DTrace für Einsteiger

Thomas Nau, kiz (Thomas.Nau@uni-ulm.de)

Timeline

- über uns und mich
- early-days
- DTrace Kurzübersicht
- DTrace warp-engine
- Showcase
- wrap-up
- Q & A

Kommunikations- und Informationszentrum (kiz)

- Die Aufgaben der „Abteilung Infrastruktur“ umfassen u.a.
  - Azubi Ausbildung
  - Cluster basierende Universitäts weite Mail-, LDAP-, Portal-, Datenbank- und File-Services, ...
  - Betreuung von ca. 600 Desktop und Laptop Arbeitsplätzen
    - 25% Linux, 75% Windows
  - Backup Service (Bacula Enterprise) für mehrere Universitäten in Baden-Württemberg
  - Landes HPC Cluster mit Schwerpunkt „Theoretische Chemie“
  - 4 lokale Netzwerke plus flächendeckendes Campus WLAN und MAN im Ulmer Stadtbereich
  - Telefonanlage mit ca. 14.000 Anschlüssen unter Einsatz von VoIP und 2-Draht Technik

The early days

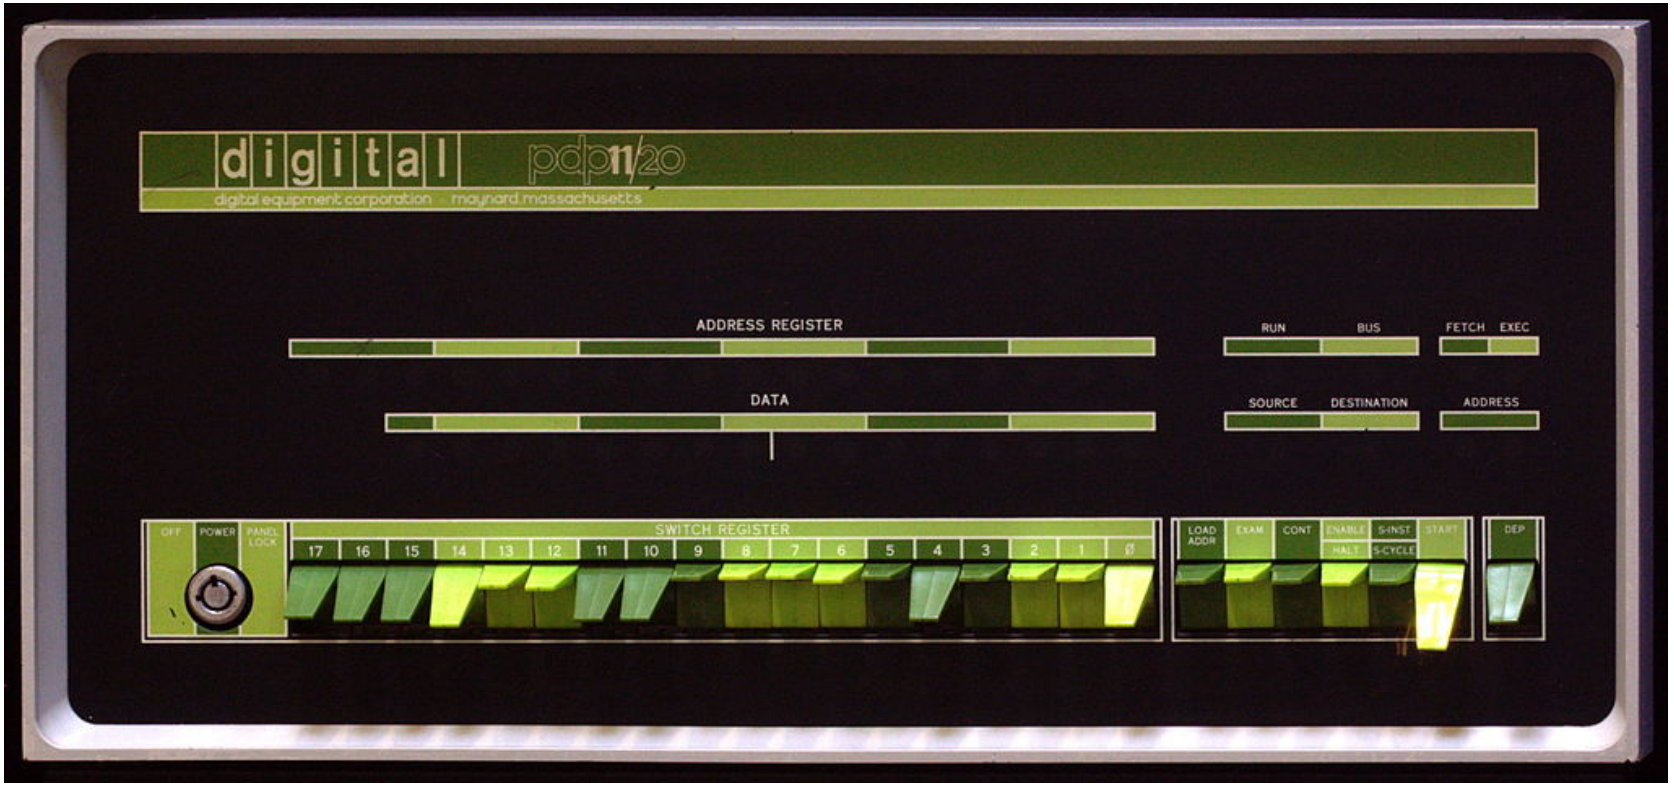

Source: Wikipedia, Autor: Rama & Musée Bolo, Derivative Work: Morn

Analyse / Debugging

==

Logic Analyzer

+

Schaltpläne

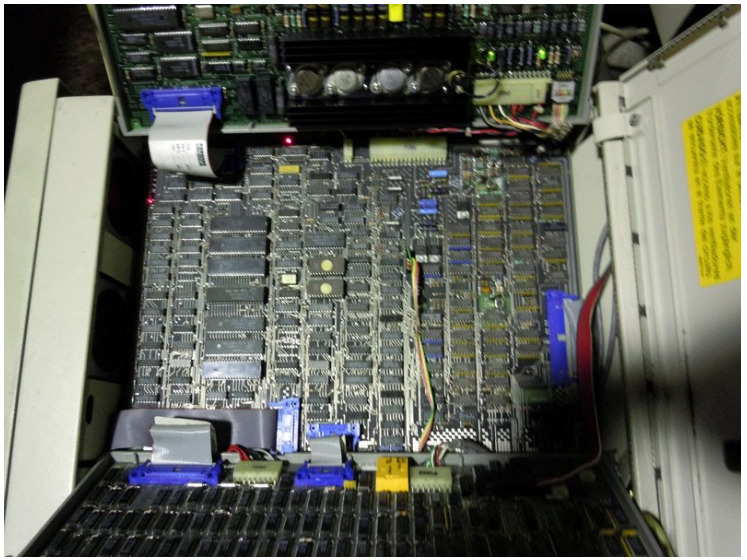

Source: http://www.ricomputermuseum.org/Home/equipment/dec-pdp-1144/pdp-11-44-restoration

Source: http://mashable.com/2012/07/04/dawson-leery-laments-90s-tech/#gallery/90s-problems

vmstat(1m)

- liefert statistische Daten über Kernel Threads, Platten IO, CPU Last, virtuellen Speicher und traps
- liefert nur wenige Anhaltspunkte wo Engpässe zu finden sind
  - hohe Anzahl von system-calls oder context-switches
  - viele page-in oder page-out Ereignisse

```
jedi# vmstat 5
 kthr      memory            page            disk          faults      cpu
 r b w   swap  free  re  mf pi po fr de sr m0 m1 m3 m1   in   sy   cs us sy id
 0 0 0 8620144 4617688 67 69 1  1  1  0  0  0  1  0  0 6147 1254 5529  0  1 99
 0 0 0 8702320 4730536 6  5  0  0  0  0  0  0  0  0  0 8010  532 7370  0  2 98
 0 0 0 8788856 4816776 6  1  0  0  0  0  0  0  0  0  0 7990  534 7428  0  2 98
^C
```

prstat(1m) (vergleichbar zu Linux *top(1)*)

- liefert viele Informationen über laufende Prozesse und deren Threads
  - guter Ausgangspunkt falls Anwendungsprobleme vermutet werden

```
jedi# prstat -Lm
   PID USERNAME USR SYS TRP TFL DFL LCK SLP LAT VCX ICX SCL SIG PROCESS/LWPID
 16480 xvm      6.9 9.8 0.0 0.0 0.0  27  54 1.8 30K 114 .2M   0 qemu-dm/3
   363 xvm      0.1 0.2 0.0 0.0 0.0 0.0 100 0.0   4   1  2K   0 xenstored/1
 16374 root     0.0 0.1 0.0 0.0 0.0 100 0.0 0.0  10   0  1K   0 dtrace/1
  1644 xvm      0.1 0.1 0.0 0.0 0.0  33  66 0.0 569   7 835   0 qemu-dm/3
  2399 root     0.0 0.1 0.0 0.0 0.0 0.0 100 0.0  49   0 388   0 sshd/1
 16376 root     0.0 0.1 0.0 0.0 0.0 0.0 100 0.0  38   0 297   0 prstat/1
 11705 xvm      0.0 0.1 0.0 0.0 0.0  50  50 0.0 576  15 858   0 qemu-dm/4
 16536 root     0.0 0.1 0.0 0.0 0.0 0.0 100 0.0  48   0 286   0 vncviewer/1
```

prstat(1m) Erklärungsnot

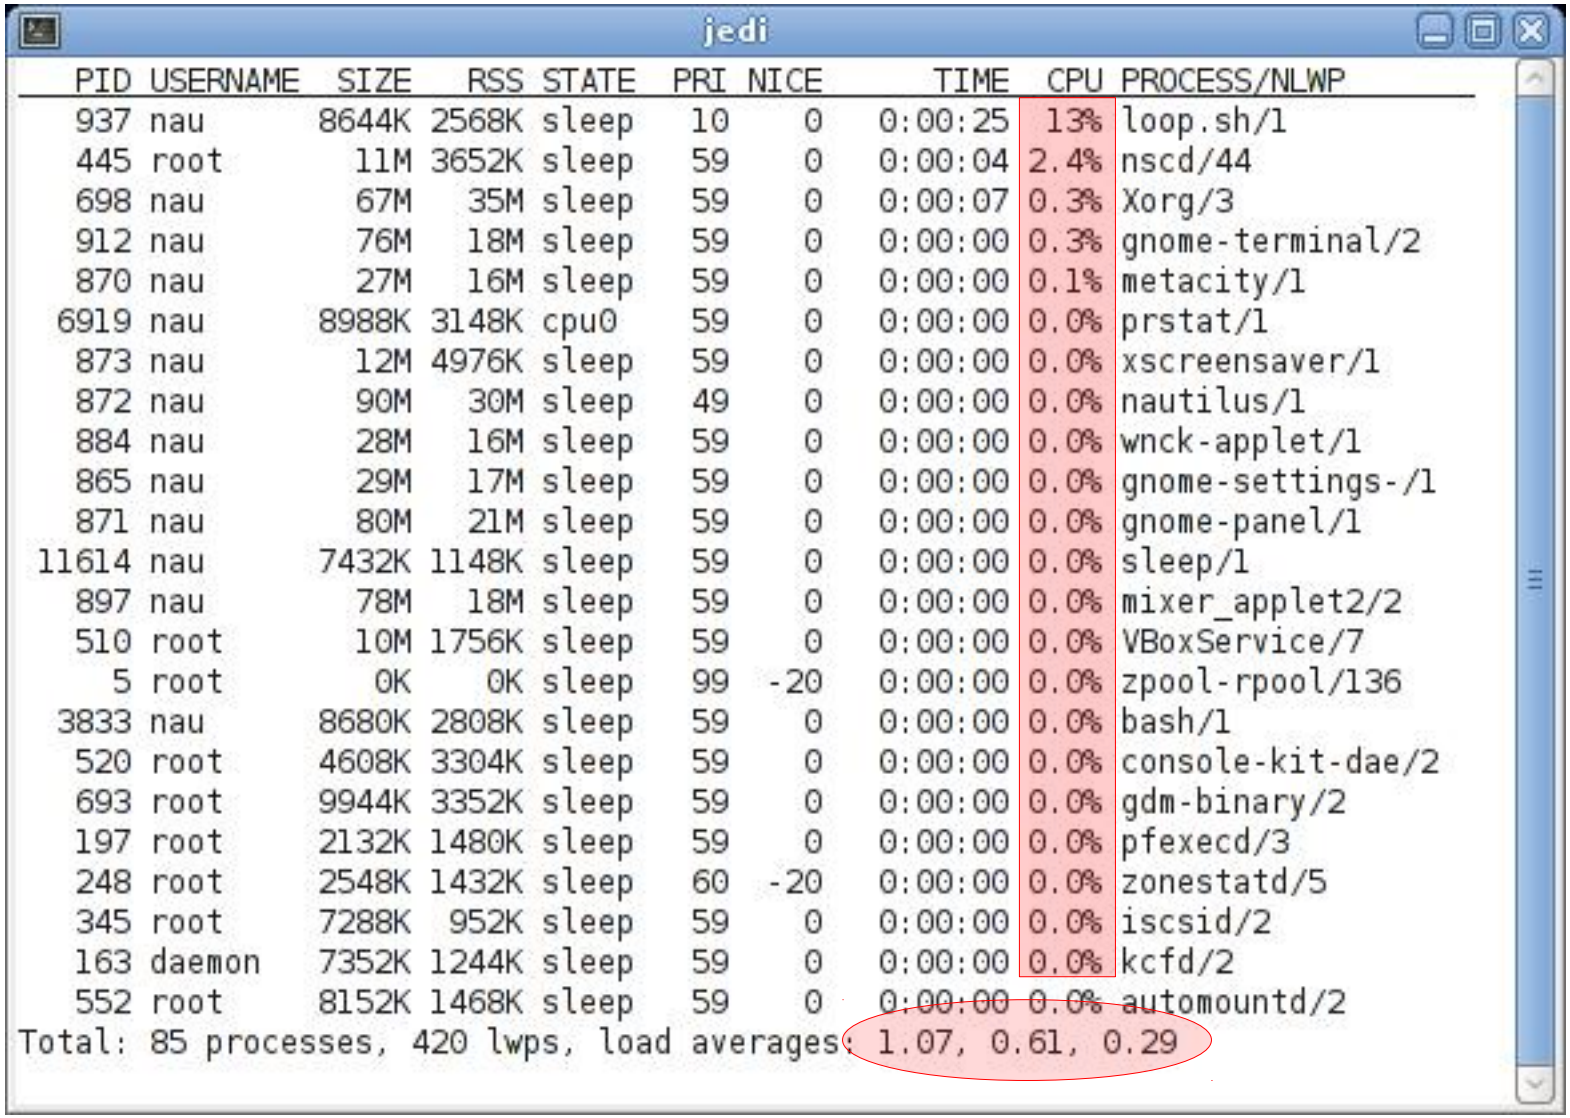

truss(1) (vergleichbar zu Linux *strace(1)*)

- *truss(1)* ist nicht dynamisch
  - Analyse vorübergehender oder kurzlebiger Probleme ist schwierig oder gar unmöglich
  - stoppt die Anwendung um Daten zu sammeln und beeinflusst dadurch besonders das Timing der Anwendung
- Auswertung zusammenhängender Prozesse schwierig oder gar unmöglich (Bsp.: user login)
- die Kernel Grenze kann nicht überschritten werden

„A process cannot be understood by stopping it. Understanding must move with the flow of the process, must join it and flow with it.“

„Erste Regel von Mentat“ aus „Dune – Der Wüstenplanet“

„... das sind nicht die Tools die ihr sucht ...“

Source: http://www.jedipedia.de/wiki/Telepathie, © LucasFile


Was würde er machen?
MACGYVER

Brendan Gregg, DTrace Guru im August 2014

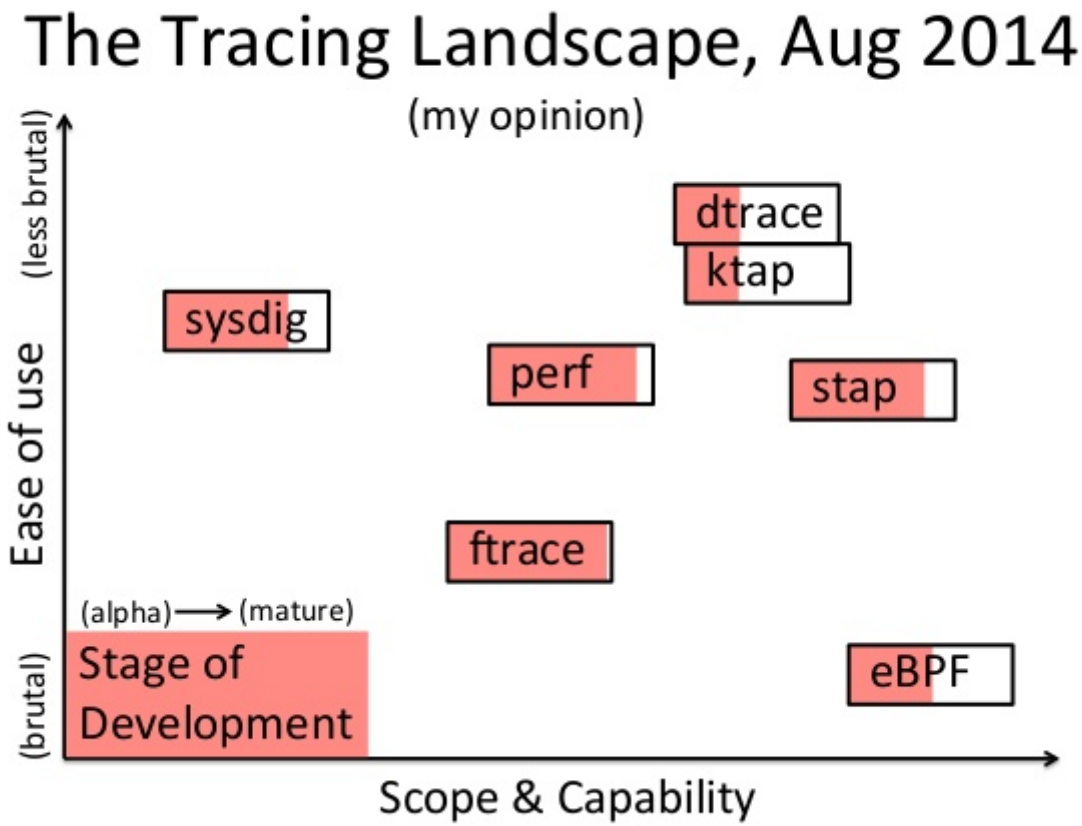

DTrace, die „Dynamic Tracing Facility“

- instrumentiert dynamisch und effizient Kernel- aber auch Bibliotheks- und Anwendungs-Code
- derzeit 100.000+ „Probes“ verfügbar
  - Zahl ist von geladenen Kernel-Modulen abhängig
  - ~90% sind Kernelfunktionen (*function boundary trace provider,* FBT)
  - lassen sich beliebig und effizient ein- bzw. ausschalten
- skriptfähig durch „C“ ähnliche Sprache „D“
- wird im Kernel Kontext ausgeführt
  - keine Schleifen (for, while, …) aus Sicherheitsgründen möglich
- viele Solaris Tools verwenden DTrace unter der Haube

DTrace Block Schaubild

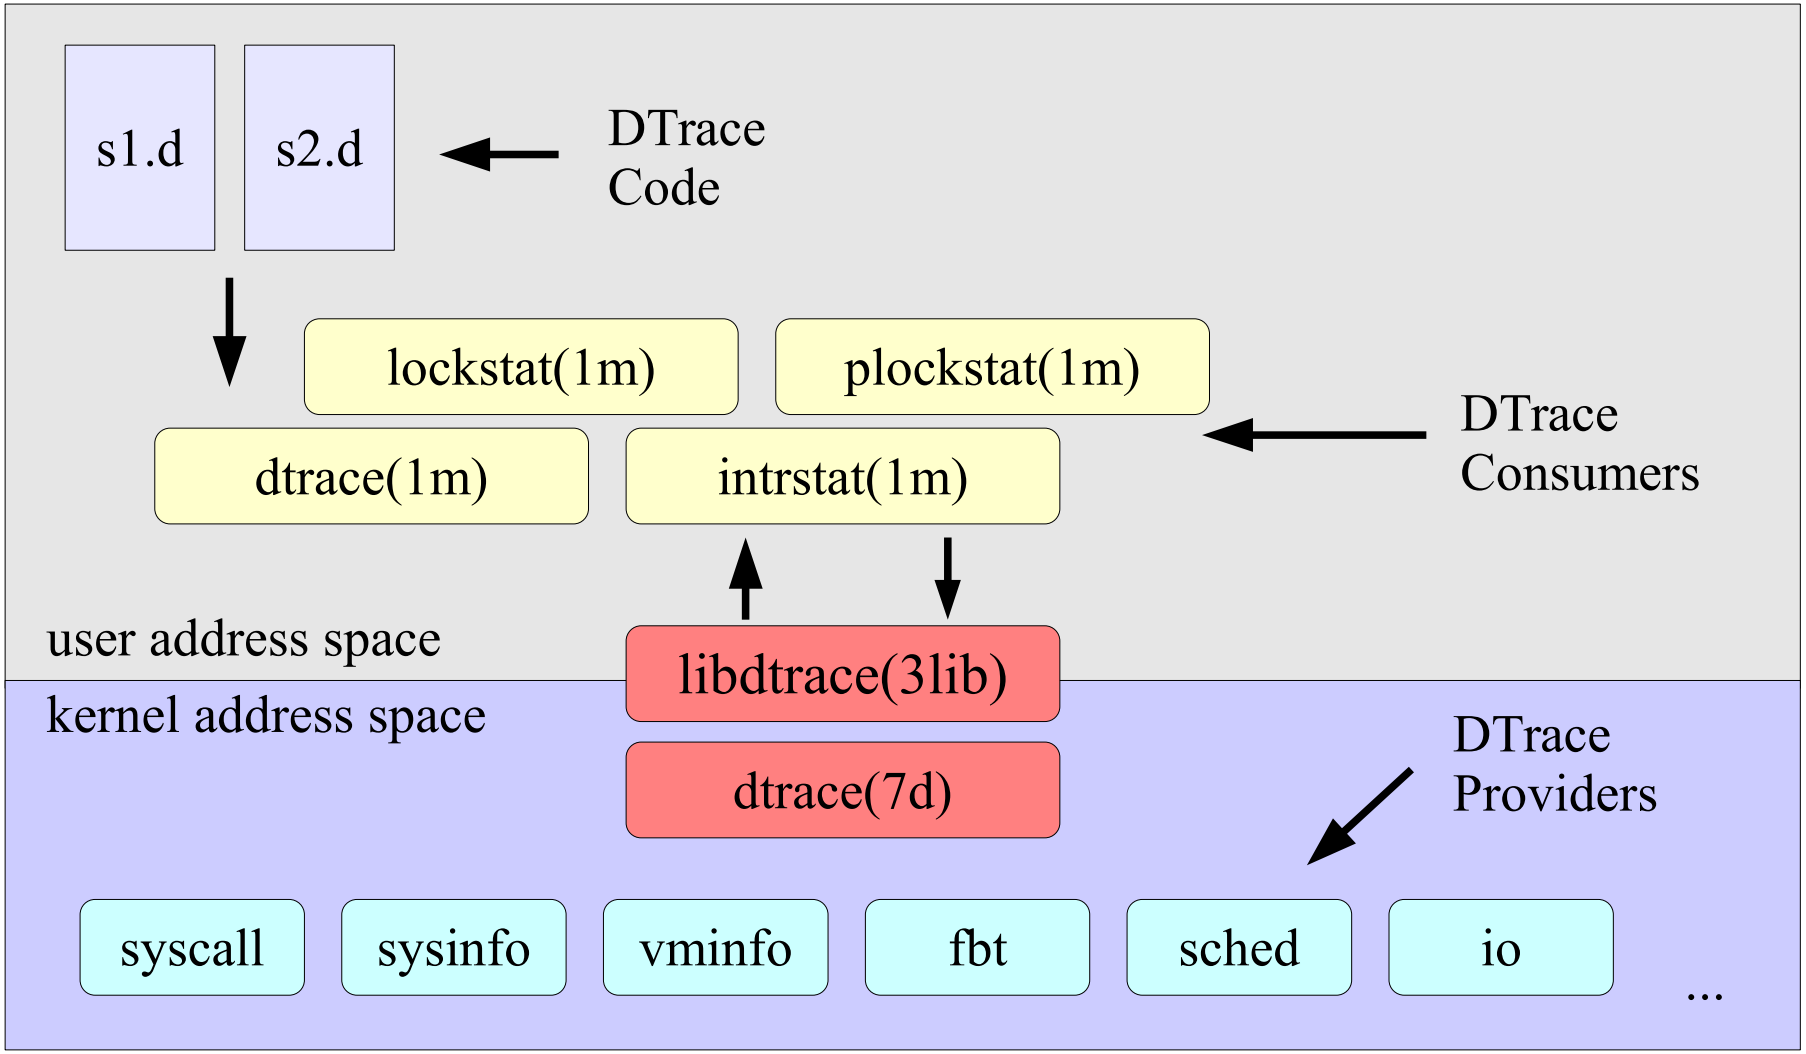

Provider

- stellen sogenannte „Probes“ zur Verfügung
- sammeln Daten, bereiten sie sinnvoll auf und stellen sie in Puffern für asynchrone Weiterverarbeitung bereit
- decken spezifische Bereiche z.B.
  - proc: Informationen über Prozesse und Threads
  - syscall: Infromationen über Solaris system-calls
  - io: Disk-IO bezogene Probes

Probes

- „Triggerpunkte“ die vielfältige Aktionen auslösen können
  - Aufzeichnung von Kernel- oder User-Stacks
  - Aufzeichnung von Datenstrukturen oder Speicherinhalten
  - Manipulation von Daten oder Speicherinhalten
  - ...
- Namens-Syntax für Probes

  provider:module:function:name

  sched:unix:resume:off-cpu

Beispiel: wer öffnet welche Datei?

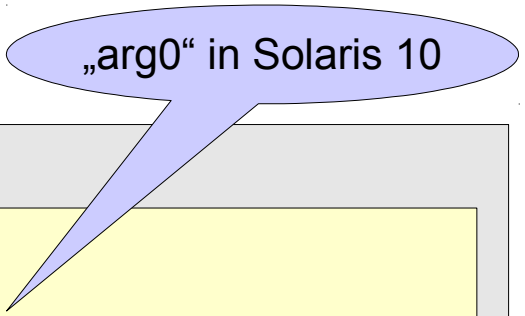


```
obi-wan# dtrace -q -n \
  'syscall::open*:entry {
     printf("%-20s %s\n", execname, copyinstr(arg1));
}'
```

```
httpd                /www/htdocs/guc/bilder/grafik/m_kontakt.gif
httpd                /www/cms/uploads/pics/rw_logo2_03.png
mysqld               /www/mysqldata/cms/fe_users.MYI
mysqld               ./cms/fe_users.MYD
mysqld               /www/mysqldata/cms/fe_groups.MYI
...
```

„D“ Sprachstruktur

- „D“ definiert eine Art „Unterprogramm-Sammlung“
- einfache Struktur die sequentiell von oben nach unten ausgewertet wird; „Bedingungen“ sind optional

```
Proben-Namen
/ Bedingung /
{
        Aktionen
}
```

- aus Sicherheitsgründen kennt „D“ keine Schleifen, …
- einfach auch in eigene Anwendungen integrierbar
  - perl, MySQL, ...

Variable, Typen und Operatoren

- „C look and feel“ mit geringen Unterschieden

  int8_t, uintptr_t, ...

- Skalare, Strings, Zeiger, *structs* und *unions* sind verfügbar
  - provider und consumer laufen in unterschiedlichen Adressräumen
- Variable müssen nicht vor Verwendung definiert werden
  - viele schon vordefiniert: *pid, uid, execname, curcpu, …*
  - lesender Zugriff auf Kernel variable möglich: *`kmem_flags*
- grundlegende Arithmetik-, Logik- und Vergleichs-Operatoren stehen zur Verfügung
  - Vergleichs-Operatoren können auf Strings angewendet werden; liefern 1 im Falle von Gleichheit sonst 0

Ausgabe bzw. Sammeln von Daten

- printf() arbeitet wie in „C“ mit Format-Strings
  - nützliche Erweiterungen verfügbar
    - 'a' Ausgabe eines Zeigers als Kernel Symbol
    - 'p' Hexadezimal Ausgabe eines Zeigers
    - 'S' Ausgabe von Strings wobei nicht druckbare Zeichen mit „\“ dargestellt werden
    - 'Y' formatiert ein Argument „Nanosekunden seit 1.1.1970“ als für Menschen verständlichen String
  - *printa()* arbeitet analog zu *prinf()* mit “aggregations“
- *stack(), ustack()*
- *tracemem()*

Beispiel: alle Lesezugriffe auf Dateien im System

```
obi-wan# cat ./reads.d
#!/usr/sbin/dtrace -s

#pragma D option quiet

syscall::read:entry {
    printf("%-16s %10s %s\n",
        execname, probefunc, fds[arg0].fi_pathname
    );
}
```

```
obi-wan# ./reads.d
bacula-fd          read       /backup/mail/imap/l/user/PRIVACY/53065.
bacula-fd          read       /backup/mail/imap/l/user/PRIVACY/53065.
hwmgmtd            read       /tmp/hmptemp/ssmlibipmitool_stdout_Bnb3b
sshd               read       /devices/pseudo/clone@0:ptm
nscd               read       /etc/passwd
```

DTrace's Warp Antrieb: Aggregations

f(f(x0) U f(x1) U ... U f(xn)) = f(x0 U x1 U ... U xn)

Aggregations nutzen eine besondere mathematische Eigenschaft bestimmter Funktionen aus

Beispiel: *sum()* Aggregation

$$\Sigma\ 1, 2, 3, \ldots 99, 100 = 5050$$

$$\Sigma\ 1, \ldots 10 = 55$$

$$\Sigma\ 11, \ldots 20 = 155$$

...

$$\Sigma\ 91, \ldots 100 = 955$$

$$\Big\} \Sigma = 5050$$

DTrace's Warp Antrieb: Aggregations

- halten den Speicherbedarf gering
  - keine Notwendigkeit alle Daten zwischenzuspeichern
  - Probleme mit der Skalierung werden vermieden
- derzeit
  - count(), sum()
  - min(), max(), avg(), stddev()
  - quantize(), lquantize(), llquantize()
- der Index von Aggregations ist nahezu beliebig, etwa *ustack()* und *stack()* oder *execname, pid, ...*

Beispiel: Solaris 11 IP Provider Probes

- send — Solaris Netzwerk Stack verschickt ein IP Paket
- receive — Solaris Netzwerk Stack empfängt ein IP Paket

- der IP Provider übergibt Daten über 6 Pointer auf:

pktinfo_t *	csinfo_t *	ipinfo_t *
ifinfo_t *	ipv4info_t *	ipv6info_t *

ipinfo_t und *ipv4info_t* Definitionen

```
typedef struct ipinfo {
        uint8_t ip_ver;         /* IP version (4, 6)     */
        uint16_t ip_plength;    /* payload length        */
        string ip_saddr;        /* source address        */
        string ip_daddr;        /* destination address   */
} ipinfo_t;

typedef struct ipv4info {
    ...
    uint8_t ipv4_protocol;      /* next level protocol   */
    string ipv4_protostr;       /* same as a string      */
    ...
    ipaddr_t ipv4_src;          /* source address        */
    ipaddr_t ipv4_dst;          /* destination address   */
    string ipv4_saddr;          /* src address, string   */
    string ipv4_daddr;          /* dest address, string  */
    ...
} ipv4info_t;
```

Beispiel: Verteilung der IP Paket Größe

- basiert auf Beispiel von

  https://wikis.oracle.com/display/DTrace/ip+Provider

- gut geeignet für IP basierte File- oder Storage Server

```
#!/usr/sbin/dtrace -s

#pragma D option quiet

ip:::send
{
    @ipstats[args[2]->ip_daddr, execname] =
        quantize(args[2]->ip_plength);
}
```

2^n Verteilung

Beispiel: Verteilung der IP Paket Größe

```
...
192.168.23.23                                                  nfsd

     value  ------------- Distribution ------------- count
        16 |                                         0
        32 |                                         1
        64 |                                         0
       128 |@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@@        244
       256 |@@@@@@@@@@@                              88
       512 |                                         0
      1024 |@@@@                                     32
      2048 |                                         0
...
```

Hilfreiche Funktionen für Aggregations

- *trunc(@aggr [, n])*
  löscht eine Aggregation oder Teile davon

  n > 0 die obersten n Einträge bleiben erhalten

  n < 0 die untersten n Einträge bleiben erhalten

- *clear(@aggr)*
  setzt die Werte einer Aggregation auf 0

- *normalize(@aggr, val)*
  dividiert alle Werte durch *val*

- *denormalize()*
  macht die Normierung rückgängig

- Tipp: im Zusammenspiel mit der *tick* probe lassen sich einfach top-ten artige Ausgaben realisieren

Beispiel: „Top-10“ Netzverkehr einzelner Clients

```
/* output collected data
 */
tick-$1 {
        /* top-n only */
    trunc(@ipstats, $2);

        /* print per second rate */
    normalize(@ipstats,(timestamp-ts) / 1000000000);
    printf("\n%Y\n", walltimestamp);
    printa("%-15s %-10s %@15d\n", @bytes);

        /* start next interval from scratch */
    ts = timestamp;
    trunc(@ipstats);
}
```

Beispiel: „Top-10“ Netzverkehr einzelner Clients

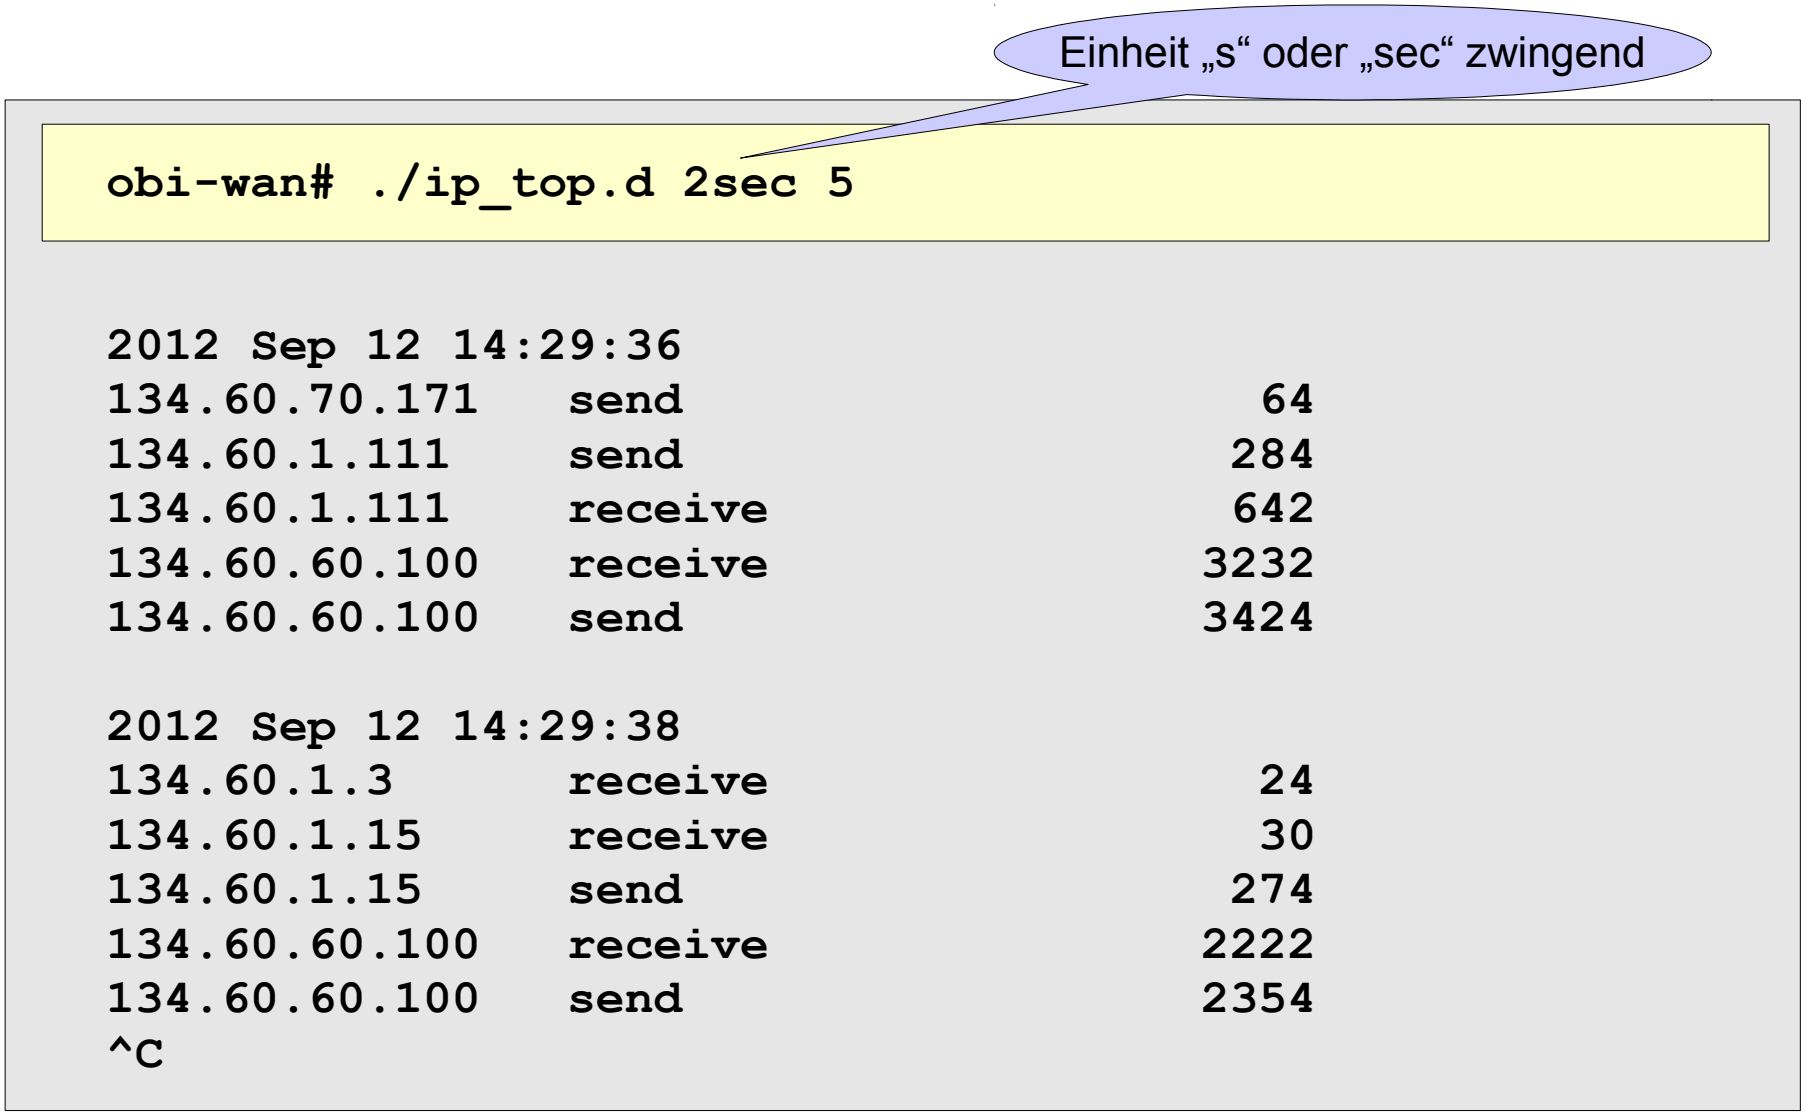

pid Provider Beispiel: Aufruf-Stacks

```
obi-wan# ./lib_call_stack.d -c ls 'libc' 'str*'

lib_call_stack.d                                  'ls' output

pid1002:libc.so.1:strcmp
              libc.so.1`strcmp
              libc.so.1`setlocale+0x1378
              ls`main+0x22
              ls`_start+0x7a
pid1002:libc.so.1:strlen
              libc.so.1`strlen
              ls`xstrdup+0x12
              ls`main+0x486
              ls`_start+0x7a
pid1002:libc.so.1:strlen
              libc.so.1`strlen
              ls`xstrdup+0x12
```

Showcase
„Bacula Enterprise Backup“

Showcase „Bacula Enterprise Backup“

- 2x Oracle SPARC-T4 Server mit jeweils
  - 128GB RAM
  - 3 dual-port SAS-2 HBA, 1 dual-port 16Mb Fiber-Channel HBA
  - 10GE Anbindung an Backbone und ggf. direkt an Belwue
- 2x Quanta M4600H JBODs mit jeweils
  - 60 x 4TB SAS-2 HGST Enterprise Platten
  - 150TB nutzbare Kapazität ohne Komprimierung
    - ZFS 7x 6+2 RAIDZ2 plus 4 hot-spare
  - filebench multi-stream IO: ~3.5 GB/s
- 8x IBM 3592-E07 Fiber-Channel Bandlaufwerke
  - 250-600 MB/s gemessen abhängig von Kompression

Showcase „Bacula Enterprise Backup“

- Backup Strategie
  - sichern auf Disk
  - Migration auf Tape bei Bedarf
- Pre-Production Tests lieferten für Daten > ~2 TB bei disk-to-tape Migration schlechtere Durchsatzwerte als erwartet
  - Migration von 6TB in 4,5 Millionen Daten benötigt 30 Stunden; Datenrate nur ca. 61 MB/s
  - enttäuschend im Vergleich zum initialen Backup vom Client (36h)

Showcase „Bacula Enterprise Backup“

- DTrace sampling des Programmzählers mit einer Frequenz von 1001Hz zeigt keine CPU Engpässe

```
Routine                                  calls   prct.
SPARC-T4`copyin                           8630    0.2%
zfs`fletcher_4_native                    10902    0.3%
zfs`vdev_raidz_generate_parity_pq        19815    0.5%
zfs`lzjb_compress                       234676    5.9%
unix`cpu_halt                          3670636   91.8%
```

- *IO-provide*r bestätigt gleichbleibend große IO chunks (256kB)

Showcase „Bacula Enterprise Backup“

- *IO-provider* liefert aber auch erste Hinweise auf „schleichendes Problem“

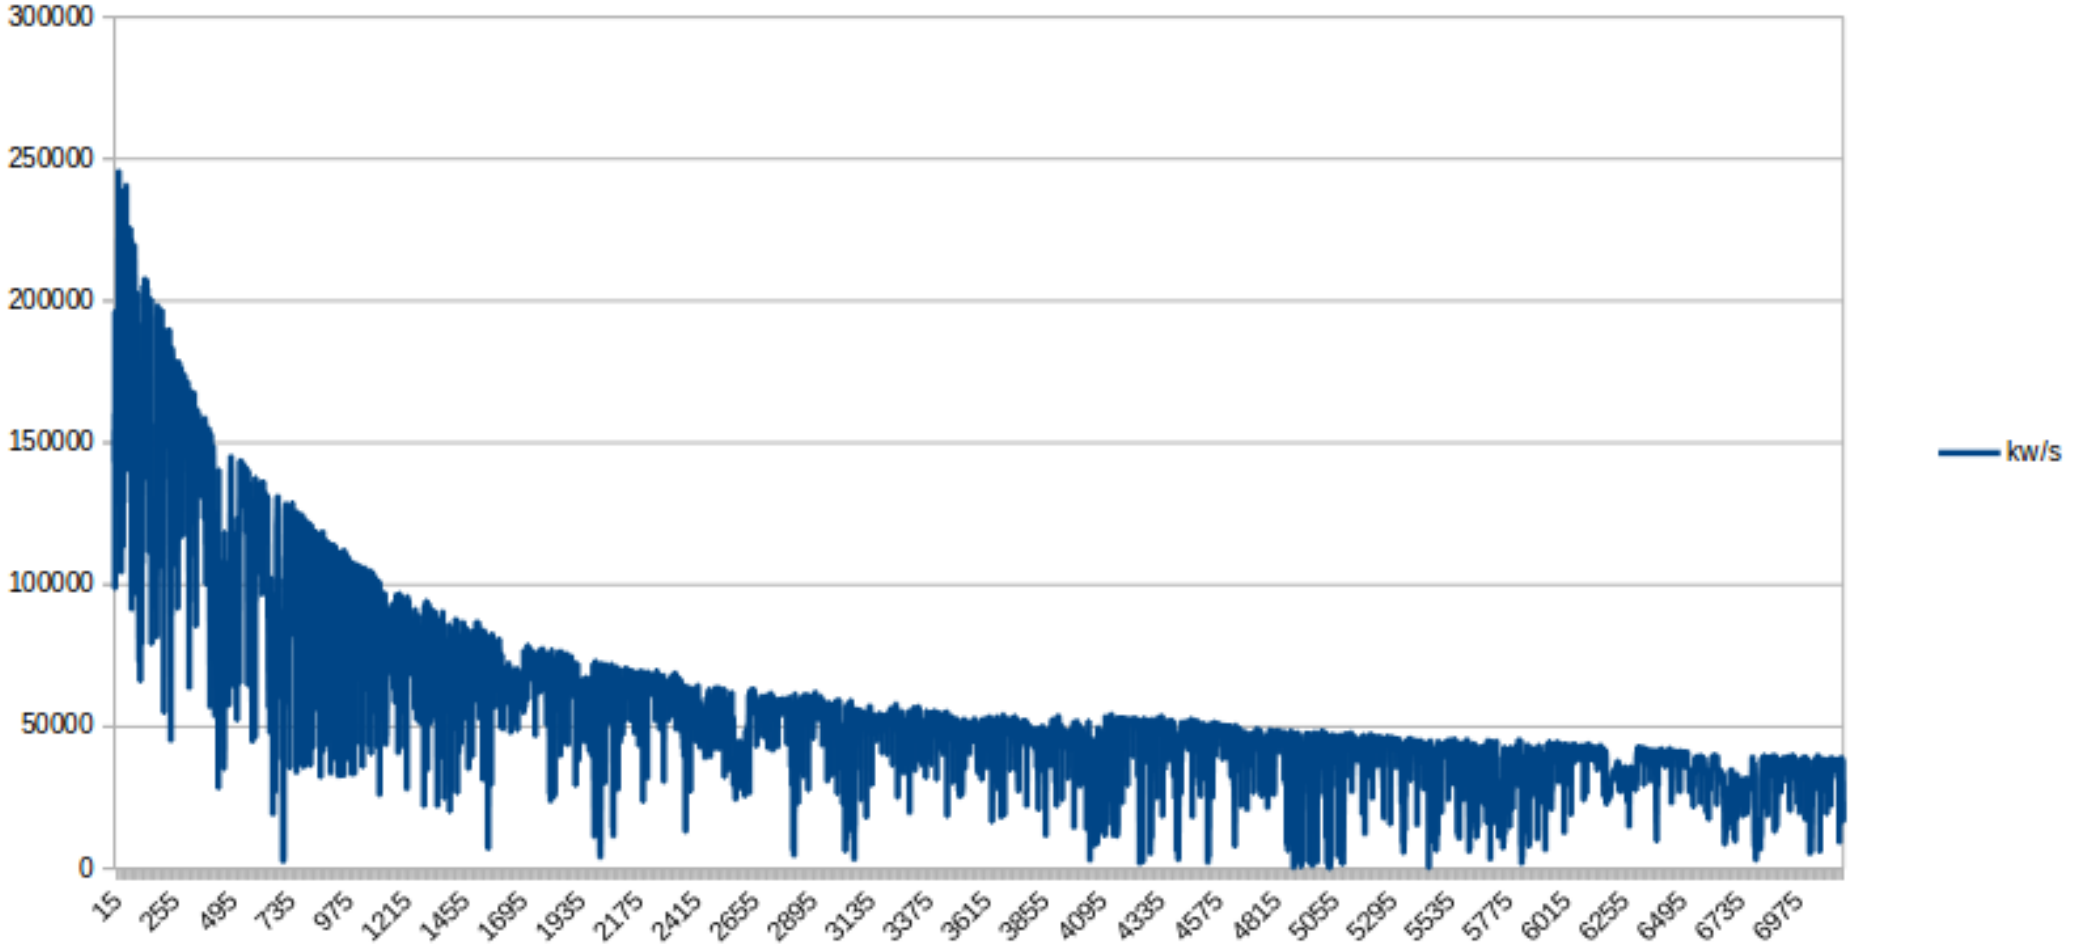

Showcase „Bacula Enterprise Backup“

- weiteres Vorgehen mit DTrace
  - hotspot sampling der Anwendung bzgl. Zahl der Aufrufe, CPU Zeit und zeitlichem Verlauf

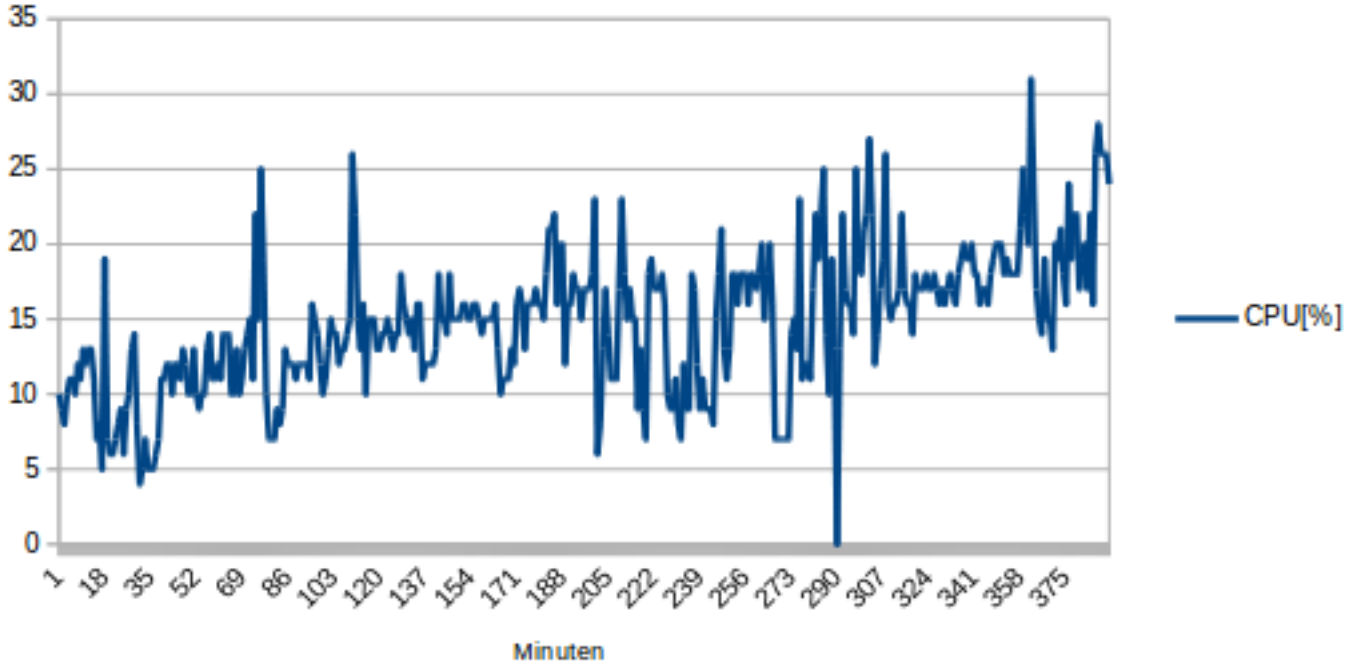

  - eine Funktion benötigt nach 6 Stunden Laufzeit bereits ca. die doppelte CPU Zeit wie zu Beginn

Showcase „Bacula Enterprise Backup“

- call-stack Analyse um Code Pfad zu finden und Übergabe an die Entwickler
- Vermutung eines schlecht skalierenden Algorithmus lies sich mit einfachem workaround verifizieren
- Patch liefert innerhalb weniger Tage knapp 4x an Verbesserung hinsichtlich der Laufzeit

Literatur

- hervorragende Informationsquelle*:* das DTrace Manual

  http://docs.oracle.com/cd/E26502_01/pdf/E28556.pdf

Danke für's Zuhören und denkt daran ...

„... use DTrace ...“

Source: http://www.jedipedia.de/wiki/Telepathie, © LucasFile