ulm university universität ulm

DTrace für Alle
Performance-Analyse für Entwickler und SysAdmins

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

kiz, Kommunikations- und Informationszentrum

- Die Aufgaben der "Abteilung Infrastruktur" umfassen
  - Cluster basierende universitätsweite Mail-, LDAP-, Portal-, Datenbank- und File-Services
  - Betreuung von ca. 600 Desktop und Laptop Arbeitsplätzen
    - 25% Linux, 75% Windows
  - Backup Service für die Universitäten Konstanz und Ulm
  - HPC Cluster für die Universitäten in Konstanz, Stuttgart und Ulm
  - 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
  - Ausbildung von 6 Azubis

Tools: *truss(1)*

- *truss(1)* ist nicht dynamisch was eine Analyse vorübergehender oder kurzlebiger Probleme erschwert oder unmöglich macht
- die Anwendung wird beeinflusst
  - stoppt die Anwendung um die notwendigen Daten zu sammeln bevor der Prozess fortgesetzt wird
- die Auswertung zusammenhängender Prozesse wie etwa einer Login-Session ist nahezu unmöglich
- die Grenze zum Kernel kann nicht überschritten werden

Tools: *prstat(1m)*

- liefert Informationen über laufende Prozesse und deren Threads im Hinblick auf CPU Zeiten, Latenz Zeiten, context-switches, ...
  - falls Anwendungsprobleme vermutet werden ist *prstat(1m)* ein sehr guter Ausgangspunkt für weitere Untersuchungen

```
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

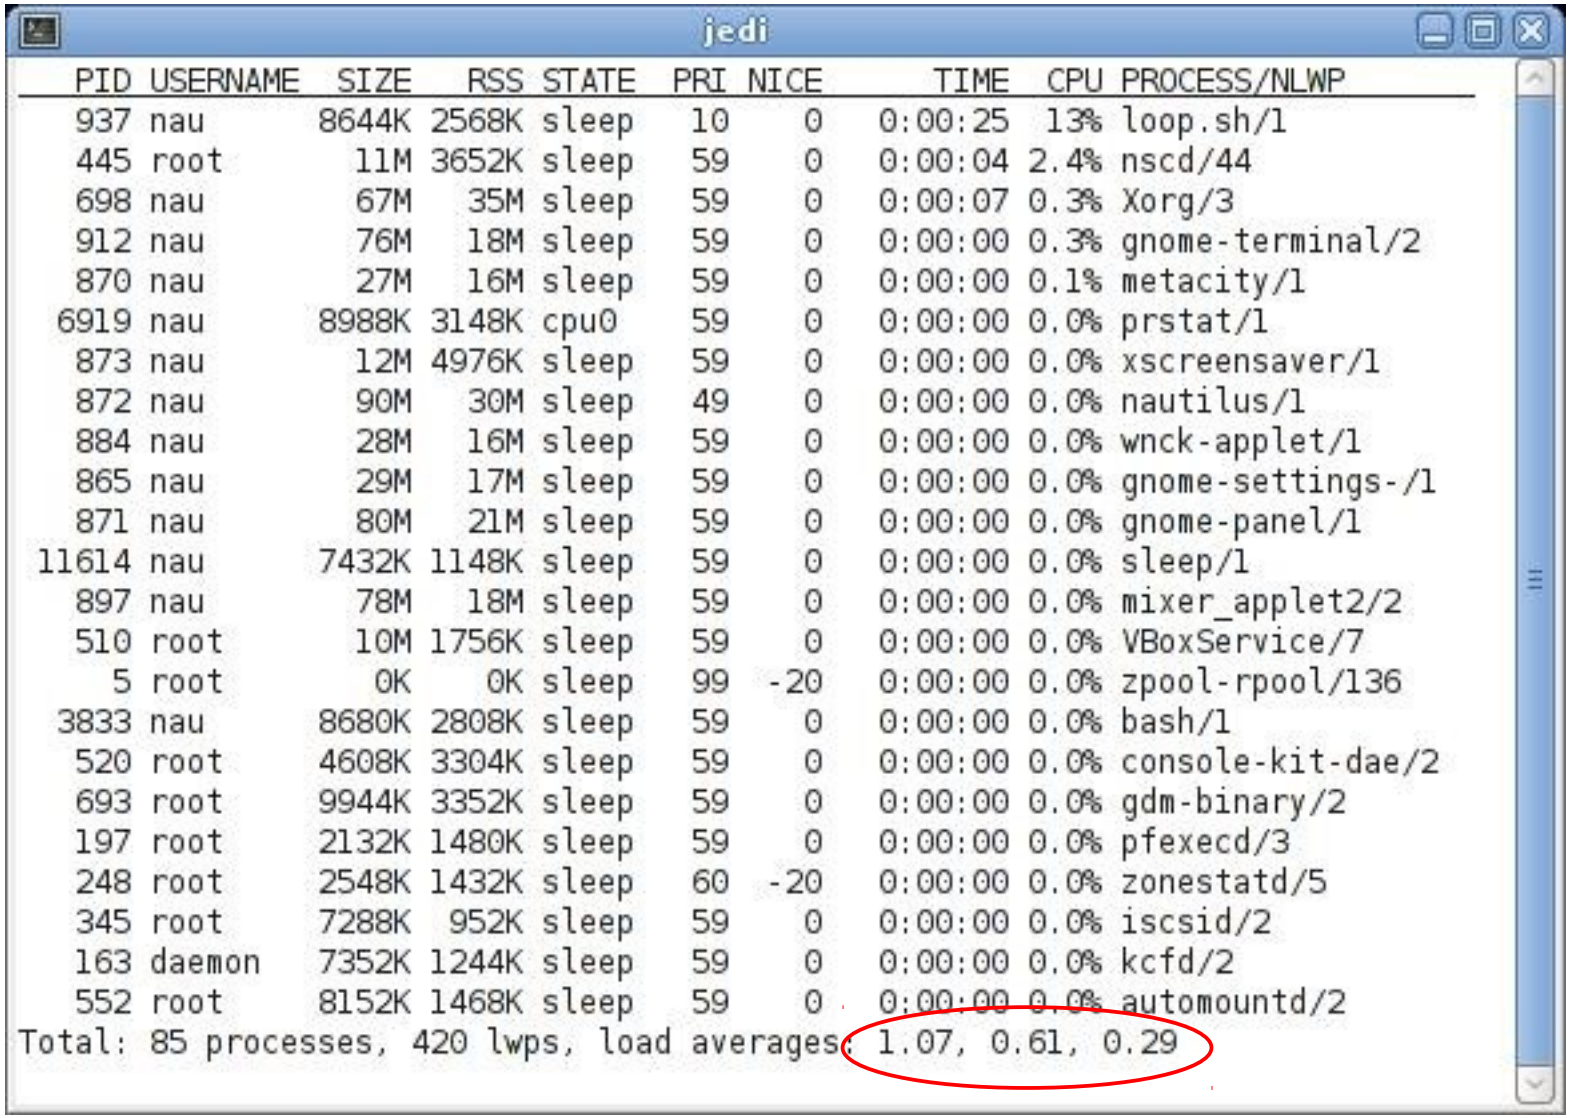

Tools: *vmstat(1m)*

- liefert statistische Daten über Kernel Threads, Platten IO, CPU Last, virtuellen Speicher und traps
- eines der nützlichsten Tools da es Anhaltspunkte liefert 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
```

Wie kommt man weiter, wenn die beschriebenen Tools nicht gut genug sind?

DTrace, die "Dynamic Tracing Facility"

- gibt uns die Möglichkeit dynamisch und effizient Kernel-, Bibliotheks- und Anwendungs-Code zu instrumentieren
- abhängig vom System und den geladenen Modulen stehen derzeit über 90.000 „Probes“ zur Verfügung die sich beliebig und effizient ein- bzw. ausschalten lassen
- DTrace ist durch die "C" ähnliche Sprache "D" skriptfähig
  - wird im Kernel Kontext ausgeführt und beinhaltet daher aus Sicherheitsgründen keine Schleifen-Konstrukte (for, while, ...)
- immer mehr Solaris Tools verwenden DTrace

DTrace Block Schaubild

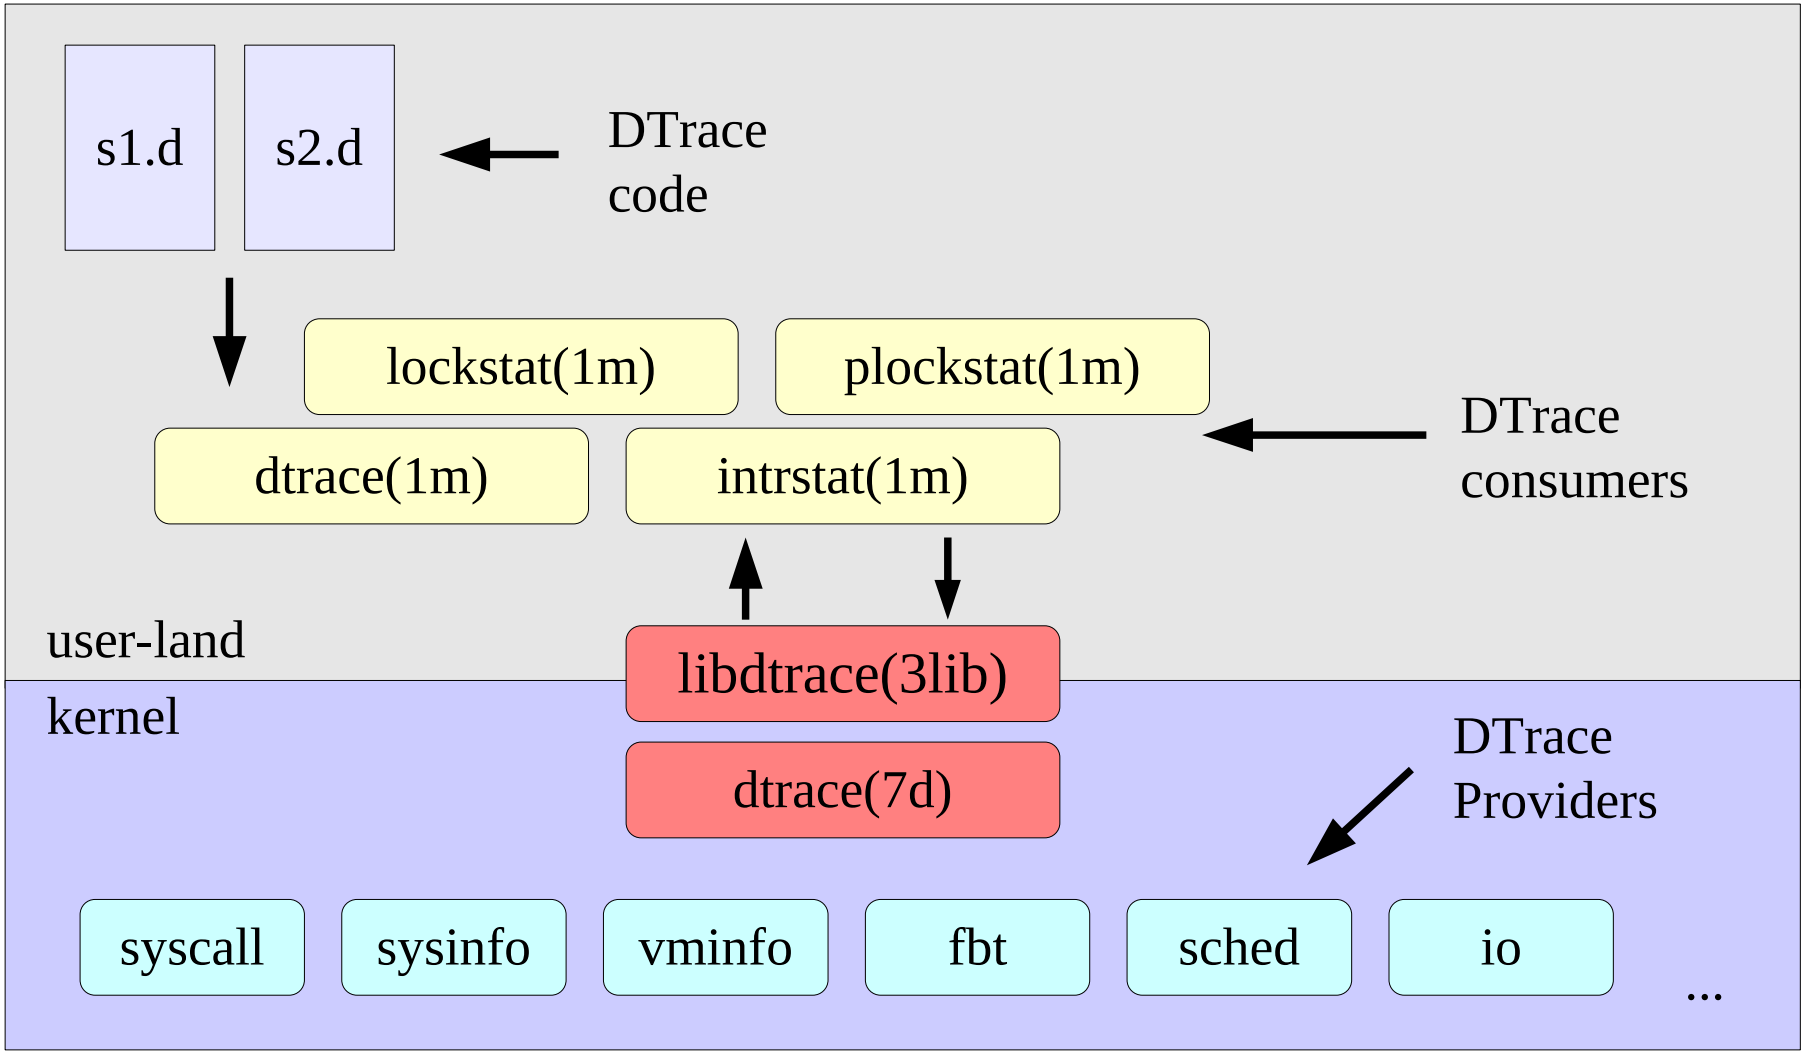

Provider

- stellen sogenannte Probes zur Verfügung
- decken spezifische Bereiche ab und bereiten Daten auf
  - proc:
    Liefert Informationen über Prozesse und Threads
  - syscall:
    Probes für alle Ein- und Austrittspunkte der Solaris system-calls
  - io:
    Disk-IO bezogene Probes
  - fbt (function boundary tracing):
    Probes für die meisten Solaris Kernel Funktionen
- neue Provider und Probes werden auch im Rahmen von Updates bereitgestellt

Probes

- sind Triggerpunkte im Kernel oder in Anwendungen die vielfältige Aktionen auslösen können
  - Aufzeichnung oder Ausgabe von Kernel- oder User-Stacks
  - Ausgabe 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(arg0));
}'
```

```
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 in eigene Anwendungen integrierbar

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
  - *printa()* arbeitet analog zu *prinf()* mit "aggregations"
  - 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 Datumsstring
- *stack(), ustack()*
- *tracemem()*

DTrace's Warp Antrieb: Aggregations

- Aggregations nutzen eine besondere mathematische Eigenschaft bestimmter Funktionen aus
  - die Anwendung der Funktion auf Teilmengen der Daten und anschließend auf die Zwischenergebnisse liefert das identische Ergebnis wie die Anwendung auf die Gesamtmenge
  - count(), min(), max(), avg(), quantize(), lquantize()
- helfen den Speicherbedarf gering zu halten
  - es besteht keine Notwendigkeit alle Daten zwischenzuspeichern
  - Probleme mit der Skalierung werden vermieden
- der Index von Aggregations ist nahezu beliebig, etwa *ustack()* und *stack()* oder *execname, pid, ...*

SUM Aggregation

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

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

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

...

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

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

Beispiel: *write()* Timing

```
#!/usr/sbin/dtrace -s
#pragma D option quiet

    /* don't care about writev() */
syscall::write:entry
{ self->ts = timestamp; }

syscall::write:return
/ self->ts /
{
    @time[execname] = quantize(timestamp - self->ts);
    self->ts = 0;
}

tick-$1
{ exit(0); }
```

2^n Verteilung

Beispiel: *write()* Timing

```
obi-wan# ./write_timing.d 10sec

...
  imapd
           value  ------- Distribution ---- count
            1024 |                         0
            2048 |@                        25
            4096 |@@@@@                    97
            8192 |@@@@@@@@@@@@@@@          291
           16384 |@@@@@@@@@@@@             219
           32768 |@@@@@                    95
           65536 |                         5
          131072 |@                        20
          262144 |                         8
          524288 |                         0
  ...
```

Solaris 11: IP Provider Probes

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

- der nur in Solaris 11 verfügbare IP Provider verwendet für die Datenübergabe 6 Zeiger auf die folgenden Strukturen:

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

  http://wikis.sun.com/display/DTrace/ip+Provider

- gut geeignet für IP basierte File-oder Storage Server

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

#pragma D option quiet

ip:::send
{
    @c[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: Netzverkehr einzelner Clients

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

#pragma D option quiet

dtrace:::BEGIN {
    ts = timestamp;
}

ip:::send {
    @[args[2]->ip_daddr, probename] =
        sum(args[2]->ip_plength);
}

ip:::receive {
    @[args[2]->ip_saddr, probename] =
        sum(args[2]->ip_plength);
}
```

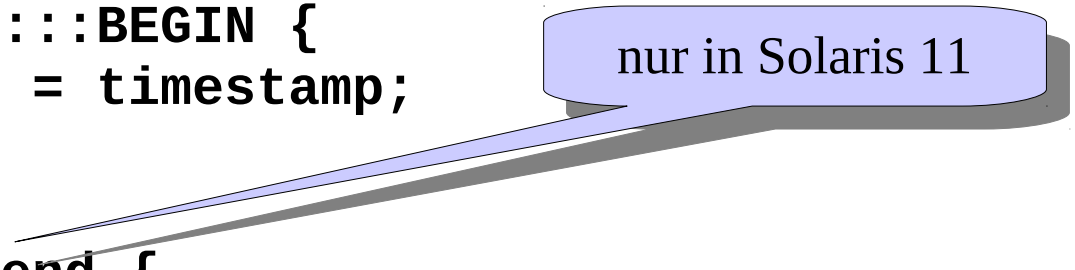

Beispiel: Netzverkehr einzelner Clients

```
/*
 * print top-n
 * normalized to bytes per second
 */
tick-$1 {
    trunc(@, $2);
    normalize(@,(timestamp-ts) / 1000000000);
    printf("\n%Y\n", walltimestamp);
    printa("%-15s %-10s %@15d\n", @);
    ts = timestamp;
    trunc(@);              /* start from scratch */
}
```

Beispiel: Netzverkehr einzelner Clients

```
obi-wan# ./ip_top.d 2s 5

2009 Jun  4 16:35:36
134.60.84.144   receive                34276
134.60.84.170   receive                49792
134.60.215.64   receive                54448
134.60.1.50     receive               301724
134.60.40.100   receive              1304200

2009 Jun  4 16:35:38
134.60.84.131   send                  101752
134.60.84.170   receive               124928
134.60.84.170   send                  303596
134.60.1.50     receive               408576
134.60.2.117    receive               580712
^C
```

Der *pid* Provider

- der *pid* Provider erlaubt die Verfolgung von Funktion oder Instruktionen einer Anwendung inkl. gelinkter Bibliotheken
  - Einschränkung: inlining durch den Compiler
- einzelne Befehle werden als Offset in Bytes bezogen auf den Anfang der Funktion angegeben

pid54321:my-object:my-function:8

pid54321:libc.so.1:strcpy:entry
pid54321:libc.so:strcpy:entry
pid54321:libc:strcpy:entry

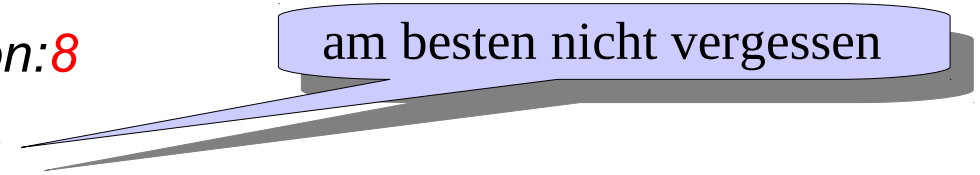

- die Probes werden erst bei Bedarf generiert und tauchen daher bei der Ausgabe von "*dtrace -l*" nicht auf
- Tipp: Kommandozeilen Optionen "-p" und "-c"

Beispiel: Aufruf-Stacks

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

/* uses the 'pid' Provider to print call stacks */

#pragma D option quiet

pid$target:$1:$2:entry
{
    printf("%s:%s:%s", probeprov, probemod, probefunc);
    ustack();
}
```

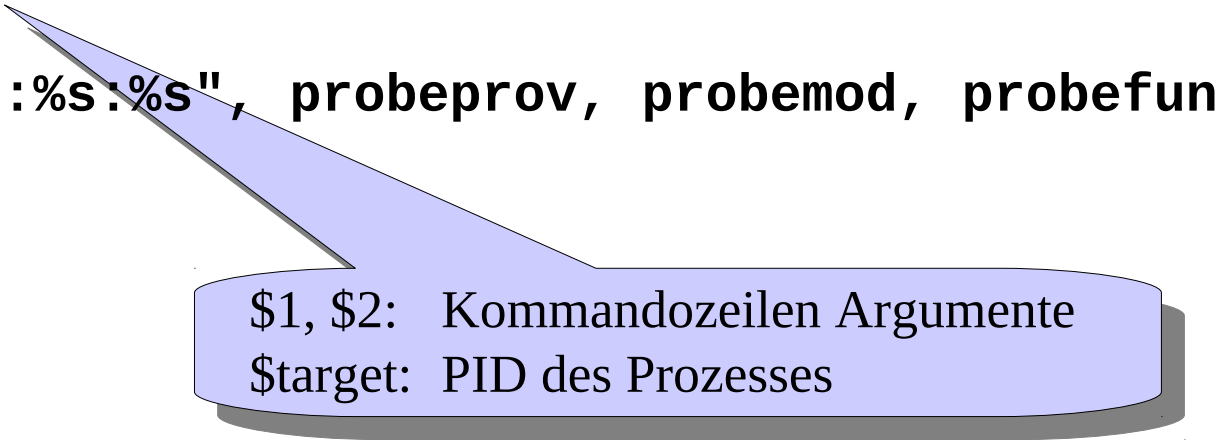

Beispiel: Aufruf-Stacks

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

lib_call_stack.d

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
```

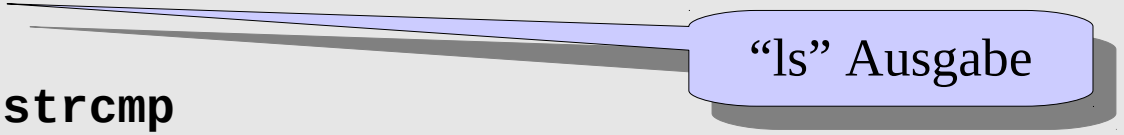

Beispiel: libc Trace

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

/* uses the 'pid' Provider to trace libc functions */

pid$target:libc.so::entry,
pid$target:libc.so::return
{
    /* use "automatic printing" feature */
}
```

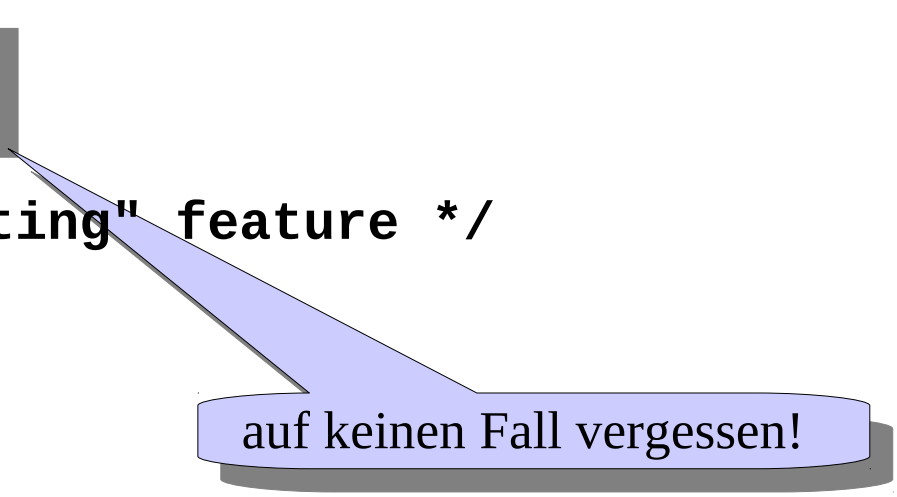

Beispiel: libc Trace

```
obi-wan# ./libc_trace.d  -F -c date
```

```
dtrace: script './libc_trace.d' matched 5789 Probes
Mon Nov  3 16:31:17 MET 2008
dtrace: pid 16648 has exited
CPU FUNCTION
  5  -> __tls_static_mods
  5    -> lmalloc
  5      -> getbucketnum
  5      <- getbucketnum
  5      -> initial_allocation
  5        -> __systemcall
  5        <- __systemcall
  5      <- initial_allocation
  5    <- lmalloc
...
```

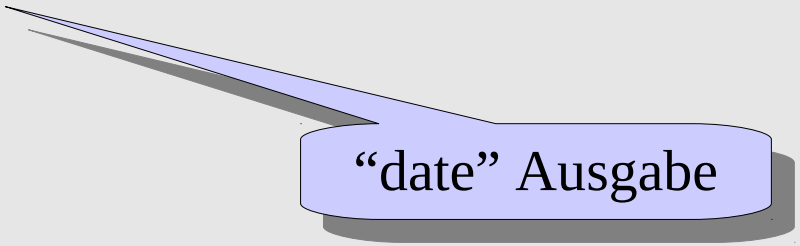

Der *proc* Provider

- der *proc* Provider implementiert Probes die in Zusammenhang mit folgenden Aktivitäten stehen:
  - Erzeugung oder Beendigung von Prozessen
  - Erzeugung oder Beendigung von Threads
  - *exec(2), fork(2)*
  - Signale

Pimp my DTrace: *proc* provider plus Graphviz

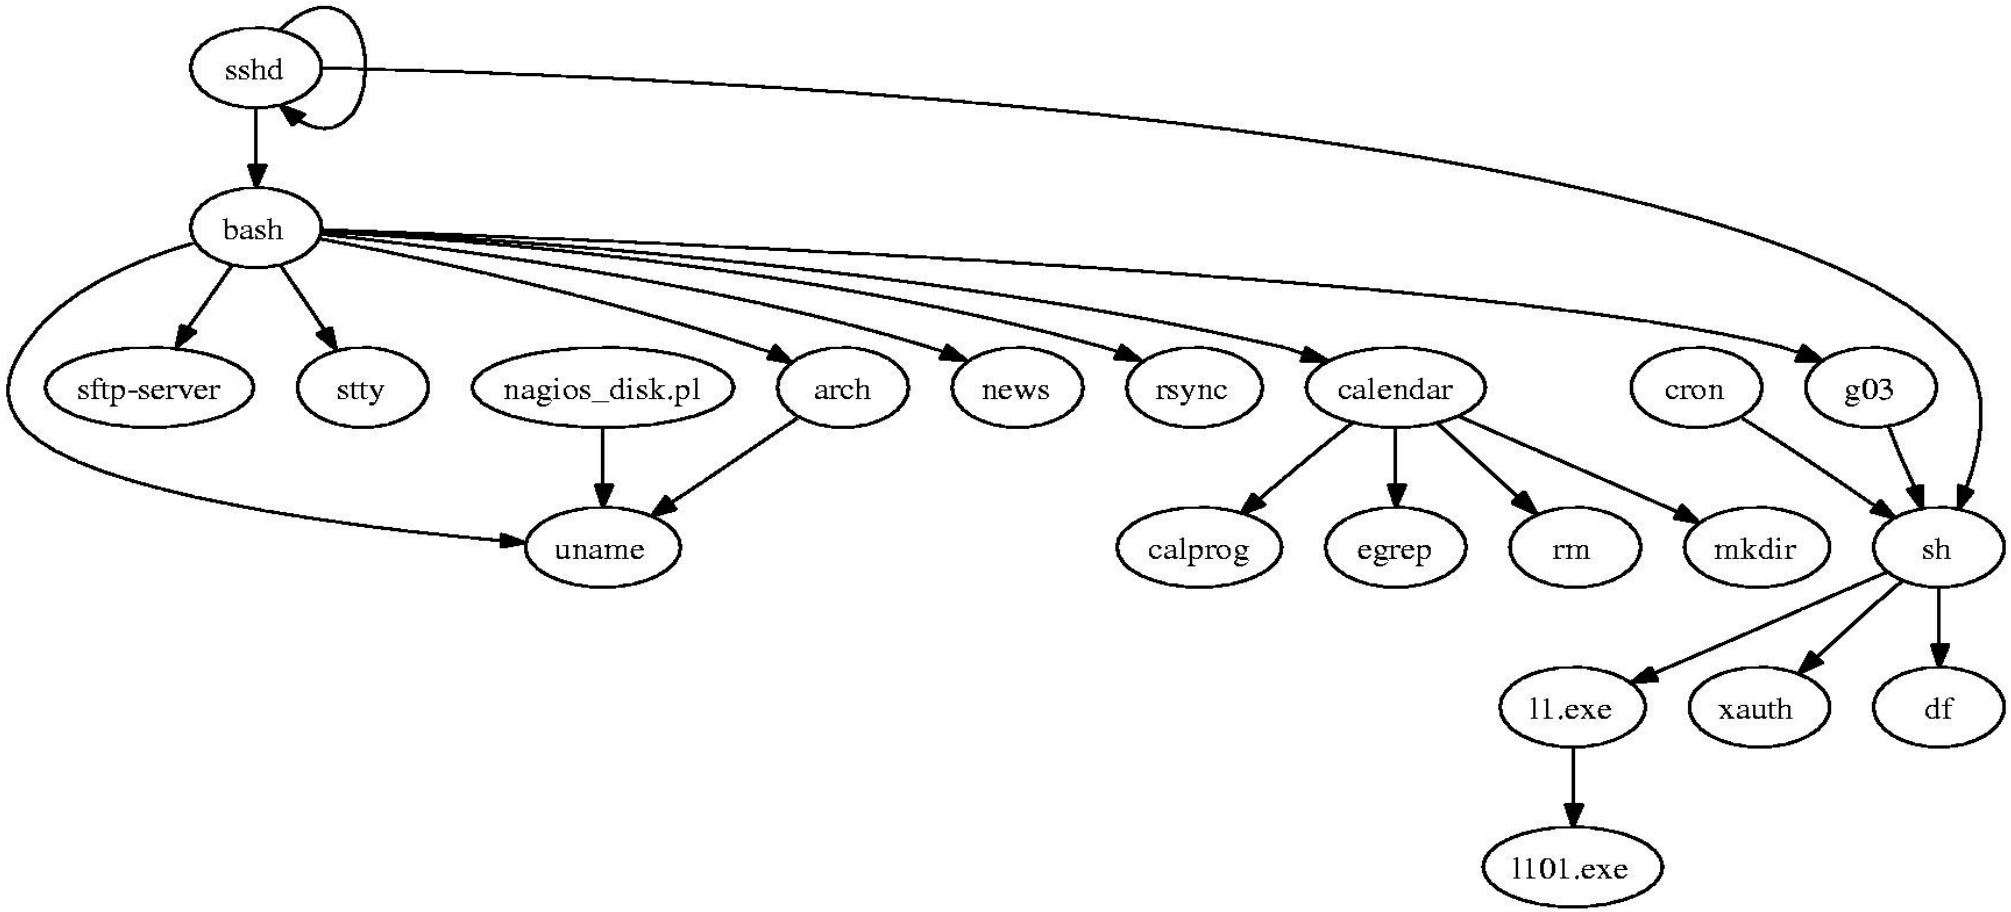

Literatur

- hervorragende Informationsquelle zumal auch alle neuen und nur in Solaris 11 verfügbaren Provider dokumentiert sind

  http://wikis.sun.com/display/DTrace

- das DTrace Manual (PDF)

  http://docs.sun.com

- Beispiele finden sich unter

  http://wikis.sun.com/display/DTrace

  http://www.brendangregg.com/dtrace.html

  http://www.opensolaris.org

  /usr/demo/dtrace

Danke und nicht vergessen ...


Use The
Tools!
©LucasFilm

Anhang:
Aus dem wahren Leben

Beispiel: Active Directory Controller

- wir verwendeten xVM (Xen) um auf Basis von Solaris Windows Server 2008 zu virtualisieren
- Platten IO ist auf Grund der para-virtualisierten Treiber im Allgemeinen sehr gut
- Problem: nachdem ein performantes System die Funktion eines AD Controllers übernahm brach die Leistung massiv ein

Beispiel: Active Directory Controller

- "vmstat 5" liefert Hinweise auf eine hohe system-call Rate
- "prstat -Lm" zeigt welcher Prozess es ist

```
PID   NAME USR SYS TRP TFL DFL LCK SLP LAT VCX ICX SCL SIG PROC/NLWP
------------------------------------------------------------------
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
...
```

Beispiel: Active Directory Controller

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

/* get some statistic about system call rates */

#pragma D option quiet

BEGIN {
        timer = timestamp;      /* nanosecond timestamp */
}
syscall:::entry {
        @c[pid, execname, probefunc] = count();
}
tick-5s {
        trunc(@c, 10);
        normalize(@c, (timestamp-timer) /1000000000);
        printa("%5d %-20s %6@d %s\n", @c);
        clear(@c);
        printf("\n");
        timer = timestamp;
}
```

Beispiel: Active Directory Controller

```
leto# ./count_syscalls.d


  209 nscd                                   27 xstat
16376 prstat                                 35 pread
16480 qemu-dm                               117 pollsys
16480 qemu-dm                               123 read
16480 qemu-dm                               136 ioctl
11705 qemu-dm                               145 pollsys
 1644 qemu-dm                               151 pollsys
16374 dtrace                                331 ioctl
16480 qemu-dm                             35512 lseek
16480 qemu-dm                             35607 write
```

Beispiel: Active Directory Controller

```
leto# ./seek-write-stat.d

  lseek fdesc       delta       count
              5          26          28
              5          29          28
              5           0          42
              5          21          42
              5           1      134540
 write fdesc        size       count
              5          21          42
             15           4          54
             16           4          63
             14           4         441
              5           1      134554
```

Beispiel: Active Directory Controller

- Überprüfung von file-descriptor #5 mit Hilfe von *pfiles(1)* liefert Hinweise darauf, das es sich um Zugriffe auf die virtuelle Platte handeln muss

```
leto# pfiles 16480


...
   5: S_IFREG mode:0600 dev:182,65543 ino:26 uid:60
gid:0 size:11623923712
      O_RDWR|O_LARGEFILE
      /xvm/hermia/disk_c/vdisk.vmdk
...
```

Beispiel: Active Directory Controller

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

/* print call stack statistics for "qemu-dm"
 * for the lseek() and write() system calls
 */

#pragma D option quiet

syscall::lseek:entry, syscall::write:entry
/ execname == "qemu-dm" /
{
        @c[probefunc, ustack()] = count();
}

tick-5s {
        trunc(@c, 3);
        printa(@c);
        clear(@c);
}
```

Beispiel: Active Directory Controller

```
...
  write
              libc.so.1`__write+0xa
              qemu-dm`RTFileWrite+0x37
              qemu-dm`RTFileWriteAt+0x48
              qemu-dm`vmdkWriteDescriptor+0x1d5
              qemu-dm`vmdkFlushImage+0x23
              qemu-dm`vmdkFlush+0x9
              qemu-dm`VDFlush+0x91
              qemu-dm`vdisk_flush+0x1c
              qemu-dm`bdrv_flush+0x2e
              qemu-dm`ide_write_dma_cb+0x187
              qemu-dm`bdrv_aio_bh_cb+0x16
              qemu-dm`qemu_bh_poll+0x2d
              qemu-dm`main_loop_wait+0x22c
              qemu-dm`main_loop+0x7a
              qemu-dm`main+0x1886
              qemu-dm`_start+0x6c
             28758
```

Beispiel: Active Directory Controller

- auf Grund des call-stacks liegt die Vermutung nahe, dass Windows den Platten Cache leert oder deaktiviert hat
- letzteres war der Fall
- eine Aktivierung in einem Windows Start-Skript beseitigt die IO Probleme
  - über eine Quantisierung der Datenmenge bei Schreibzugriffen lässt sich dies mit DTrace verifizieren

Beispiel: Active Directory Controller

```
leto# ./qemu-stat-quant.d 5
```

```
  write
  value  ------------- Distribution ------------- count
    256 |                                         0
    512 |@@@@@@                                   14
   1024 |                                         0
   2048 |@@@@                                     10
   4096 |@@@@@@@@@@@@@@@@                         39
   8192 |@@@@@@@@@@@@@@@                          36
  16384 |                                         0
```