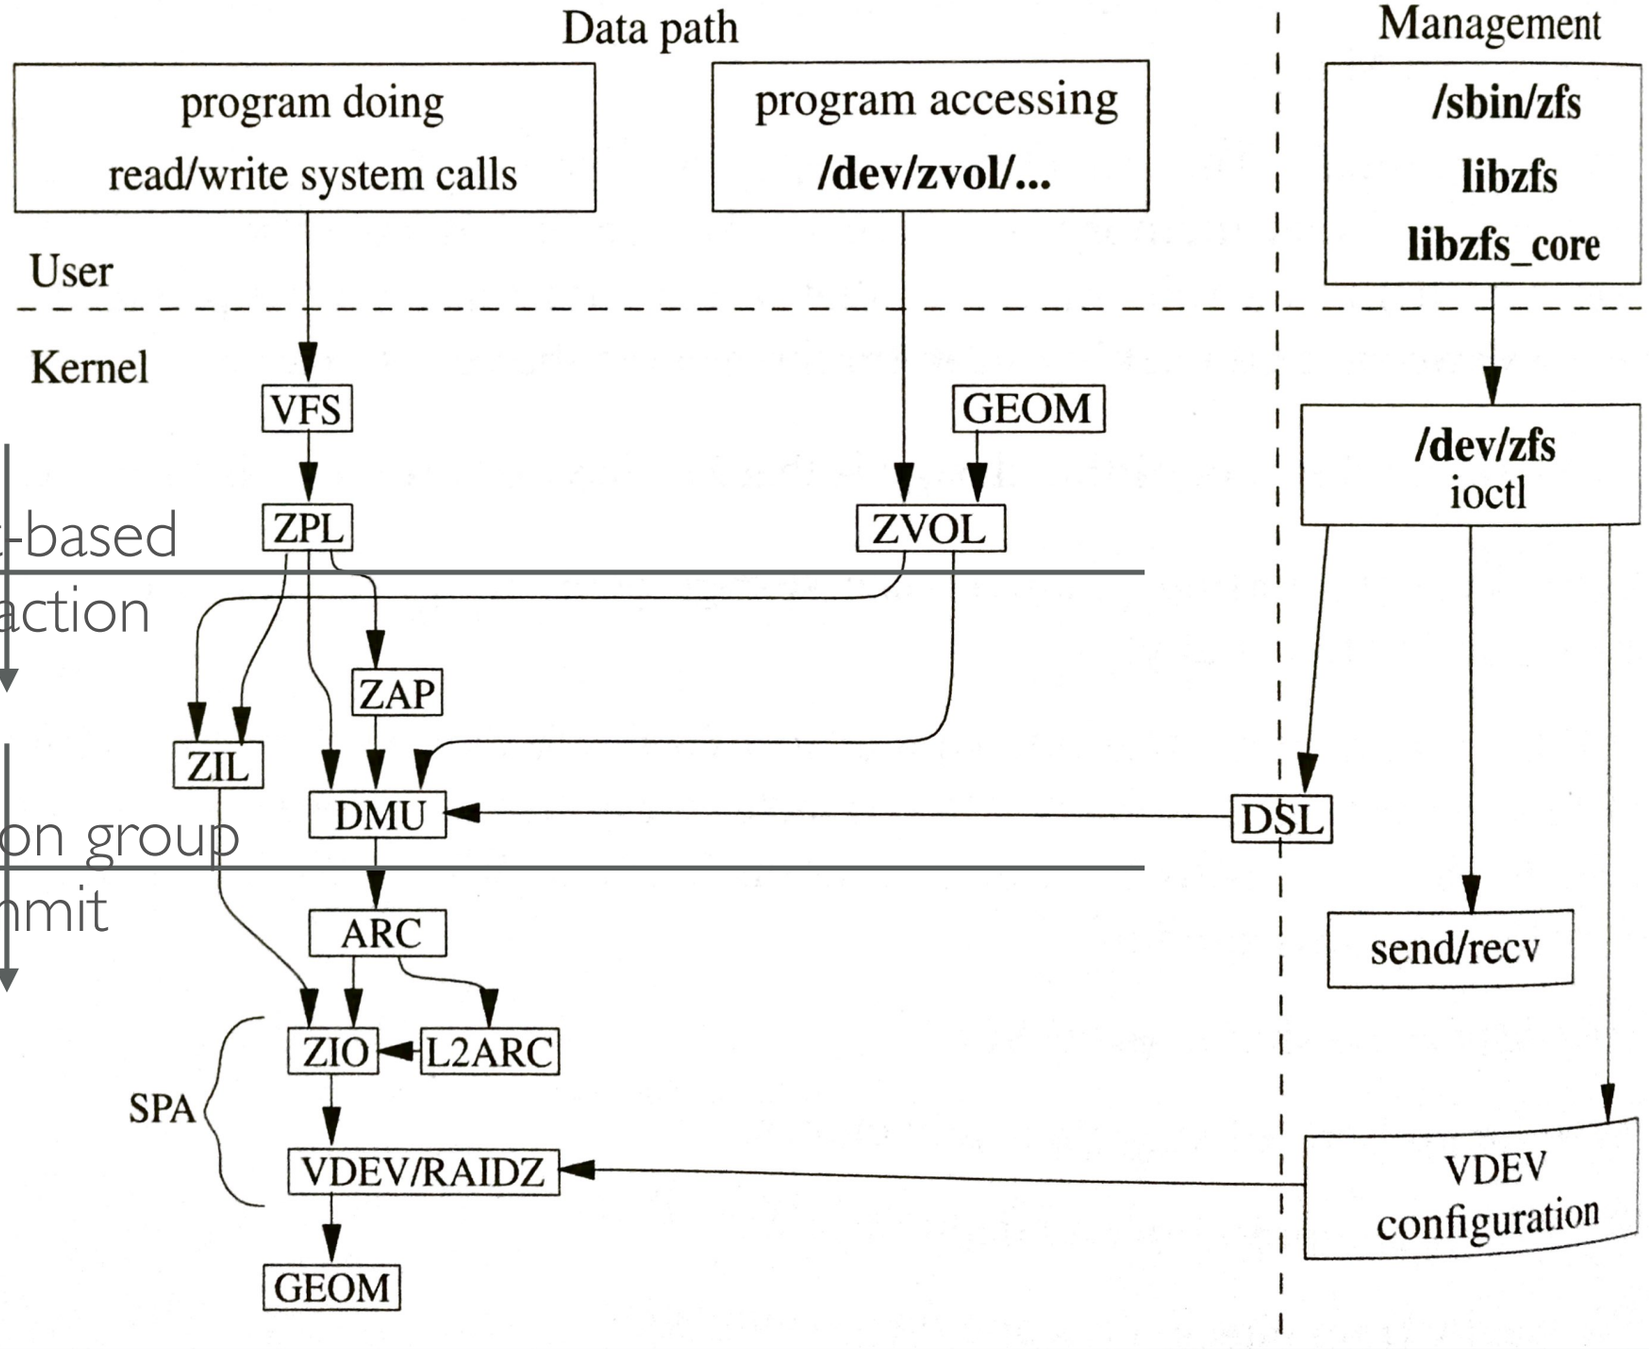

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの性能決定要因

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能を決めるのはどこか？

- SPAの効率が性能に大きく影響するため、
  その動作を知ることが重要！

- DMUより下位の要素：
  - ARC（キャッシュ）
  - ZIO（I/Oを発行するところ）

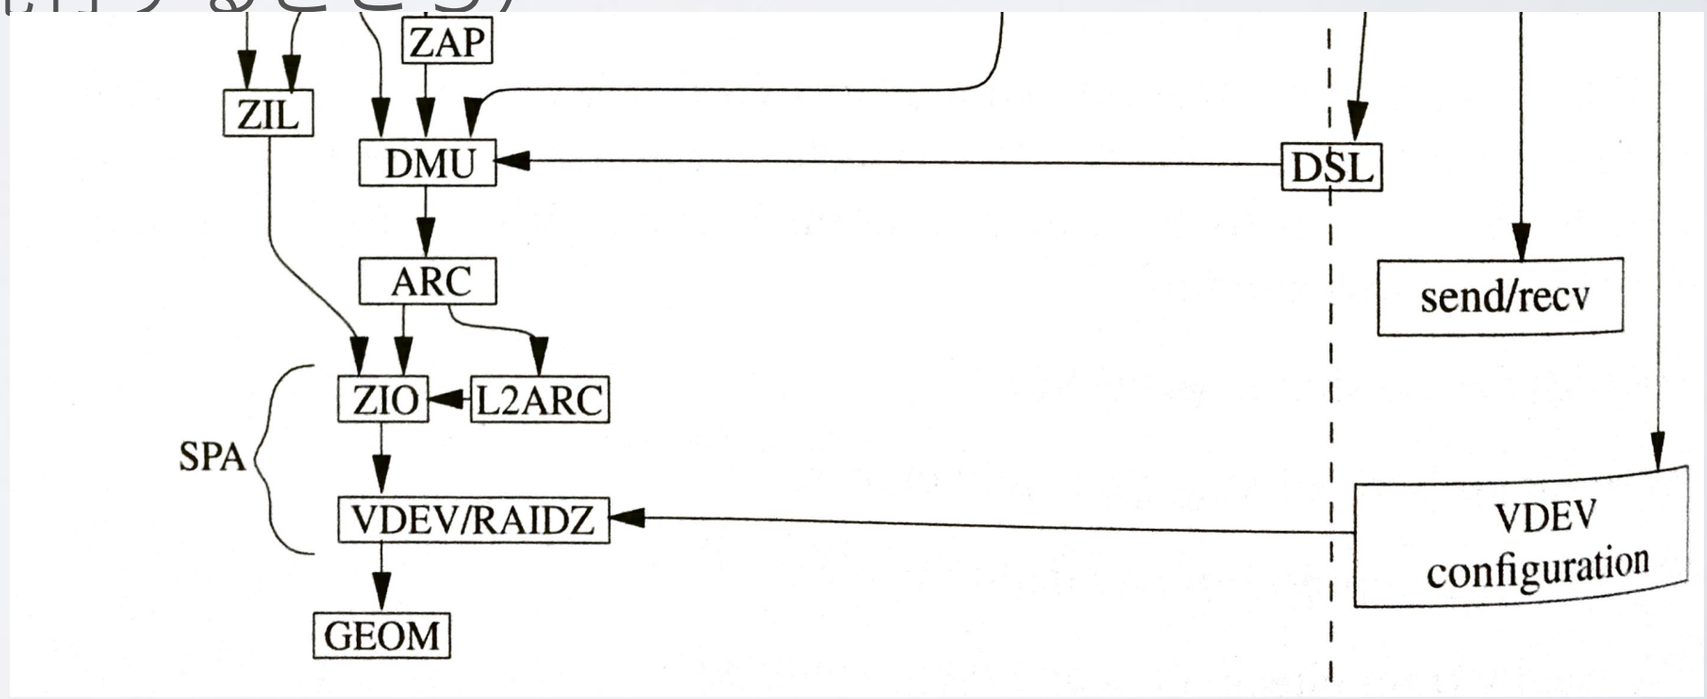

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

よくある落とし穴

- iozoneやbonnieなどのマイクロベンチマークツールで測定
  なぜダメなのか？
  → キャッシュヒットとそうでない場合に性能差が大きい

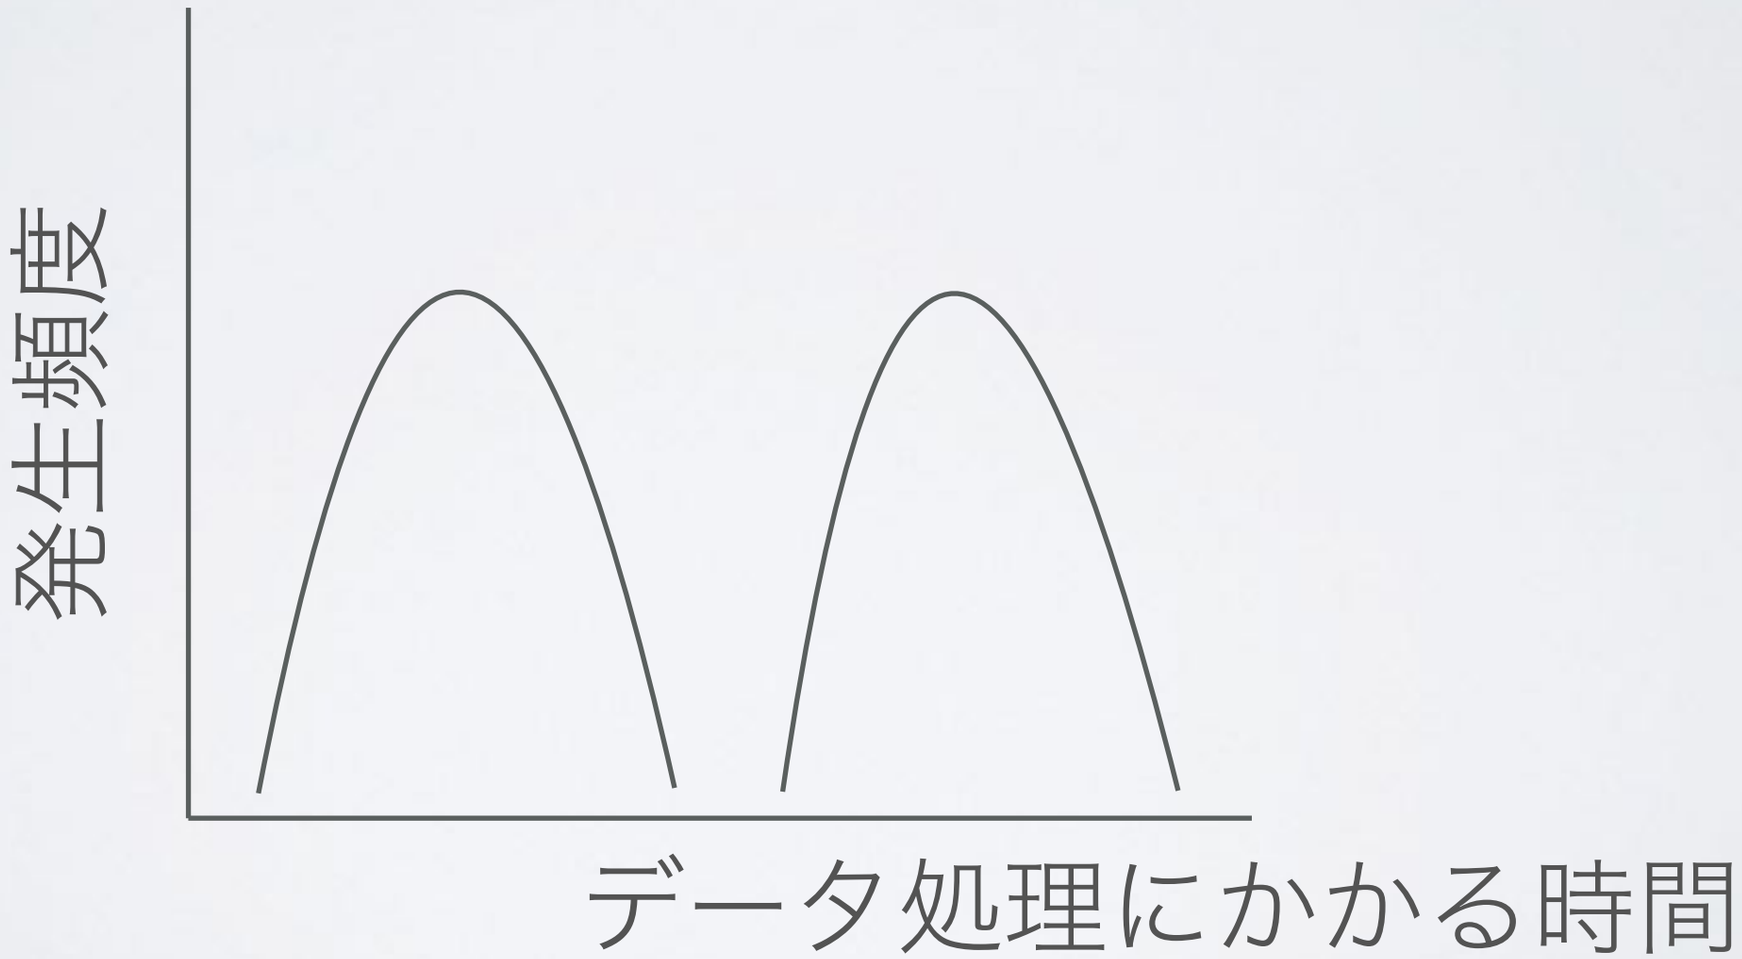

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

よくある落とし穴

- iozoneやbonnieなどのマイクロベンチマークツール
  なぜダメなのか？
  → キャッシュヒットとそうでない場合に性能差が大きい

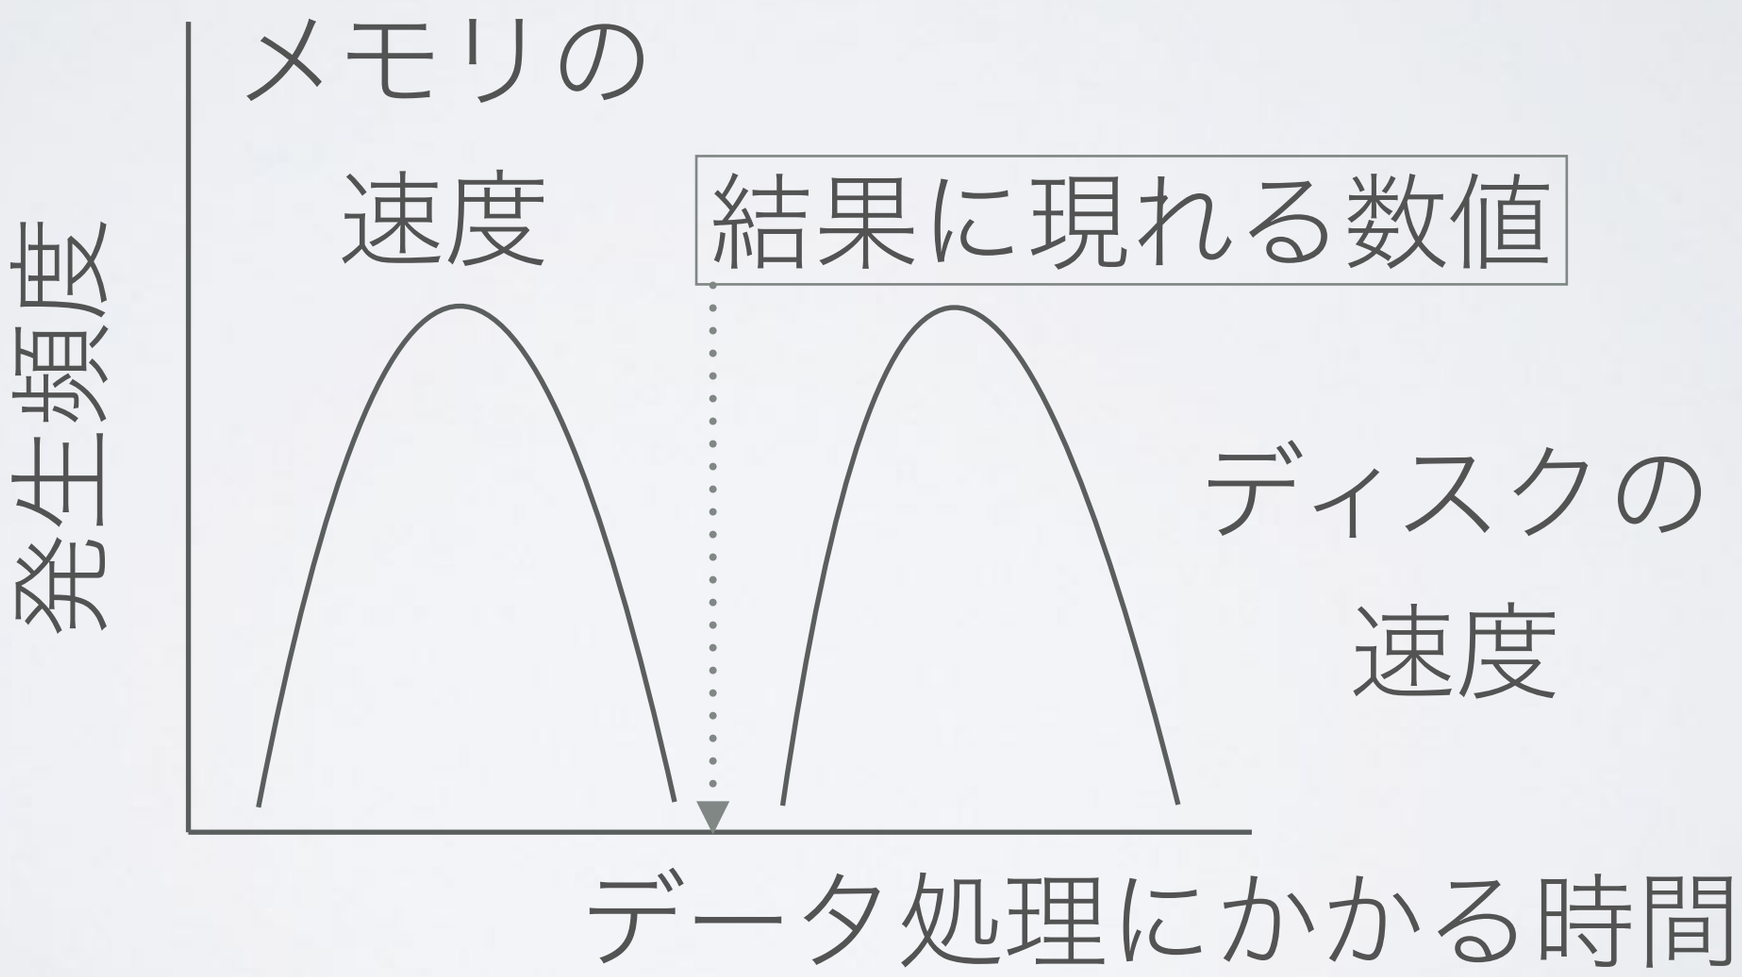

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

よくある落とし穴

- iozoneやbonnieなどのマイクロベンチマークツール
  なぜダメなのか？

- 「自分の使いたい負荷パターンで
  キャッシュがヒットしているかどうか」が支配的

- ヒット率を上げるにはどうしたら良いかを考える

- キャッシュミスを意図的に発生させた場合の
  性能の平均値を見ても意味はない
  （キャッシュヒットのチューニング結果が現れない）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

よくある落とし穴

- iozoneやbonnieなどのマイクロベンチマークツール
  なぜダメなのか？

- あらゆる負荷パターンで万能のチューニング法は存在しない

- 必ず自分で測定しよう

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの読み出し性能

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：読み出し

- ZFSはUFSと比較して、データブロックを読み出すまでに
  ブロックポインタをたどる回数が多い
  (uberblock -> objset -> objset -> ... -> data)

- 同一の処理に対して、より多くのIOPSが必要ということ！

- ほとんどの場合、キャッシュによってその差は見えなくなる

- メタデータのキャッシュヒット率が低下すると、
  UFSと比較してかなり遅くなってしまうことがある

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：読み出し

- キャッシュはどこにある？　＝　DMU, ARC, L2ARC

- DMUのキャッシュはdnodeレベル、
  ARC, L2ARCはブロックポインタレベルで保持する

- ARCはメモリ、
  L2ARCは
  HDD, SSDなど
  の記憶装置

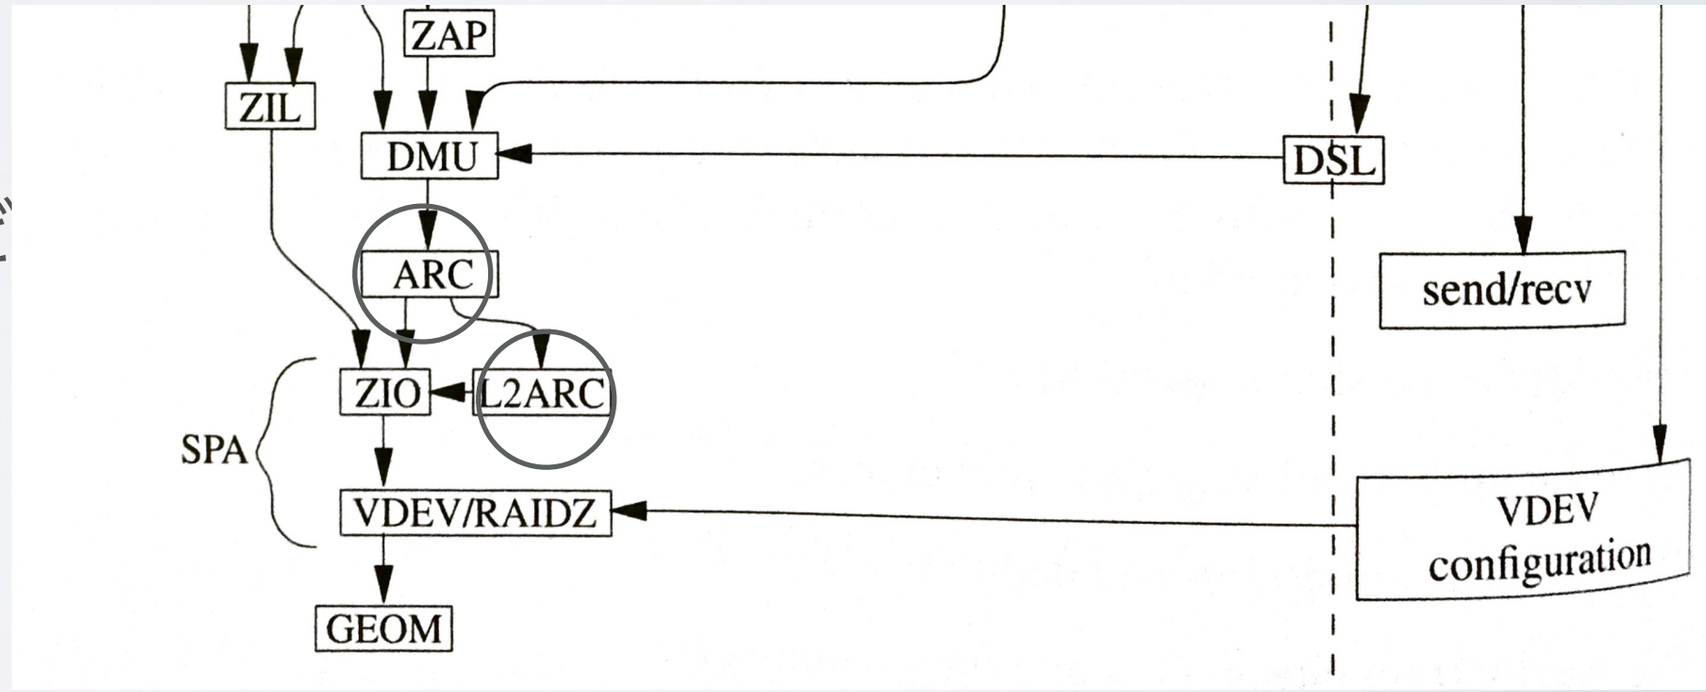

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：読み出し

- ヒット率を調べるには？
- sysutils/zfs-stats をインストールして zfs-stats(8)を使いましょう

```
hrs@pool % zfs-stats -E

------------------------------------------------------------------------
ZFS Subsystem Report                            Fri Jun 24 15:31:52 2016
------------------------------------------------------------------------

ARC Efficiency:                                 9.16b
        Cache Hit Ratio:                87.49%  8.01b
        Cache Miss Ratio:               12.51%  1.15b
        Actual Hit Ratio:               86.94%  7.97b

        Data Demand Efficiency:         79.96%  98.35m
        Data Prefetch Efficiency:       35.42%  35.41m

        CACHE HITS BY CACHE LIST:
          Most Recently Used:           0.93%   74.29m
          Most Frequently Used:         98.45%  7.89b
          Most Recently Used Ghost:     0.61%   48.86m
          Most Frequently Used Ghost:   0.23%   18.37m

        CACHE HITS BY DATA TYPE:
          Demand Data:                  0.98%   78.64m
          Prefetch Data:                0.16%   12.54m
          Demand Metadata:              95.33%  7.64b
          Prefetch Metadata:            3.53%   283.22m

        CACHE MISSES BY DATA TYPE:
          Demand Data:                  1.72%   19.71m
          Prefetch Data:                2.00%   22.87m
          Demand Metadata:              84.43%  967.76m
          Prefetch Metadata:            11.86%  135.91m

------------------------------------------------------------------------
```

ZFSのI/O：読み出し

- ヒット率を調べるには？
- sysutils/zfs-stats をインストールして zfs-stats(8)を使いましょう

追加スライド

```
hrs@pool % zfs-stats -E

------------------------------------------------------------------------
ZFS Subsystem Report                            Fri Jun 24 15:31:52 2016
------------------------------------------------------------------------

ARC Efficiency:                                 9.16b
        Cache Hit Ratio:                87.49%  8.01b
        Cache Miss Ratio:               12.51%  1.15b
        Actual Hit Ratio:               86.94%  7.97b

        Data Demand Efficiency:         79.96%  98.35m
        Data Prefetch Efficiency:       35.42%  35.41m

        CACHE HITS BY CACHE LIST:
          Most Recently Used:           0.93%   74.29m
          Most Frequently Used:         98.45%  7.89b
          Most Recently Used Ghost:     0.61%   48.86m
          Most Frequently Used Ghost:   0.23%   18.37m

        CACHE HITS BY DATA TYPE:
          Demand Data:                  0.98%   78.64m
          Prefetch Data:                0.16%   12.54m
          Demand Metadata:              95.33%  7.64b
          Prefetch Metadata:            3.53%   283.22m

        CACHE MISSES BY DATA TYPE:
          Demand Data:                  1.72%   19.71m
          Prefetch Data:                2.00%   22.87m
          Demand Metadata:              84.43%  967.76m
          Prefetch Metadata:            11.86%  135.91m

------------------------------------------------------------------------
```

Cache Hit Ratio と
Demand Metadata の積が
80% を超えるかどうかが目安

ZFSのI/O：読み出し

修正

- "zfs-mon -a" で表示されるARC Demand Metadata が 定常的に 90% を切っているとちょっと厳しい
- キャッシュに使うメモリが足りないか、メタデータに割り当てている量が足りない

- **調整１：**
  ZFSプロパティのprimarycache, secondarycache
- デフォルトは all になっている。metadataに設定すると、メタデータだけをキャッシュするようになる。
- secondarycache は L2ARCの設定。
- 注：primarycacheをmetadataにすると、L2ARCはallにしてもmetadataだけになる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：読み出し

- Demand Metadata が 90% を切っているとちょっと厳しい
- キャッシュに使うメモリが足りないか、メタデータに割り当てている量が足りない

- **調整２：**
  sysctl の vfs.zfs.arc_meta_limit
- ARCのうち、メタデータに使う量（バイト単位）
- デフォルトは全物理メモリの 1/4 に設定される（arc_maxは(全物理メモリ- 1GB)）
- vfs.zfs.arc_meta_limit="9G" のように指定できる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCに関する注意点

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- **知っておこう（1）：**
  Q：ARC使用量を設定しているのに制限が効かないことがある
  A：**ZFSのARC使用量はフィードバック制御を使って制限している**

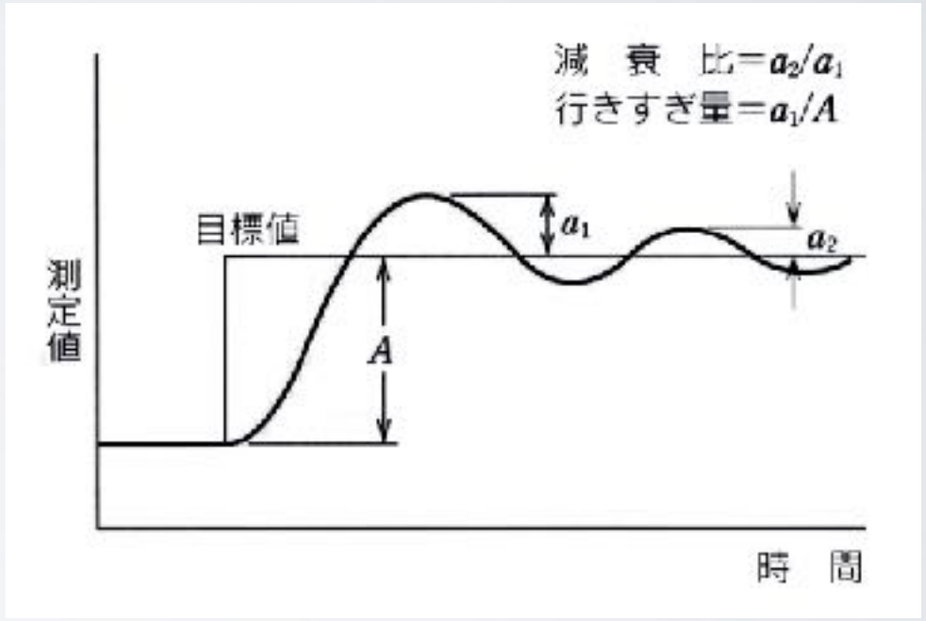

- **vfs.zfs.arc_max: ARCの最大値。**
  デフォルトは（全物理メモリ量-1GB）。
- **vfs.zfs.arc_min: ARCの最小値。**
  デフォルトは全物理メモリ量の1/32。

- 設定してもハードリミットにはならない！
  → 一時的に超えても構わない値にすること

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- **知っておこう（2）：**
  Q：L2ARCを単純にデカくすればヒット率は改善するんじゃないの?
  A：**L2ARCを増やすと、耐えられないくらいメモリ消費量が増える**

- キャッシュ管理のためにメモリが必要
- ARCのみ = 176B/8kB（平均が8kBブロックのケース）
- L2ARC ＝ 240B/8kB（平均が8kBブロックのケース）

つまりL2ARCの容量 x 2.92%のメモリを消費！

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- **知っておこう（2）：**
  Q：L2ARCを単純にデカくすればヒット率は改善するんじゃないの?
  A：**L2ARCを増やすと、耐えられないくらいメモリ消費量が増える**

つまりL2ARCの容量 x 2.92%のメモリを消費！

- ARCはメモリだから小さいが、L2ARCは大容量SSDでも組める

- 例：L2ARC = 1.6TB SSD、RAM = 60GB にしたシステム
  （Amazon EC2など）
  → キャッシュ管理データは 1600GB x 2.92% = **46GB！**
- メインメモリの8割近くが持っていかれる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- **知っておこう（2）：**
  Q：L2ARCを単純にデカくすればヒット率は改善するんじゃないの?
  A：**L2ARCを増やすと、耐えられないくらいメモリ消費量が増える**

つまりL2ARCの容量 x 2.92%のメモリを消費！

- ＜朗報＞10.3, 11.0 以降は 1.59% の消費に減りました。

- ヒット率を見ながらARC量を決める
- L2ARCは大きければ大きいほどヒットは増えるが、
  メモリ消費量を犠牲にするので、物理メモリ量の決定にも影響する
- ARCも2.15%ほどメモリを使うので、8Gで172MBくらい食います

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- 想像だけでチューニングしないこと！
  → 必ず測定をする

- 適当に値をいじったり、誰かの値を理解せずコピーしない
  → 自動チューニングはそれなりに優秀です

- 何事も増やせば良いというものではない
  - アプリケーションに使うメモリ
  - ARCに使うメモリ
  - ARCの管理に消費されるメモリ（ARC量の2%)
  - L2ARCの管理に消費されるメモリ(L2ARC量の3%)

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- 何事も増やせば良いというものではない
  - アプリケーションに使うメモリ
  - ARCに使うメモリ
  - ARCの管理に消費されるメモリ（ARC量の2%)
  - L2ARCの管理に消費されるメモリ(L2ARC量の3%)
- **例：8GB物理メモリ、アプリケーションに3GBとする**
  - 残りは5GB
  - 1GBをキャッシュ管理に確保するとL2ARCは最大33GB
  - 4GBをARCにすると管理用メモリは80MB

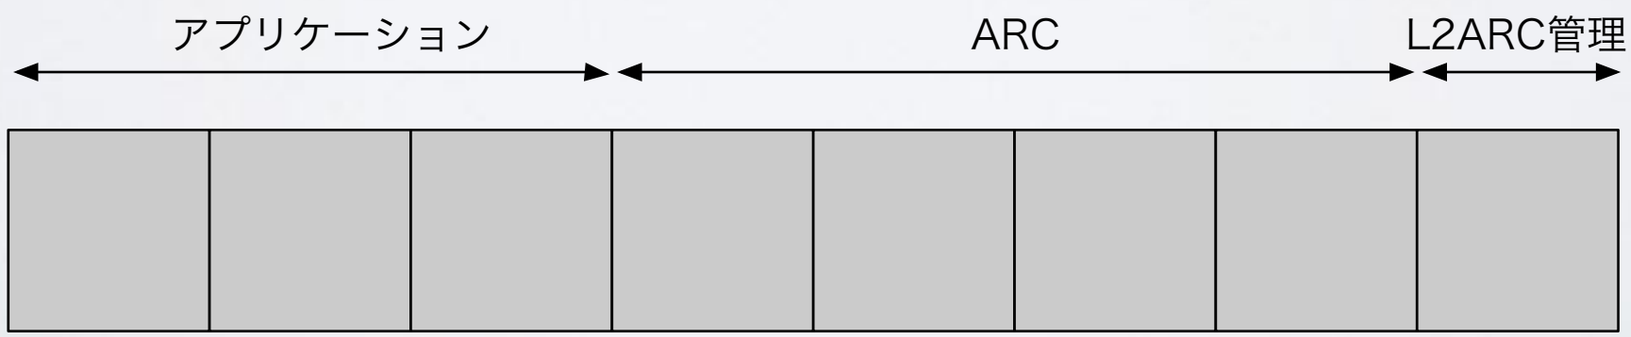

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ARCパラメータ

- 何事も増やせば良いというものではない
  - アプリケーションに使うメモリ
  - ARCに使うメモリ
  - ARCの管理に消費されるメモリ（ARC量の2%)
  - L2ARCの管理に消費されるメモリ(L2ARC量の3%)
- **例：8GB物理メモリ、アプリケーションに3GBとする**
  - デフォルト＝ARCが最大7GB。大丈夫？
    - アプリケーション用メモリが優先される
    - L2ARC管理領域を確保しないと効率が下がる

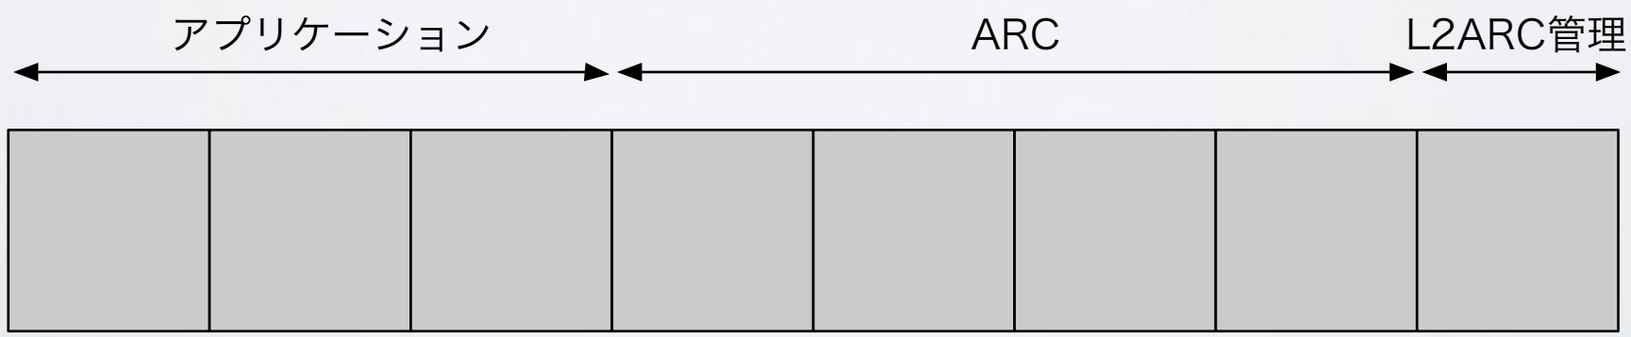

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSの書き込み性能

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- ZFSは、特に書き込みの性能にチューニングが必要！

SPAの処理構造

- DMUで変更があった部分 (dirty data) は、I/O要求として蓄積されていく
- この単位をTXGと呼ぶ
- TXGは最大3つ。Syncing TXGというTXGにある要求が処理される

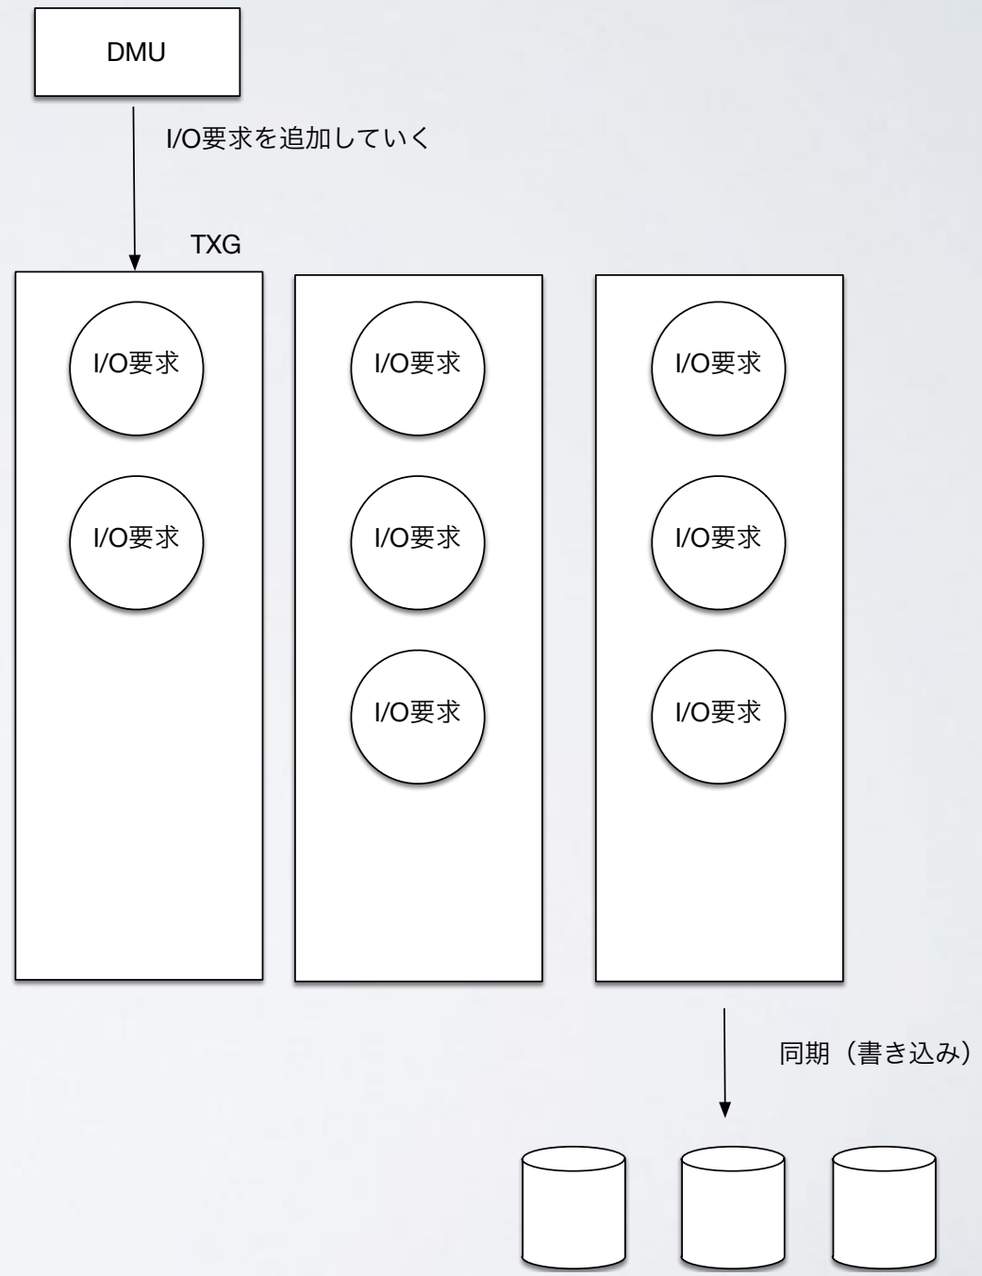

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **SPAの同期**
  - TXGは、
    「処理データが一定量に達する」か、
    「一定時間が経過する」かのいずれかで
    ストレージへの同期を行う
    - 一定量とは、全物理メモリ量の1/10である。
    - 一定時間とは、5 秒である。

- **例えば16GBのRAMならどうなる？**
  - 5秒間に平均320MB/sの書き込みが生じる！
  - HDDは間に合うか？　自分の用途でこの速度は十分か？

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **同期が間に合わないとどうなる？**
  - 重要：同期が終わるまで、ZFSの読み出しI/Oは
    ブロックされてしまう
  - 典型的な症状：
    - 書き込み負荷が高くなると、数秒おきにカクンカクンとシステムの
      応答が極端に遅くなったり、止まって見える
    - スムーズにデータが流れないので
      書き込み速度はHDDの本来の速度限界よりも
      SPAの処理で律速になってしまう
- 大きなメモリ、遅いストレージの組み合わせが要注意

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **チューニングするには**
  - 想像でやらない：同期が間に合っているのかを調べよう

- **性能の測定**
  - DTraceを活用！大変便利です。
    （スライド末尾にチュートリアルをつけました）

- まず、自分の使いたい負荷をかけた状態でディスクI/Oを測定

```
# dtrace -s diskio.d -c "sleep 30"
```

https://people.allbsd.org/~hrs/FreeBSD/diskio.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

```
# dtrace -s diskio.d -c "sleep 30"
  write
           value  ------------- Distribution ------------- count
              16 |                                         0
              32 |                                         31
              64 |@@@@@                                    505
             128 |@@@@@@@@@@@@@@@@@@@@@@@@@                2531
             256 |@@@@@@                                   588
             512 |@@                                       223
            1024 |@                                        57
            2048 |                                         46
            4096 |@                                        71
            8192 |                                         22
           16384 |                                         34
           32768 |@                                        69
           65536 |                                         27
          131072 |                                         0

    read
            value  ------------- Distribution ------------- count
               16 |                                         0
               32 |                                         2
               64 |@@@@@@@@@@@@                             4404
              128 |@@@@@@@@@@@@@@@@                         5937
              256 |                                         131
              512 |                                         33
             1024 |                                         116
             2048 |@                                        226
             4096 |@                                        510
             8192 |@@@@                                     1546
            16384 |@@@@                                     1418
            32768 |@                                        323
            65536 |                                         44
           131072 |                                         7
           262144 |                                         0

                               avg latency      stddev        iops  throughput
write                               1974us      9683us       140/s     1632k/s
read                                5043us     10832us       489/s     1394k/s
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

```
                                avg latency      stddev        iops  throughput
write                             1974us       9683us       140/s     1632k/s
read                              5043us      10832us       489/s     1394k/s
```

- この結果を確認し、チューニング前後でIOPSとスループットが増加するかどうかを調べること

ZFSのI/O：書き込み

- 次に、Syncing TXGの処理が間に合ってるのかどうか確認

```
# dtrace -s delayed-io.d -c "sleep 30"
dtrace: script 'delayed-io.d' matched 1 probe
dtrace: pid 58771 has exited

  no delay                                                  12151
```

注：no delay だけなら問題無し

https://people.allbsd.org/~hrs/FreeBSD/delayed-io.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- delayed が出ているようなら、間に合ってないのでlatencyを測定する。

```
# dtrace -s delay-mintime.d -c "sleep 30"
```

latencyのヒストグラムが出ます。

https://people.allbsd.org/~hrs/FreeBSD/delay-mintime.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

```
# dtrace -s zfs-txg.d a
CPU     ID                    FUNCTION:NAME
  8  57917                 none:txg-synced   64MB of 2454MB synced in 0.22 seconds
 11  57917                 none:txg-synced  702MB of 2454MB synced in 0.20 seconds
  7  57917                 none:txg-synced  444MB of 2454MB synced in 0.17 seconds
 11  57917                 none:txg-synced  442MB of 2454MB synced in 0.16 seconds
  4  57917                 none:txg-synced  384MB of 2454MB synced in 0.18 seconds
  1  57917                 none:txg-synced  478MB of 2454MB synced in 0.47 seconds
  2  57917                 none:txg-synced 1320MB of 2454MB synced in 0.75 seconds
  1  57917                 none:txg-synced 1672MB of 2454MB synced in 0.62 seconds
  8  57917                 none:txg-synced 1502MB of 2454MB synced in 0.26 seconds
  0  57917                 none:txg-synced  500MB of 2454MB synced in 0.19 seconds
  0  57917                 none:txg-synced  500MB of 2454MB synced in 0.22 seconds
  3  57917                 none:txg-synced  501MB of 2454MB synced in 0.24 seconds
  8  57917                 none:txg-synced  615MB of 2454MB synced in 0.34 seconds
  8  57917                 none:txg-synced  886MB of 2454MB synced in 0.28 seconds
  6  57917                 none:txg-synced    3MB of 2454MB synced in 0.21 seconds
```

https://people.allbsd.org/~hrs/FreeBSD/zfs-txg.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

pool名を引数に

TXGのI/Oのサイズ

TXGが保持できる最大サイズ

同期にかかった時間

```
# dtrace -s zfs-txg.d a
CPU     ID                    FUNCTION:NAME
  8  57917                 none:txg-synced   64MB of 2454MB synced in 0.22 seconds
 11  57917                 none:txg-synced  702MB of 2454MB synced in 0.20 seconds
  7  57917                 none:txg-synced  444MB of 2454MB synced in 0.17 seconds
 11  57917                 none:txg-synced  442MB of 2454MB synced in 0.16 seconds
  4  57917                 none:txg-synced  384MB of 2454MB synced in 0.18 seconds
  1  57917                 none:txg-synced  478MB of 2454MB synced in 0.47 seconds
  2  57917                 none:txg-synced 1320MB of 2454MB synced in 0.75 seconds
  1  57917                 none:txg-synced 1672MB of 2454MB synced in 0.62 seconds
  8  57917                 none:txg-synced 1502MB of 2454MB synced in 0.26 seconds
  0  57917                 none:txg-synced  500MB of 2454MB synced in 0.19 seconds
  0  57917                 none:txg-synced  500MB of 2454MB synced in 0.22 seconds
  3  57917                 none:txg-synced  501MB of 2454MB synced in 0.24 seconds
  8  57917                 none:txg-synced  615MB of 2454MB synced in 0.34 seconds
  8  57917                 none:txg-synced  886MB of 2454MB synced in 0.28 seconds
  6  57917                 none:txg-synced    3MB of 2454MB synced in 0.21 seconds
```

https://people.allbsd.org/~hrs/FreeBSD/zfs-txg.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

TXGが保持できる最大サイズ

TXGのI/Oのサイズ

同期にかかった時間

```
# dtrace -s zfs-txg.d a
CPU     ID                    FUNCTION:NAME
  8  57917                 none:txg-synced   64MB of 2454MB synced in 0.22 seconds
```

書き込みI/Oがあれば、少なくとも5秒で1回の同期が発生する。

一回の同期が5秒以上かかっている　＝　間に合ってない。

https://people.allbsd.org/~hrs/FreeBSD/zfs-txg.d

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **チューニングはどうやったら良いの？**
  - 1) TXGのサイズ調整
  - 2) TXGの同期I/O発行量
  - 3) TXGのタイムアウト

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **1) TXGのサイズ調整**

- **同期までに溜め込むI/Oの量は、次のsysctlで決まっている**

  vfs.zfs.dirty_data_max: 2573481984

  溜め込む量（バイト）。

  vfs.zfs.dirty_data_max_percent: 10

  data_maxをメモリ量から起動時に自動計算する時の%値。

  vfs.zfs.dirty_data_max_max: 4294967296

  data_max_percentで計算された値の上限。

  vfs.zfs.dirty_data_sync: 67108864

  TXG sync を強制的にスタートするサイズ: デフォルト64MB

- これらを増減させると、一回の同期量が変わる。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **2) TXGの同期I/O発行量**
- 同期用のI/Oを、HDDやSSDにいくつ並行で送るかという数
- sysctl とデフォルトは次の通り

vfs.zfs.vdev.trim_max_active: 64
vfs.zfs.vdev.trim_min_active: 1
vfs.zfs.vdev.scrub_max_active: 2
vfs.zfs.vdev.scrub_min_active: 1
vfs.zfs.vdev.async_write_max_active: 10
vfs.zfs.vdev.async_write_min_active: 1
vfs.zfs.vdev.async_read_max_active: 3
vfs.zfs.vdev.async_read_min_active: 1
vfs.zfs.vdev.sync_write_max_active: 10
vfs.zfs.vdev.sync_write_min_active: 10
vfs.zfs.vdev.sync_read_max_active: 10
vfs.zfs.vdev.sync_read_min_active: 10
vfs.zfs.vdev.max_active: 1000

非同期書き込み=10

同期書き込み=10

非同期読み出し=3

同期読み出し=10

scrub = 2

合計：35（注意：VDEV単位）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **2) TXGの同期I/O発行量**
- デバイスのキュー長を調べて、余裕があるなら増やす

```
# camcontrol identify /dev/da0 | grep Q

pass0: 600.000MB/s transfers, Command Queueing Enabled
Tagged Command Queuing (TCQ)    no          no
Native Command Queuing (NCQ)    yes                32 tags
NCQ Queue Management            no
NCQ Streaming                   no
Receive & Send FPDMA Queued     no
```

- 増やした時にTXG同期が
  間に合ってるかどうか入念にチェックすること。
- デフォルトの値はSSDなど、IOPSが大きくとれるものに
  対しては少ないので、増やした方が良い。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのI/O：書き込み

- **3) TXGのタイムアウト**
  - 5秒のタイムアウトを短くすることができる
    vfs.zfs.txg.timeout

- 短くするよりも、自分の負荷のデータ量で制限する方が良い
  - 5秒より短いtimeoutは、書き込み負荷が小さい時の
    処理オーバヘッドが増加したり、
    フラグメンテーション増加の要因になる

- そもそも書き込み負荷が小さい用途なら、
  増やすのも一つの方法

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ZFSのチューニングまとめ

- **読み込み：**
  キャッシュヒットがキーポイント。
  足りなければ増やすしかないが、特にメタデータの
  キャッシュヒット率が低いと全体的な性能が落ちる

- **書き込み：**
  TXGの同期量がキーポイント。
  自分の処理したい負荷、自分のマシンのメモリ、
  ストレージの能力に対して適正かどうかを測定して判断

- まだまだありますが、今回はこのへんで...
  （もっと聞きたいという人は要望を表明ください）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

おしまい

- 質問はありますか？

DTrace入門（おまけ）

佐藤　広生 <hrs@FreeBSD.org>

東京工業大学/ FreeBSD Project

2016/11/29

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

DTraceとは？

- 名前は聞いたことがあるけどよく知らない...

- システムやアプリケーションプログラムの
  内部動作を稼働中に調べるためのツール
  - 動作を調べる
  - ベンチマークを取る
  - などなど。**「稼働中に」「対象を変更せずに」**がポイント

- 2005年3月にSolarisに追加され、現在は
  OpenSolaris(illumos), Mac OSX, FreeBSD, NetBSD, Linux
  などで使える（カーネルが対応している必要あり）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

DTraceとは？

- Unix系OSでシステムの動作を調べるコマンドはたくさんある
- **Solaris:** sar(1), vmstat(1M), mpstat(1M), iostat(1M), netstat(1M), kstat(1M), prstat(1M),...
- **Mac OSX:** sar(1), vm_stat(1), top(1),...
- **FreeBSD:** systat(1), vmstat(8), iostat(8), netstat(8), sockstat(1), procstat(1), top(1),...

- DTrace は、これらと何か違うものなのか？

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

DTraceの特徴

- 個々のツールは統計情報の取得にCPU時間を多く使う
  → top(1)はとても重いユーティリティです。
- ktraceやtrussのようなツールはプロセス単位でしか情報が取れない
- システムコールなどのカーネルの動作は調べられるけれど、ユーザランドプログラムの動作を調べる方法は少ない
- 知りたい情報以外もたくさん出てきてしまう

- 例：今あるプロセスが read(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい！

準備

- FreeBSDの動作を調べるには

- FreeBSD 10 系ならば GENERIC カーネルで使えます。
- 9は
  options KDTRACE_HOOKS
  options DDB_CTF
  options KDTRACE_FRAME
  makeoptions DEBUG="-g"
  makeoptions WITH_CTF=1
  を入れてカーネルを作る必要があります。
  （ハンドブック参照のこと）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

準備

- FreeBSD以外のユーザランドプログラムにも
  DTraceを使いたい場合には

- /etc/make.confに
  STRIP=
  CFLAGS+=-fno-omit-frame-pointer
  WITH_CTF=1
  を付けてください

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

準備

- DTraceカーネルモジュールを読む

```
# kldload dtraceall
```

- dtraceコマンドを実行する

```
# dtrace -l
```

- 覚えておこう
  - 基本的にdtraceコマンドだけを使う
  - root権限が必要
  - カーネルモジュールは、読み込まれていなければ
    dtraceコマンドを実行する時点で自動で読み込まれる

準備

```
# dtrace -l
  ID   PROVIDER            MODULE                          FUNCTION NAME
   1     dtrace                       BEGIN
   2     dtrace                       END
   3     dtrace                       ERROR
   4        fbt                kernel                camstatusentrycomp entry
   5        fbt                kernel                camstatusentrycomp return
   6        fbt                kernel           cam_compat_handle_0x17 entry
   7        fbt                kernel           cam_compat_handle_0x17 return
:
:
:
```

- -l を指定して実行すると、何かたくさん行が出てくる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

使ってみよう

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

使ってみよう

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

使ってみよう

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -n 'syscall::read:entry /execname != "dtrace"/ { @reads[execname, arg2] = count(); }' -c "sleep 10"
dtrace: description 'syscall::read:entry ' matched 2 probes
dtrace: pid 98661 has exited
```

ftpd	71	1
ftpd	128	1
ftpd	260	1
rsync	262144	1
ftpd	41448	2
ftpd	1048600	2
sshd	16384	2
inetd	260	3
inetd	32768	9
ftpd	32768	14
spegla	4096	16
spegla	16384	18
cvsupd	8192	203
cvsupd	4096	1249
spegla	1	1653

使ってみよう

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -n 'syscall::read:entry /execname != "dtrace"/ { @reads[execname, arg2] = count(); }'
-c "sleep 10"
dtrace: description 'syscall::read:entry ' matched 2 probes
dtrace: pid 98661 has exited

  ftpd                                                         71                1
  ftpd                                                        128                1
  ftpd                                                        260                1
  rsync                                                    262144                1
  ftpd                                                      41448                2
  ftpd                                                    1048600                2
  sshd                                                      16384                2
  inetd                                                       260                3
  inetd                                                     32768                9
  ftpd                                                      32768               14
  spegla                                                     4096               16
  spegla                                                    16384               18
  cvsupd                                                     8192              203
  cvsupd                                                     4096             1249
  spegla                                                        1             1653
```

何をやったのか？

- dtraceコマンドは、D言語（注意：Walter Bright のD言語ではなくDTrace専用の簡易言語）で書かれたスクリプトを実行する
- 「-n "スクリプト本体"」、もしくは「-s スクリプトファイル名」
- 「-c "コマンド"」は、指定したコマンドが終了したら dtrace を止めるという指定

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

何をやったのか？

- D言語
  - AWKにとても良く似た文法
  - 「プローブ /述語/ { 手続き }」という宣言を並べるだけ！

- プローブ：調べたいポイント。「-l」で出てきたリストがそれ。
  - syscall::read:entry = read(2)が呼ばれた時点

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

何をやったのか？

- D言語
  - AWKにとても良く似た文法
  - 「プローブ /述語/ { 手続き }」という宣言を並べるだけ！

- 述語：条件の絞り込み（省略しても良い）
  - `/execname != "dtrace"/`
    → 実行ファイル名が dtraceでないもの

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

何をやったのか？

- D言語
  - AWKにとても良く似た文法
  - 「プローブ /述語/ { 手続き }」という宣言を並べるだけ！

- 手続き：何をやるか
  - execname と arg2 をキーにした連想配列に回数をセット

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

プローブはread(2)の入り口

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

- プローブを知るには？
  - dtrace -l で一覧が表示される
  - 「プロバイダ：モジュール：関数：プローブ名」
  - システムコールなら、syscallプロバイダにある
  - 省略や「*」が使える（syscall::read*: とするとreadvも対象）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

述語

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

- 述語で使える書き方
  - AWKと同じ（regexではない）。組み込み変数が使える。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

DTraceの組み込み変数

名前	意味
arg0, arg1, ... arg9	引数。int64_t。定義されていなければ0になる
args[]	引数。型は定義されたもの。
cpu	実行しているCPUのID
curpsinfo	現在のプロセスの情報（struct psinfo_t）
errno	最後のシステムコールのerrno
execname	現在のプロセス名
pid, ppid, uid, tid	PID, PPID, UID, スレッドID
timestamp	時刻

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

DTraceの組み込み変数

名前	意味
a	▶ ここで出てくる構造体の定義は、/usr/lib/dtrace/ にある。
a	▶ カーネルのヘッダファイルにある構造体ももちろん使用可能
c	
c	
c	
e	
e	
p	
ti	

```
typedef struct psinfo {
        int     pr_nlwp;        /* number of threads */
        pid_t   pr_pid;         /* unique process id */
        pid_t   pr_ppid;        /* process id of parent */
        pid_t   pr_pgid;        /* pid of process group leader */
        pid_t   pr_sid;         /* session id */
        uid_t   pr_uid;         /* real user id */
        uid_t   pr_euid;        /* effective user id */
        gid_t   pr_gid;         /* real group id */
        gid_t   pr_egid;        /* effective group id */
        uintptr_t
                pr_addr;        /* address of process */
        string  pr_psargs;      /* process arguments */
        u_int   pr_arglen;      /* process argument length */
        u_int   pr_jailid;      /* jail id */
} psinfo_t;
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

述語

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

- 述語で使える書き方
  - AWKと同じ（regexではない）。組み込み変数が使える。
  - プロセス名が dtrace と一致しないもの全部、という意味。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

述語

```
syscall::read:entry
/execname != "dtrace" && uid == 1000/
{
        @reads[execname, arg2] = count();
}
```

- 述語で使える書き方
  - AWKと同じ（regexではない）。組み込み変数が使える。
  - プロセス名が dtrace と一致しないもの全部、という意味。
  - こうすると、さらに UID が 1000 に一致するものに限定

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{ 手続き
        @reads[execname, arg2] = count();
}
```

- 手続きで使える書き方
  - これもAWKにとても似ている
  - 変数は宣言せずに使える。C言語風のキャスト文法にも対応
  - 宣言もできる。char, short(int16_t), int(int32_t), long long(int64_t), float, double, long doubleが使える。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

手続き

- read(2) のarg2って何だ？

```
% man 2 read

ssize_t
read(int fd, void *buf, size_t nbytes);
```

↓ここ

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{ 手続き
        @reads[execname, arg2] = count();
}
```

- 手続きで使える書き方
  - 文字列型として string がある。
  - []をつけると配列型になり、連想配列になる。配列のキーは","で区切って複数指定可能。
  - 構造体も定義可能。/usr/lib/dtrace/*.d の内容がデフォルト

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{ 手続き
        @reads[execname, arg2] = count();
}
```

- 手続きで使える書き方
  - スレッドローカル変数として、self->x = 1 という書き方ができる。0 を代入するか、スレッドがなくなると解放される。
  - 手続きローカル変数として、this->x = 1 という書き方ができる。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

```
syscall::read:entry /execname != "dtrace"/
{ 手続き
        @reads[execname, arg2] = count();
}
```

- 集約変数 @ と集約関数
  - カウンタ用の特殊文法。
  - @a = count(); とすると、呼ばれる度に a++ される。
  - @a[execname] = count(); とすると、プロセス名単位に
- a++ と同じだが、SMP環境での挙動がポイント

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

詳しく読んでみる

- 集約変数 @ と集約関数
  - 集約変数の代入は集約関数しかできない
  - count()：カウンタの値を1増やす
  - sum(a)：カウンタの値をa増やす
  - avg(a)：カウンタの平均値を計算する
  - min(a), max(a)：カウンタに最小値 or 最大値を保持する
  - quantize(a)：2の冪乗の単位でヒストグラムを生成する
  - lquantize(a, b, c, d)：線形なヒストグラムを生成する

もっと使ってみよう

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 例：**rsyncのプロセス**が 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べて**ヒストグラム**にしたい

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname == "rsync"/
{ @reads = quantize(arg2); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 例：**rsyncのプロセス**が 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べて**ヒストグラム**にしたい

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname == "rsync"/ { @reads = quantize(arg2); }'
dtrace: description 'syscall::read:entry ' matched 2 probes
dtrace: pid 14340 has exited


           value  ------------- Distribution ------------- count
           16384 |                                         0
           32768 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@ 32
           65536 |                                         0
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 例：**rsyncのプロセス**が 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べて**ヒストグラム**にしたい

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname == "rsync"/ { @reads = quantize(arg2); }'
dtrace: description 'syscall::read:entry ' matched 2 probes
dtrace: pid 14340 has exited
```

32kBのreadが32回

```
           value  ------------- Distribution ------------- count
           16384 |                                         0
           32768 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@ 32
           65536 |                                         0
```

quantize() は回数と大きさのヒストグラムを生成する

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- スクリプトにして実行しよう

  例：**5秒の間に、プロセス名と、そのプロセスが開いた**
  パス名のリストを出すスクリプト

```
#!/usr/sbin/dtrace -s
profile:::tick-5s
{
        exit(0);
}
syscall::open:entry
{
  @opens[execname, copyinstr(arg0)] = count();
}
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- スクリプトにして実行しよう

  例：**5秒の間に、プロセス名と、そのプロセスが開いた**
  パス名のリストを出すスクリプト

```
#!/usr/sbin/dtrace -s
profile:::tick-5s
{
        exit(0);
}
syscall::open:entry
{
  @opens[execname, copyinstr(arg0)] = count();
}
```

shebang行を書いて

"opens.d" という名前で保存

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- スクリプトにして実行しよう

  例：**5秒の間に、プロセス名と、そのプロセスが開いた**
  パス名のリストを出すスクリプト

```
#!/usr/sbin/dtrace -s
profile:::tick-5s
{
        exit(0);
}
syscall::open:entry
{
  @opens[execname, copyinstr(arg0)] = count();
}
```

profile:::tick-Ns というプローブは、
N秒後に一回マッチするプローブ

exit()関数は、dtraceを終了させる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- スクリプトにして実行しよう

  例：**5秒の間に、プロセス名と、そのプロセスが開いた**
  パス名のリストを出すスクリプト

```
# ./opens.d
dtrace: script './opens.d' matched 3 probes
CPU     ID                    FUNCTION:NAME
  0  55680                         :tick-5s

  ftpd                /etc/group                          8
  ftpd                /etc/pwd.db                         8
  ftpd                /usr/share/zoneinfo/UTC             8
  ftpd                /usr/share/zoneinfo/posixrules      8
  ftpd                .                                  24
#
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 前回のZFSの性能チューニングで使ったスクリプト

```
/*
 * Measure ZFS transaction group statistics
 */
txg-syncing /((dsl_pool_t *)arg0)->dp_spa->spa_name == $$1/
{
        start = timestamp;
        this->dp = (dsl_pool_t *)arg0;
        d_total = this->dp->dp_dirty_total;
        d_max = `zfs_dirty_data_max`;
}
txg-synced /start && ((dsl_pool_t *)arg0)->dp_spa->spa_name
== $$1/
{
        this->d = timestamp - start;
        printf("%4dMB of %4dMB synced in %d.%02d seconds",
        d_total / 1024 / 1024,
        d_max / 1024 / 1024, this->d / 1000000000,
        this->d / 10000000 % 100);
}
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 前回のZFSの性能チューニングで使ったスクリプト

```
/*
 * Measure ZFS transaction group statistics
 */
txg-syncing /((dsl_pool_t *)arg0)->dp_spa->spa_name == $$1/
{
        start = timestamp;
        this->dp = (d
        d_total = thi
        d_max = `zfs_
}
txg-synced /start &&
== $$1/
{
        this->d = tim
        printf("%4dMB
        d_total / 1024 / 1024,
        d_max / 1024 / 1024, this->d / 1000000000,
        this->d / 10000000 % 100);
}
```

```
% dtrace -l | grep txg-
57913     sdt          zfs                    none txg-quiesced
57914     sdt          zfs                    none txg-quiescing
57915     sdt          zfs                    none txg-opened
57916     sdt          zfs                    none txg-syncing
57917     sdt          zfs                    none txg-synced
```

実際には **sdt:zfs:none:txg-syncing** という名前。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- 前回のZFSの性能チューニングで使ったスクリプト

```
/*
 * Measure ZFS transaction group statistics
 */
txg-syncing /((dsl_pool_t *)arg0)->dp_spa->spa_name == $$1/
{
        start = timestamp;
        this->dp = (dsl_pool_t *)arg0;
        d_total = this->dp->dp_dirty_total;
        d_max = `zfs_
}
                                                    a->spa_name
        this->d = timestamp - start;
        printf("%4dMB of %4dMB synced in %d.%02d seconds",
        d_total / 1024 / 1024,
        d_max / 1024 / 1024, this->d / 1000000000,
        this->d / 10000000 % 100);
}
```

$$1 は、dtraceコマンドの引数の1番目（ここではzpool名）

このへんはカーネルのソースを読んで、
どのデータにアクセスしているのか調べないとわかりません....

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

もっと使ってみよう

- とてもとても複雑な例

```
# less /usr/sbin/dtruss
```

- truss(1)をD言語で書いたもの。そのまま実行できます。

```
# dtruss df -h
SYSCALL(args)              = return
mmap(0x0, 0x8000, 0x3)           = 6422528 0
issetugid(0x0, 0x0, 0x0)                 = 0 0
lstat("/etc\0", 0x7FFFFFFFD3E8, 0x0)              = 0 0

...
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ここまでのまとめ

- DTraceとは、カーネルやユーザランドプログラムの挙動を調べるための機構です。

- DTraceを使うには、カーネルが対応する必要があります。FreeBSD, Mac OS X などは、標準インストールで使えます。

- プローブ（データ収集点）とそれに対する処理をD言語で書き、イベントドリブンで動作します。

- D言語はAWKの文法によく似ています。

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ここまでのまとめ

- スクリプトを書くにはソースを読む能力が必要ですが、
  すでにたくさんのスクリプトが公開されています。
  性能測定用スクリプトなどは、詳しい内部構造を知らなくても
  使えます。

- プローブの種類は、OSによって異なります。
  他のOS用のスクリプトを持ってくる時には要注意。

- 既存のコードを変更せず、性能与える影響を最小限に
  抑えるように設計されているため、デバッグなどにも便利です
  （開発者はprintfデバッグの代わりに使えて重宝します）

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

次の話題

- DTraceで性能測定
- ユーザランドプログラムで使うには

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

復習：使い方

- 前準備は、前の資料の「準備」を参照のこと

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -c "sleep 10" -n '
syscall::read:entry /execname != "dtrace"/
{ @reads[execname, arg2] = count(); }'
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

復習：使い方

- 前準備は、前の資料の「準備」を参照のこと

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

プローブ　　述語

```
syscall::read:entry /execname != "dtrace"/
{
        @reads[execname, arg2] = count();
}
```

アクション

復習：使い方

- 例：今走っているプロセスが 10秒間でread(2)のシステムコールを何回発行し、どれくらいのデータ長のデータを読んだのか調べたい。

```
# dtrace -n 'syscall::read:entry /execname != "dtrace"/ { @reads[execname, arg2] = count(); }'
-c "sleep 10"
dtrace: description 'syscall::read:entry ' matched 2 probes
dtrace: pid 98661 has exited

  ftpd                                                         71                1
  ftpd                                                        128                1
  ftpd                                                        260                1
  rsync                                                    262144                1
  ftpd                                                      41448                2
  ftpd                                                    1048600                2
  sshd                                                      16384                2
  inetd                                                       260                3
  inetd                                                     32768                9
  ftpd                                                      32768               14
  spegla                                                     4096               16
  spegla                                                    16384               18
  cvsupd                                                     8192              203
  cvsupd                                                     4096             1249
  spegla                                                        1             1653
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能測定

- I/Oの測定：ioの発生原因とデータ長を出す　ioプロバイダ

```
profile:::tick-5s
{
    exit(0);
}
```

5秒で終わり

```
io:::start /args[0] != NULL/
{
    @[pid, execname] = quantize(args[0]->bio_bcount);
}
```

IOのデータ長

```
   20976  sync
          value  ------------- Distribution ------------- count
           1024 |                                         0
           2048 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@ 2
           4096 |                                         0
           8192 |                                         0
          16384 |@@@@@@@@@@@@@@@                          1
          32768 |                                         0
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能測定

- I/Oの測定：特定のプロセスのioの発生原因とデータ長を出す

```
profile:::tick-5s
{
    exit(0);
}
io:::start /pid == $target && args[0] != NULL/
{
    @[ustack()] = count();
}
```

$target は「-c コマンド」もしくは -p PIDで指定

ustack()は、ユーザランドのスタックトレースを返す

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能測定

- I/Oの測定：特定のプロセスのioの発生原因とデータ長を出す

```
# dtrace -s iopid.d -c 'cp -R /var/log /tmp'
dtrace: script 'iopid.d' matched 2 probes
dtrace: pid 21004 has exited
              libc.so.7`__sys_getdirentries+0x7
                0x3
                0xc985c031
                  1
              libc.so.7`mkdir+0x7
               cp`0x804c6d8
               0x585
                  1
              libc.so.7`__sys_openat+0x7
               0xffffff9c
               0x9090c35d
                  1
              libc.so.7`_write+0x7
               0x4
               0x44f8e0f
               177
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能測定

- I/Oの測定：I/Oのレイテンシをデバイス単位で出す

```
#!/usr/sbin/dtrace -s
#pragma D option quiet
io:::start
{
        start_time[arg0] = timestamp;
}

io:::done /this->start = start_time[arg0]/
{
        this->delta = (timestamp - this->start) / 1000;
        @a[args[1]->device_name, args[1]->unit_number] =
            quantize(this->delta);
        start_time[arg0] = 0;
}

profile:::tick-10s
{
        exit(0);
}
```

#pragma D option quiet は「-q」と同じ

timestampは現在時刻。

io-startで代入

io-doneで代入

デバイス名(da0)など

性能測定

- I/Oの測定：I/Oのレイテンシをデバイス単位で出す

```
da0
           value  ------------- Distribution ------------- count
               0 |                                         0
               1 |                                         1
               2 |                                         0
               4 |                                         2
               8 |                                         2
              16 |                                         1
              32 |                                         13
              64 |@                                        78
             128 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@ 3971
             256 |@@@@@@@@                                 1125
             512 |@@@                                      490
            1024 |@@                                       232
            2048 |                                         65
            4096 |                                         11
            8192 |                                         0
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

性能測定

- ネットワーク：
  80/tcpに到着するパケット数をクライアントIP別に集計

tcpプロバイダ

tcp:::receiveはTCP接続を受け取った時点

```
tcp:::receive /args[4]->tcp_dport == 80/
{
  @[args[2]->ip_daddr] = count();
}

# dtrace -s httpc.d -c "sleep 10"
dtrace: script 'httpc.d' matched 1 probe
dtrace: pid 21183 has exited

  127.0.0.1                                                     12
  ::1                                                           12
```

性能測定

- ネットワーク： TCP接続にかかる時間を測定

```
tcp:::connect-request
{
        start[args[1]->cs_cid] = timestamp;
}
tcp:::connect-established /start[args[1]->cs_cid]/
{
        @["Latency (us)", args[2]->ip_daddr] =
            quantize(timestamp - start[args[1]->cs_cid]);
        start[args[1]->cs_cid] = 0;
}
```

cs_cidは接続ID

```
# dtrace -s tcplatency.d -c "nc -z www.yahoo.com 80"
dtrace: script 'tcplatency.d' matched 2 probes
Connection to www.yahoo.com 80 port [tcp/http] succeeded!
dtrace: pid 21350 has exited

  Latency (us)                                        172.16.87.129
           value  ------------- Distribution ------------- count
          131072 |                                         0
          262144 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@ 1
          524288 |                                         0
```

ncを使って接続

性能測定

- ネットワーク： TCPステートマシンの遷移動作を見る

```
#pragma D option quiet
#pragma D option switchrate=10

dtrace:::BEGIN
{
        printf(" %12s %3s %12s  %-20s    %-20s\n",
            "PID", "CPU", "DELTA(us)", "OLD", "NEW");
        last = timestamp;
}

tcp:::state-change
{
        this->elapsed = (timestamp - last) / 1000;
        printf(" %12d %3d %12d  %-20s -> %-20s\n",
            pid, cpu, this->elapsed,
            tcp_state_string[args[5]->tcps_state],
            tcp_state_string[args[3]->tcps_state]);
        last = timestamp;
}
```

最初に一回

tcps_stateはステートを保持している

性能測定

- ネットワーク： TCPステートマシンの遷移動作を見る

wgetを使って接続：TCP接続が2本出てる！

```
# dtrace -s tcpstate.d -c "wget -o /dev/null http://www.google.com"

       PID CPU     DELTA(us)  OLD                   NEW
     21473   1        350651  state-closed          -> state-syn-sent
        12   1        103086  state-syn-sent        -> state-established
     21473   1         64244  state-closed          -> state-syn-sent
        12   1        102376  state-syn-sent        -> state-established
     21473   1         78939  state-established     -> state-fin-wait-1
        12   1           187  state-fin-wait-1      -> state-fin-wait-2
        12   1          1544  state-fin-wait-2      -> state-time-wait
     21473   1         16546  state-established     -> state-fin-wait-1
        12   1           729  state-fin-wait-1      -> state-fin-wait-2
        12   1            16  state-fin-wait-2      -> state-time-wait
```

PID=12ってなんだ？

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- PIDプロバイダを使ってユーザランドも調べられる
- そもそもDTraceの動作は、カーネル・ユーザランドの区別を特別扱いしない
- ユーザランド関数のプローブ：

```
pid$target:procname:probefunc:entry
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- dtrace -l を見てみる

```
# dtrace -l -P pid\$target -c "/bin/ls" | wc -l
230383
```

- 「pid$target:共有ライブラリ名:関数名:プローブ名」

```
# dtrace -l -P pid\$target -c "/bin/ls"
....
56421   pid21553  libutil.so.9  forkpty return
....
269515  pid21553  libc.so.7     poll entry
.....
```

ユーザランドDTrace

- /bin/echoを実行して、libc の関数を呼んでるところを見る

```
# dtrace -n 'pid\$target:libc*::entry { @[probefunc] = count(); }' \
        -c "/bin/echo"
dtrace: description 'pid\$target:libc*::entry ' matched 2996 probes

dtrace: pid 21579 has exited

  __malloc                                                  1
  __sys_exit                                                1
  __sys_writev                                              1
  _exit                                                     1
  _writev                                                   1
  atexit                                                    1
  exit                                                      1
  malloc                                                    1
  memset                                                    1
  mmap                                                      1
  writev                                                    1
  __cxa_finalize                                            2
```

「pid$target:**libc***::entry」を見ている

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- 自分で作ったプログラムならどうなの？

```
#include <stdio.h>

void
myfunc(int i)
{
        printf("...%d\n", i);
        return;
}

int
main(void)
{
        printf("hello, world\n");
        myfunc(100);

        return(0);
}
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- 自分で作ったプログラムならどうなの？

```
# cc hello.c
# dtrace -q -n 'pid\$target:a.out:myfunc:entry    \
              { printf("entry = %d\n",arg0); }' \
              -c ./a.out
hello, world
...100
entry = 100
#
```

「pid$target:実行ファイル名:関数名:entry」になるところに注意

```
# dtrace -l -m pid\$target:a.out -c ./a.out
53695   pid21805              a.out                                  _start entry
53696   pid21805              a.out                                  myfunc return
53697   pid21805              a.out                                  myfunc entry
53698   pid21805              a.out                                  myfunc 0
53699   pid21805              a.out                                  myfunc 1
....
```

「-m プロバイダ:モジュール」で表示を制限できる

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- MySQLやPostgreSQLは、DTraceに対応している
  → mysql$target:::filesort-start や
  mysql$target:::filesort-done が定義されていて、
  データベースの検索の性能分析や動作をトレースできる

```
mysql$target:::filesort-start
{
        self->ts = timestamp;
        printf("Sort start: %s", copyinstr(arg0));
}
mysql$target:::filesort-done
{
        printf("Sort done: %d ms / Result: %s",
            (timestamp - self->ts) / 1000000,
            copyinstr(arg0));
}
```

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

- DTraceに対応してるという意味は？
  → 独自のプロバイダを持っているということ
  （SDT: Statically Defined Tracingというタイプのプローブ）

- 関数単位であれば、対応していなくても使える

- USDTの作り方：

```
% cat provider.d
provider database {
        probe query__start(char *);
        probe query__done(char *);
};

% dtrace -h -s provider.d

DATABASE_QUERY_START("hoge") -> database$target:::query-start
DATABASE_QUERY_DONE("fuga")  -> database$target:::query-done
```

定義

provider.hの生成

対応関係

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

ユーザランドDTrace

```
#include <stdio.h>

#include <sys/sdt.h>
#include "provider.h"

int
main(void)
{
        /* Give us time to start DTrace */
        sleep(5);

        DATABASE_QUERY_START("SELECT * FROM apples");
        /* simulate a long query */
        sleep(1);
        DATABASE_QUERY_DONE("TOO MANY APPLES");

        return (0);
}
```

provider.h とsys/sdt.h をinclude

定義したものを使う

注意：libelf をリンクすること

https://people.allbsd.org/~hrs/sato-FBSDS20161129.pdf

まとめ

- 一見複雑そうに見える測定でも、数行のスクリプトでいけるだけの記述力
- デバッグ、ユニットテスト、動作の検証、性能測定など、いろいろな用途に重宝するはず
- 触ってみましょう！