science + computing
A Bull Group Company

Linux-Versteher dank Strace

Fun with strace
understand what Linux does with you(r PC)

Harald König

science + computing ag
IT-Dienstleistungen und Software für anspruchsvolle Rechnernetze
Tübingen | München | Berlin | Düsseldorf

Agenda I

science + computing
A Bull Group Company

1. s+c and me

2. Let's use `strace`
   - Erste Schritte
   - Ausgabe von `strace` einschränken
   - Mehrere Prozesse und Kind-Prozesse tracen
   - Time-Stamps und Performance-Betrachtungen
   - Warum bricht denn XY ab, welche Dateien sind relevant?
   - Welche Login-Skripte wurden ausgeführt
   - Noch mehr Daten sehen

Agenda II

science + computing
A Bull Group Company

3. Probleme
   - `strace` stört den Prozess-Ablauf
   - `ptrace()` ist nicht kaskadierbar
   - SUID-Programme tracen
   - Für alle Benutzer lesbarer Output von `strace`
   - Dead-Locks
4. SEE ALSO
5. Conclusion

science + computing ag (s+c)

science + computing
A Bull Group Company

Gegründet	1989
Büros	Tübingen München Berlin Düsseldorf
Mitarbeiter	270
Besitzer	Bull S.A. (100 %) seit 10/2008
Jahresumsatz	26 Mio. Euro (07/08)

S+C

science + computing
A Bull Group Company

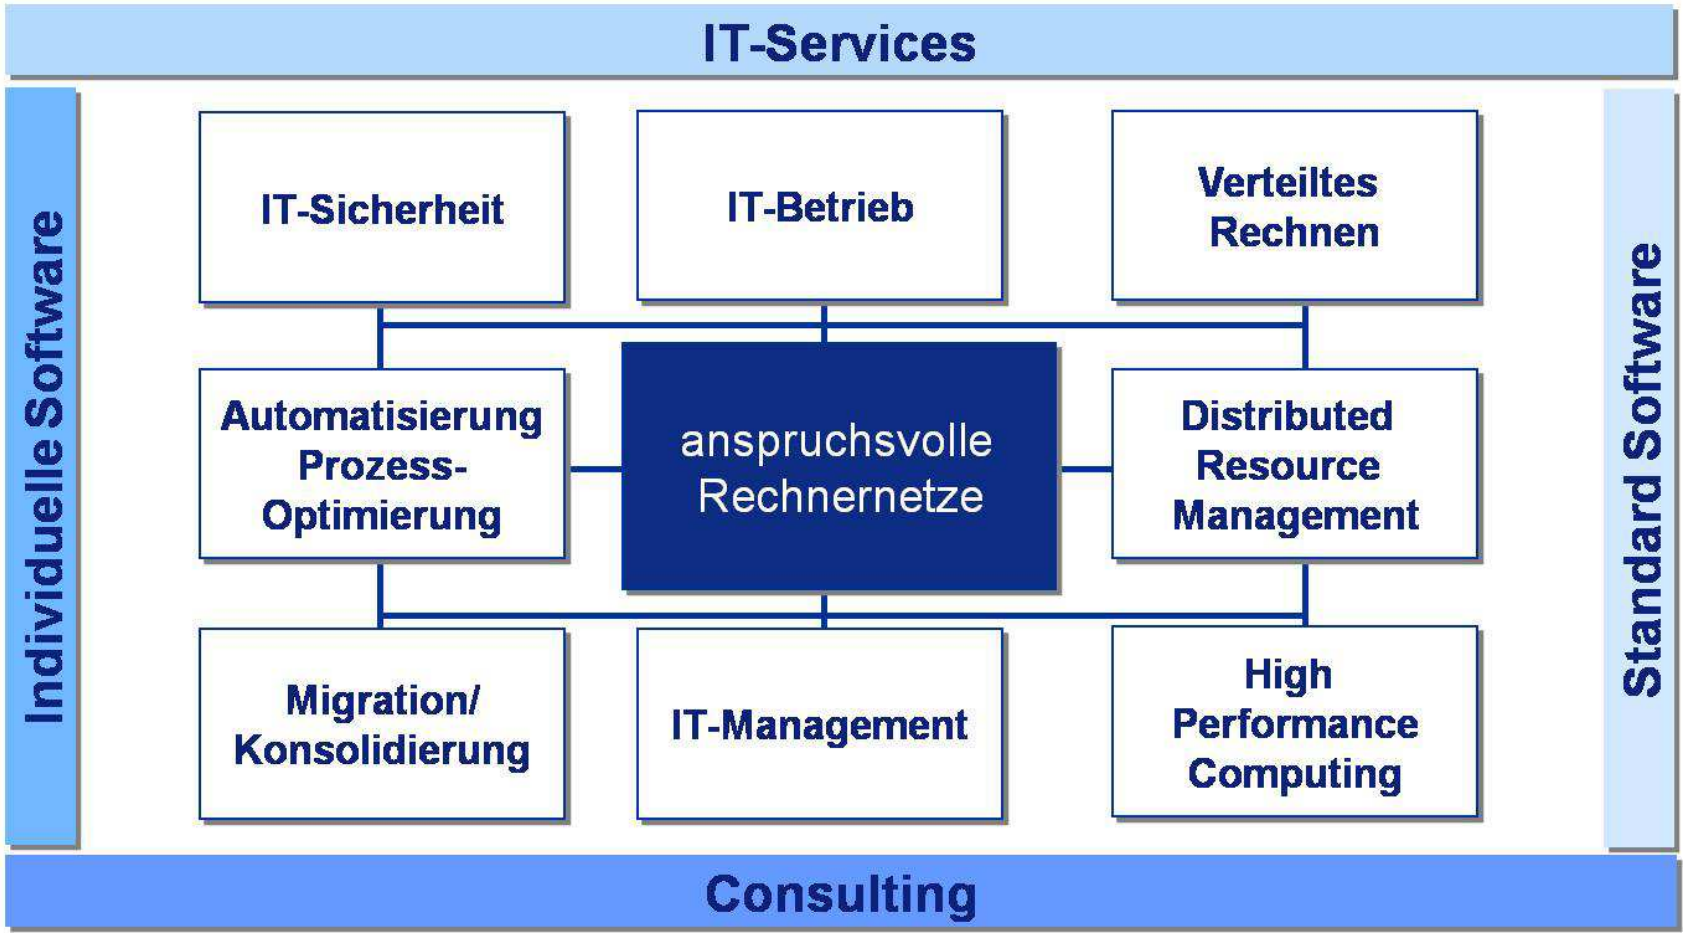

S+C

science + computing
A Bull Group Company

- Automobilindustrie
- Anlagen- und Maschinenbau
- Luft- und Raumfahrt
- Mikroelektronik
- Chemie / Pharma
- Biotechnologie
- Öffentlicher Dienst

Me

science + computing
A Bull Group Company

- OpenSource in der Schule (CBM-3032)
- TEX ab 1986 an der Uni
- VMS (1985) und UNX (1987) an der Uni
- Nie wieder INTEL (1989/90)
- Linux 0.98.4 (1992, doch wieder Intel:-(
- XFree86 (S3, 1993-2001)
- science + computing ag in Tübingen seit 2001
- ...

Let's use `strace`

science + computing
A Bull Group Company

- Datei-Zugriffe
- Programm-Aufrufe
- Datenfluß, Replay
- time stamps und kernel delay
- Statistik

Man Pages

science + computing
A Bull Group Company

- `man strace`
- `man gdb`
- `man ptrace`
- `man ltrace`

Erste Schritte

science + computing
A Bull Group Company

```
$ strace emacs
$ strace $( pgrep httpd | sed 's/^/-p/' )
$ strace emacs 2> OUTFILE
$ strace -o OUTFILE emacs
$ strace -e open   cat /etc/HOSTNAME
$ strace -e file   cat /etc/HOSTNAME
....
```

Alles weitere in den Proceedings bzw. im `xterm`...

Linux-Versteher dank `strace`

Harald König
science + computing ag
Hagellocher Weg 73
72070 Tübingen
Deutschland
<H.Koenig@science-computing.de>
<koenig@linux.de>

1 Abstract

`strace` ist ein wahres Wundertool in Linux, man muss es nur einsetzen – und kann damit sehr viel über die Abläufe und Interna von Linux lernen (bzw. `truss` in Solaris und AIX, `tusc` in HP-UX usw.). Mit `strace` können einzelne oder mehrere Prozesse zur Laufzeit auf System-Call-Ebene „beobachtet“ werden. Damit lassen sich bei vielen Problemen sehr einfach wertvolle Informationen zum Debuggen gewinnen: welche Config-Dateien wurden wirklich gelesen, welches war die letzte Datei oder Shared-Library vor dem Crash usw. Im Unterschied zu interaktiven Debuggern läuft das zu testende Programm mit `strace` mehr oder weniger in Echtzeit ab, und man erhält schon während des Programm-Laufs jede Menge Ausgaben zu allen erfolgten Kernel-Calls, so dass man den Ablauf des Prozesses „live“ mitverfolgen bzw. den abgespeicherten Output nachträglich bequem auswerten kann.

Auch bei Performance-Problemen kann man mit `strace` interessante Informationen gewinnen: wie oft wird ein Syscall ausgeführt, wie lange dauern diese, wie lange „rechnet“ das Programm selbst zwischen den Kernel-Calls. Man kann auch den kompletten I/O eines Programms (Disk oder Net) mit `strace` recht elegant mitprotokollieren und später offline analysieren (oder auch „replay“en, bei Bedarf sogar in „Echtzeit“ Dank präziser Time-Stamps).

Der Vortrag soll anregen, rätselhafte UNIX-Effekte, -Probleme, Programm-Crashes neu mit `strace` zu betrachten und damit hoffentlich (schneller) zu Lösungen und neuen Erkenntnissen zu gelangen.

2 Let's use `strace`

`strace` kennt viele Optionen und Varianten. Hier können nur die in meinen Augen wichtigsten angesprochen und gezeigt werden – die Man-Page (RTFM: `man strace`) birgt noch viele weitere Informationsquellen und Hilfen.

2.1 Erste Schritte

Je nachdem, was man untersuchen will, kann man (genau wie mit Debuggern wie `gdb`) ein Kommando entweder mit `strace` neu starten, oder aber man kann sich an einen bereits laufenden Prozess anhängen und diesen analysieren:

```
$ strace emacs
```

bzw. für einen schon laufenden `emacs`

```
$ strace -p $( pgrep emacs )
```

und wenn es mehrere Prozesse gleichzeitig zu tracen gibt (z.B. alle Instanzen des Apache `httpd`):

```
$ strace $( pgrep httpd | sed 's/^/-p/' )
```

Das an einen Prozess angehängte `strace -p ...` kann man jederzeit mit `CTRL-C` beenden, das untersuchte Programm läuft dann normal und ungebremst weiter. Wurde das zu testende Programm durch `strace` gestartet, dann wird durch `CTRL-C` nicht nur `strace` abgebrochen, sondern auch das gestartete Programm beendet.

`strace` gibt seinen gesamten Output auf `stderr` aus, man kann jedoch den Output auch in eine Datei schreiben bzw. die Ausgabe umleiten, dann jedoch inklusive dem `stderr`-Outputs des Prozesses (hier: emacs) selbst:

```
$ strace -o OUTFILE emacs
$ strace emacs 2> OUTFILE
```

Üblicherweise wird jeweils eine Zeilepro System-Call ausgegeben. Diese Zeile enthält den Namen der Kernel-Routine und deren Parameter, sowie den Rückgabewert des Calls. Der Output von `strace` ist sehr `C`-ähnlich, was nicht sehr wundern dürfte, da das Kernel-API von Linux/UNIX ja als ANSI-C-Schnittstelle definiert ist (meist didaktisch sinnvoll gekürzte Ausgabe):

```
$ strace cat /etc/HOSTNAME
execve("/bin/cat", ["cat", "/etc/HOSTNAME"], [/* 132 vars */]) = 0
open("/etc/HOSTNAME", O_RDONLY)         = 3
read(3, "harald.science-computing.de\n", 32768) = 28
write(1, "harald.science-computing.de\n", 28) = 28
read(3, "", 32768)                      = 0
close(3)                                = 0
close(1)                                = 0
close(2)                                = 0
exit_group(0)                           = ?
```

Selbst ohne `C`-Programmierkenntnisse lässt sich diese Ausgabe verstehen und vernünftig interpretieren. Details zu den einzelnen Calls kann man in den entsprechenden Man-Pages nachlesen, denn alle System-Calls sind dokumentiert in Man-Pages (`man execve ; man 2 open ; man 2 read write` usw.). Nur aus der Definition des jeweiligen Calls ergibt sich, ob die Werte der Argumente vom Prozess an den Kernel übergeben, oder aber vom Kernel an den Prozess zurückgegeben werden (bspw. den String-Wert als zweites Argument von `read()` und `write()` oben).

Für einige System-Calls (z.B. `stat()` und `execve()`) erzeugt `strace` mit der Option `-v` eine „verbose“ Ausgabe mit mehr Inhalt. Auf der Suche nach mehr Informationen (`stat()`-Details von Dateien, oder komplettes Environment beim execve()) kann dies oft weiterhelfen.

```
$ strace -e execve cat /etc/HOSTNAME
execve("/bin/cat", ["cat", "/etc/HOSTNAME"], [/* 132 vars */]) = 0
harald.science-computing.de
$
$ strace -v -e execve cat /etc/HOSTNAME
execve("/bin/cat", ["cat", "/etc/HOSTNAME"], ["LESSKEY=/etc/lesskey.bin", "MANPATH=/usr/
local/man:/usr/loca"..., "XDG_SESSION_ID=195", "TIME=\\t%E real,\\t%U user,\\t%S sy"...,
 "HOSTNAME=harald", "GNOME2_PATH=/usr/local:/opt/gnom"..., "XKEYSYMDB=/usr/X11R6/lib/X11
/XKe"..., "NX_CLIENT=/usr/local/nx/3.5.0/bi"..., "TERM=xterm", "HOST=harald", "SHELL=/bi
n/bash", "PROFILEREAD=true", "HISTSIZE=5000", "SSH_CLIENT=10.10.8.66 47849 22", "VSCMBOO
T=/usr/local/scheme/.sche"..., "CVSROOT=/soft/.CVS", "GS_LIB=/usr/local/lib/ghostscrip".
.., "TK_LIBRARY=/new/usr/lib/tk4.0", "MORE=-sl", "WINDOWID=14680077", "QTDIR=/usr/lib/qt
3", "JRE_HOME=/usr/lib64/jvm/jre", "USER=harald", "XTERM_SHELL=/bin/bash", "TIMEFORMAT=\
t%R %3lR real,\t%U use"..., "LD_LIBRARY_PATH=/usr/local/nx/3."..., "LS_COLORS=no=00:fi=0
0:di=01;34:l"..., "OPENWINHOME=/usr/openwin", "PILOTPORT=usb:", "XNLSPATH=/usr/share/X11
[ ... 22 lines deleted ...]
rap"..., "_=/usr/bin/strace", "OLDPWD=/usr/local/nx/3.5.0/lib/X"...]) = 0
```

Ein besonderer Modus von `strace` bekommt man mit der Option `-c`. Hier wird nicht mehr jeder einzelne Kernel-Call ausgegeben, sondern nur ganz am Ende eine Statistik über die Anzahl der einzelnen Calls sowie die jeweils verbrauchte CPU-Zeit. Diese Ausgabe mag für einen ersten Überblick bei Performance-Problemen ganz nützlich sein, jedoch erfährt man nur wenige Details über den Programmablauf und sieht den Ablauf des Programms nicht mehr „live“ (für die Kombination von Live-Trace und abschließender Statistik gibt es dann die Option `-C`).

2.2 Ausgabe von `strace` einschränken

Der Output von `strace` kann schnell *sehr* umfangreich werden, und das synchrone Schreiben der Ausgabe auf `strerr` oder auch eine Log-Datei kann erheblich Performance kosten. Wenn man genau weiß, welche System-Calls interessant sind, kann man die Ausgabe auf einen bzw. einige wenige Kernel-Calls beschränken (oder z.B. mit `-e file` alle Calls mit Filenames!). Das verlangsamt den Programmablauf weniger und vereinfacht das spätere Auswerten des `strace`-Outputs erheblich. Allein die Option `-e` bietet sehr viel mehr Möglichkeiten. Hier nur ein paar einfache Beispiele, welche sehr oft ausreichen, alles Weitere dokumentiert die Man-Page:

```
$ strace -e open             cat /etc/HOSTNAME
open("/etc/HOSTNAME", O_RDONLY)         = 3

$ strace -e open,read,write  cat /etc/HOSTNAME
open("/etc/HOSTNAME", O_RDONLY)         = 3
read(3, "harald.science-computing.de\n", 32768) = 28
write(1, "harald.science-computing.de\n", 28harald.science-computing.de
) = 28
read(3, "", 32768)                      = 0

$ strace -e open,read,write  cat /etc/HOSTNAME > /dev/null
open("/etc/HOSTNAME", O_RDONLY)         = 3
read(3, "harald.science-computing.de\n", 32768) = 28
write(1, "harald.science-computing.de\n", 28) = 28
read(3, "", 32768)                      = 0

$ strace -e file             cat /etc/HOSTNAME
execve("/bin/cat", ["cat", "/etc/HOSTNAME"], [/* 132 vars */]) = 0
open("/etc/HOSTNAME", O_RDONLY)         = 3
```

2.3 Mehrere Prozesse und Kind-Prozesse tracen

`strace` kann auch mehrere Prozesse gleichzeitig tracen (mehrere Optionen `-p PID`) bzw. auch alle Kind-Prozesse (Option `-f`) mit verfolgen. In diesen Fällen wird in der Ausgabe am Anfang jeder Zeile die PID des jeweiligen Prozesses ausgegeben. Alternativ kann man die Ausgabe auch in jeweils eigene Dateien je Prozess schreiben lassen (mit Option `-ff`).

Wenn man nicht genau weiß, was man denn eigentlich tracen muss, dann ist die Verwendung von `-f` oder `-ff` angesagt, da man ja nicht ahnen kann, ob evtl. mehrere (Unter-) Prozesse oder Skripte involviert sind. Ohne `-f` oder `-ff` könnten sonst beim Trace wichtige Informationen von weiteren Prozessen entgehen. In meinen einfachen Beispielen mit `emacs` ist dieser selbst auch schon ein Wrapper-Shell-Skript. Hier nun ein paar Varianten als kleine Denksportaufgabe zum Grübeln, wie die `bash` intern so tickt:

```
$ strace -e execve bash -c true
execve("/bin/bash", ["bash", "-c", "true"], [/* 132 vars */]) = 0

$ strace -e execve bash -c /bin/true
execve("/bin/bash", ["bash", "-c", "/bin/true"], [/* 132 vars */]) = 0
execve("/bin/true", ["/bin/true"], [/* 130 vars */]) = 0
```

```
$ strace -e execve bash -c "/bin/true ; /bin/false"
execve("/bin/bash", ["bash", "-c", "/bin/true ; /bin/false"], [/* 132 vars */]) = 0

$ strace -f -e execve bash -c "/bin/true ; /bin/false"
execve("/bin/bash", ["bash", "-c", "/bin/true ; /bin/false"], [/* 132 vars */]) = 0
execve("/bin/true", ["/bin/true"], [/* 130 vars */]) = 0
execve("/bin/false", ["/bin/false"], [/* 130 vars */) = 0

$ strace -o OUTFILE -f -e execve bash -c "/bin/true ; /bin/false" ; grep execve OUTFILE
21694 execve("/bin/bash", ["bash", "-c", "/bin/true ; /bin/false"], [/* 132 vars */]) = 0
21695 execve("/bin/true", ["/bin/true"], [/* 130 vars */]) = 0
21696 execve("/bin/false", ["/bin/false"], [/* 130 vars */]) = 0

$ strace -o OUTFILE -ff -e execve bash -c "/bin/true ; /bin/false" ; grep execve OUTFILE*
OUTFILE.22155:execve("/bin/bash", ["bash", "-c", "/bin/true ; /bin/false"], [/*...*/]) = 0
OUTFILE.22156:execve("/bin/true", ["/bin/true"], [/* 130 vars */]) = 0
OUTFILE.22157:execve("/bin/false", ["/bin/false"], [/* 130 vars */]) = 0
```

2.4 Time-Stamps und Performance-Betrachtungen

Bei Performance-Fragen ist es oft hilfreich, dass jede Ausgabe von `strace` zu einem Kernel-Call mit einem Time-Stamp versehen werden kann. Gibt man die Option `-t` ein-, zwei- oder dreimal an, kann man verschiedene Formate des Zeit-Stempels wählen: HH:MM:SS, HH:MM:SS.Mikrosekunden, sowie die „UNIX-Zeit“ in Sekunden und Mikrosekunden seit 1970 GMT/UTC. Die letzte Form ist für spätere Berechnungen mit den Time-Stamps am einfachsten, die anderen beiden Formen meist leichter lesbar und einfacher mit anderen Time-Stamps z.B. aus `syslog` oder anderen Log-Files abzugleichen, wenn es um die Analyse ganz bestimmter Events geht.

Mit der Option `-r` bekommt man wahlweise auch die Zeit-Differenz zum letzten Kernel-Call in Mikrosekunden (das kann man mit `-ttt` auch später noch selbst ausrechnen und ergänzen). Alle Time-Stamps beziehen sich immer auf den Aufruf des Kernel-Calls (Kernel Entry), man bekommt direkt keinen Time-Stamp vom Zeitpunkt des Rücksprungs vom Kernel zurück in das Programm.

Die Option `-T` fügt am Ende der Ausgabe-Zeile noch in spitzen Klammern die Verweildauer im Kernel an. Nur mit dieser Angabe kann man sich bei Bedarf den absoluten Time-Stamp der Rückkehr aus dem Kernel selbst errechnen, denn bis zum nächsten Kernel-Call könnte viel Zeit im User-Mode verbracht werden, so dass der nächste Kernel-Entry-Time-Stamp nicht immer aussagekräftig ist.

```
$ strace -t    -e open,read,write,close  cat /etc/HOSTNAME > /dev/null
22:22:25 open("/etc/HOSTNAME", O_RDONLY) = 3
22:22:25 read(3, "harald.science-computing.de\n", 32768) = 28
22:22:25 write(1, "harald.science-computing.de\n", 28) = 28
22:22:25 read(3, "", 32768)             = 0
22:22:25 close(3)                       = 0

$ strace -tt   -e open,read,write,close  cat /etc/HOSTNAME > /dev/null
22:22:46.314380 open("/etc/HOSTNAME", O_RDONLY) = 3
22:22:46.314566 read(3, "harald.science-computing.de\n", 32768) = 28
22:22:46.314698 write(1, "harald.science-computing.de\n", 28) = 28
22:22:46.314828 read(3, "", 32768)      = 0
22:22:46.314945 close(3)                = 0

$ strace -ttt  -e open,read,write,close  cat /etc/HOSTNAME > /dev/null
1325971387.860049 open("/etc/HOSTNAME", O_RDONLY) = 3
1325971387.860143 read(3, "harald.science-computing.de\n", 32768) = 28
1325971387.860186 write(1, "harald.science-computing.de\n", 28) = 28
1325971387.860249 read(3, "", 32768)    = 0
1325971387.860283 close(3)              = 0
```

```
$ strace -r    -e open,read,write,close  cat /etc/HOSTNAME > /dev/null
     0.000067 open("/etc/HOSTNAME", O_RDONLY) = 3
     0.000076 read(3, "harald.science-computing.de\n", 32768) = 28
     0.000042 write(1, "harald.science-computing.de\n", 28) = 28
     0.000039 read(3, "", 32768)        = 0
     0.000033 close(3)                  = 0

$ strace -ttT  -e open,read,write,close  cat /etc/HOSTNAME > /dev/null
22:24:09.339915 open("/etc/HOSTNAME", O_RDONLY) = 3 <0.000010>
22:24:09.340001 read(3, "harald.science-computing.de\n", 32768) = 28 <0.000012>
22:24:09.340052 write(1, "harald.science-computing.de\n"
```

Meist wird man zunächst den `strace`-Output in eine Datei schreiben und anschließend „Offline“ verschiedene Auswertungen machen. Hier aber ein kleines „Live“-Beispiel zur Frage „was treibt denn der `acroread` die ganze Zeit im Hintergrund?“:

```
$ strace -p $( pgrep -f intellinux/bin/acroread ) -e gettimeofday -tt
22:48:19.122849 gettimeofday({1325972899, 122962}, {0, 0}) = 0
22:48:19.123038 gettimeofday({1325972899, 123055}, {0, 0}) = 0
22:48:19.140062 gettimeofday({1325972899, 140154}, {0, 0}) = 0
22:48:19.140347 gettimeofday({1325972899, 140482}, {0, 0}) = 0
22:48:19.142097 gettimeofday({1325972899, 142261}, {0, 0}) = 0
22:48:19.146188 gettimeofday({1325972899, 146335}, {0, 0}) = 0
22:48:19.159878 gettimeofday({1325972899, 160023}, {0, 0}) = 0
CTRL-C
$ strace -p $( pgrep -f intellinux/bin/acroread ) -e gettimeofday -t 2>&1 \
  | cut -c-8 | uniq -c
    136 22:48:26
    138 22:48:27
    140 22:48:28
CTRL-C
```

oder als weiteres Beispiel eine kleine Statistik über 10 Sekunden:

```
$ strace -p $( pgrep -f intellinux/bin/acroread )  -c & sleep 10 ; kill %1
[1] 24495
Process 18559 attached - interrupt to quit
[ Process PID=18559 runs in 32 bit mode. ]
Process 18559 detached
System call usage summary for 32 bit mode:
$ % time     seconds  usecs/call     calls    errors syscall
------ ----------- ----------- --------- --------- ----------------
 79.13    0.010992           5      2114           poll
  7.88    0.001094           0      2939           clock_gettime
  7.00    0.000972           0      2124      1716 read
  3.07    0.000426           0      1388           gettimeofday
  2.93    0.000407           1       406           writev
  0.00    0.000000           0         1           restart_syscall
  0.00    0.000000           0         2           time
------ ----------- ----------- --------- --------- ----------------
100.00    0.013891                  8974      1716 total
```

2.5 Warum bricht denn XY ab, welche Dateien sind relevant?

Wenn ein Programm abbricht, ob nun mit einer „segmentation violation“ oder einer erkennbaren vernünftigen(?) Fehlermeldung, hat man schon halb gewonnen: jetzt muss man „nur“ das Programm mit `strace`

laufen lassen, hoffen, dass damit der Fehler noch reproduzierbar ist und schon findet man kurz vor Ende der `strace`-Ausgabe vielleicht den ganz offensichtlichen Hinweis auf einen der letzten Schritte, der zum Problem geführt hat.

So könnte das Problem daran liegen, dass eine benötigte Shared-Library nicht gefunden wird. Hier ein Beispiel von `emacs` der seine `libX11.so.6` nicht mehr finden kann:

```
25243 open("/usr/lib64/x86_64/libX11.so.6", O_RDONLY) = -1 ENOENT (No such file or directory)
25243 stat("/usr/lib64/x86_64", 0x7fff4f3568c0) = -1 ENOENT (No such file or directory)
25243 open("/usr/lib64/libX11.so.6", O_RDONLY) = -1 ENOENT (No such file or directory)
25243 stat("/usr/lib64", {st_mode=S_IFDIR|0755, st_size=212992, ...}) = 0
25243 writev(2, [{"/usr/bin/emacs", 14}, {": ", 2}, {"error while loading shared libra"...
25243 exit_group(127)                   = ?
```

Oft bekommt man bei Problemen postwendend als Antwort „Wir haben seit dem letzten erfolgreichen Lauf gar nichts geändert“. Hier kann man mit `strace` leicht eine komplette Liste aller geöffneten oder auch gesuchten und nicht gefundenen Dateien erstellen und dann deren Time-Stamps im Filesystem überprüfen, ob denn wirklich nichts neu installiert oder geändert wurde:

```
$ strace -o OUT -e open,execve -f emacs
$ grep \" OUT | cut -d\" -f2 | sort | uniq -c | sort -nr | less
     35 /opt/kde3/share/icons/hicolor/icon-theme.cache
      9 /home/harald/.icons/DMZ/index.theme
      6 /usr/share/emacs/site-lisp/anthy/leim-list.el
      5 /usr/share/emacs/23.3/etc/images/splash.xpm
      4 /usr/share/icons/hicolor/icon-theme.cache
$ ls -ltcd $( grep \" OUT | cut -d\" -f2 | sort -u )  | less
-r--r--r--  1 root   root         0 Jan  7 23:43 /proc/filesystems
-r--r--r--  1 root   root         0 Jan  7 23:43 /proc/meminfo
drwx------  2 harald users    28672 Jan  7 23:40 /home/harald/.emacs.d/auto-save-list/
drwxrwxrwt 48 root   root     12288 Jan  7 23:33 /tmp//
-rw-r--r--  1 root   root   3967384 Jan  7 14:29 /usr/local/share/icons/hicolor/icon-theme.cache
-rw-r--r--  1 root   root  94182076 Jan  7 11:34 /usr/share/icons/hicolor/icon-theme.cache
-rw-r--r--  1 root   root    289877 Jan  7 11:34 /etc/ld.so.cache

$ strace -o OUT -e open,execve -e signal=\!all  -f emacs /etc/HOSTNAME
$ cut -d\" -f2 OUT | sort -u > FILELIST

$ strace -o OUT -e open -f emacs /etc/HOSTNAME
$ grep open OUT | grep -v ENOENT | cut -d\" -f2 | sort -u > FILELIST
```

oder eine Liste aller Zugriffe, die fehlschlugen (vgl. Unterschied zwischen `-e open` und `-e file`!):

```
$ strace -o OUT -e file,execve -f emacs
$ grep ENOENT OUT | cut -d\" -f2 | sort -u
$ grep ' = -1 E'  OUT | cut -d\" -f2 | sort -u
```

Wenn man eine komplette `FILELIST` erstellt, lässt sich leicht prüfen, welche Config-Dateien beispielsweise gelesen wurden, und kann dann nach der Datei suchen, aus der ein magischer String (Makro, Config-Setting, komischer Text in der Ausgabe o.ä.) kommt, um das Problem einkreisen zu können. Man sollte jedoch zuvor noch Einträge mit `/dev/` oder `/proc/` etc. entfernen:

```
$ strace -o OUT -e open,execve  -f emacs /etc/HOSTNAME
$ grep -v ENOENT OUT | grep \" | cut -d\" -f2 | sort -u > FILELIST
$ egrep -v '^/dev/|^/proc/' FILELIST | xargs grep "Welcome to GNU Emacs"
Binary file /usr/bin/emacs-gtk matches
```

2.6 Welche Login-Skripte wurden ausgeführt

... ist hiermit auch ganz allgemein zu prüfen und zu verifizieren. Entweder kann man der entsprechenden Shell vertrauen, dass diese sich z.B. mit deren Option `-login` wirklich identisch zu einem „echten“ Login verhält. Mit dieser Annahme reicht es, eine File-Liste zu erstellen und diese zu analysieren. Im gezeigten Beispiel bleibt `FILELIST` unsortiert, denn auch die Reihenfolge der Login-Skripte ist natürlich interessant:

```
$ strace -o OUT -e open -f bash --login -i
exit
$ grep -v ENOENT OUT | grep \" | cut -d\" -f2 > FILELIST1
$ strace -o OUT -e file -f bash --login -i
exit
$ grep \" OUT | cut -d\" -f2 > FILELIST2

$ egrep "^/etc|$HOME" FILELIST1
/etc/profile
/etc/bash.bashrc
/etc/venus/env.sh
/etc/bash.local
/home/koenig/.bashrc
/etc/bash.bashrc
/etc/venus/env.sh
/etc/bash.local
/home/koenig/.bash_profile
/home/koenig/.profile.local
/home/koenig/.bash_history
/etc/inputrc
/home/koenig/.bash_history
```

Wenn man der Shell nicht so ganz traut, dann sollte man die „Quelle“ eines Logins selbst tracen! Als Nicht-`root` kann man dies z.B. noch mit `xterm -ls` versuchen. Oder man traced als `root` direkt den SSH-Daemon an Port 22 oder ein `getty`-Prozess mit allen Folge-Prozessen (s.u. zu Sicherheitsaspekten eines `strace`-Logs von `sshd` o.ä.):

```
$ lsof -i :22
COMMAND  PID USER   FD   TYPE DEVICE SIZE/OFF NODE NAME
sshd    2732 root    3u  IPv4  15551      0t0  TCP *:ssh (LISTEN)
$ strace -p 2732 -ffv -e file -o sshd.strace ....
```

2.7 Noch mehr Daten sehen

Bei lokalen Dateien reicht eine Datei-Liste und `grep`, um nach der Quelle eines bestimmten Strings zu suchen. Mit Netzwerkverbindungen o.ä. geht das leider nicht so einfach. Für lange Strings bei `read()`, `write()`, usw. werden per default nur die ersten 32 Zeichen ausgegeben, damit kann man im Output von `strace` nicht gut suchen. Hier ist es nützlich, die maximale Länge der Strings zu erhöhen. Oft reichen die ersten 999 Zeichen, manchmal braucht man wirklich die kompletten Records („viel hilft viel“):

```
$ strace -s999    -o OUTFILE -f wget http://www.google.de/
```

(oder gleich `-s 999999`) um nach einem bekannten String zu suchen (z.B. HTTP). Damit findet man den System-Call `recvfrom()` sowie `read()` und kann sich auf den `read()`-Call konzentrieren, wenn man nur die empfangenen Daten untersuchen will (für den gesendeten Daten-Stream entsprechend `sendto()`). Einen guten Überblick über die Netz-Verbindung liefert

```
$ strace -o OUT -e connect,bind,recvfrom,sendto,read wget http://www.google.de/
```

Um nun alle empfangenen Daten zu extrahieren, kann man z.B. die Strings der `recvfrom()`-Calls extrahieren, die ordentlich gequoteten Strings mit dem Shell-Kommando ausgeben und die Quotes konvertieren lassen:

```
$ strace -o OUT -s 999999 -e read wget http://www.google.de/
$ grep 'read(4, "' OUT | cut -d, -f2- | sed -e '1,/google.com/d' \
     -e s'/. [0-9]*) * = [0-9]*$//'  -e 's@^@/bin/echo -en @' | sh
```

Nun stören nur noch die Längen-Records des HTTP-Protokolls, aber der interessante Inhalt ist komplett und durchsuchbar.

3 Probleme

Doch selbst ein so traumhaftes Werkzeug wie `strace` ist nicht ganz ohne Schatten. Hier ein paar Hinweise und Warnungen, den Rest erzählt ihnen die Man-Page oder `google` ;-)

3.1 `strace` stört den Prozess-Ablauf

Die Verwendung von `strace` ist meist transparent für den getracten Prozess, so sollte eine „Messung“ mit `strace` das Messergebnis meist nicht verfälschen.

Jedoch sollte man immer berücksichtigen, dass die Kommunikation zwischen `strace` und den getracten Prozess(en) zusätzlichen Rechenaufwand und viele Kontext-Wechsel bedingen. Zumindest bei Performance-Aussagen auf Systemen mit hoher Last sollte man daher besonders vorsichtig sein.

Ab und an hatte ich auch schon Hänger in den Prozessen, meist bei IPC oder mit Realtime-Signalen. „Früher“ (alte Linux-Kernel, vielleicht um 2.6.<klein> und noch älter?!) trat dies häufiger und dann leider reproduzierbar auf – inzwischen eher nicht mehr.

Sollte jedoch ein angehängter Prozess weiter hängen, obwohl `strace` abgebrochen wurde (`strace` lässt sich ab und an nur mit einem beherzten `kill -9` noch bremsen), dann kann es lohnen, den hängenden Prozessen ein `SIGCONT` zu schicken (`kill -CONT ....`), damit diese vielleicht weiterlaufen.

3.2 `ptrace()` ist nicht kaskadierbar

Der System-Call-Tracer `strace` verwendet, ebenso wie `gdb` oder andere Debugger, den System-Call `ptrace()`, um den zu debuggenden Prozess zu kontrollieren und von diesem Informationen zu erhalten. Da immer nur ein einziger Prozess mittels `ptrace()` einen anderen Prozess kontrollieren kann, ergibt sich automatisch die Einschränkung, dass Prozesse, welche schon mit `gdb`/`strace` o.ä. debuggt werden, nicht nochmals mit einem weiteren `strace`-Kommando beobachtet werden können:

```
$ strace sleep 999 &
$ strace -p $( pgrep sleep )
attach: ptrace(PTRACE_ATTACH, ...): Operation not permitted
```

3.3 SUID-Programme tracen

SUID-Programme lassen sich aus Sicherheitsgründen von normalen Benutzern in Linux/UNIX nicht mit SUID debuggen oder (s)tracen, denn damit könnte der ausführende und tracende Benutzer ja beliebig in die Programmausführung unter einer anderen UID eingreifen und z.B. Daten zu/von einem Kernel-Call ändern. SUID-Programme werden daher ohne SUID, also unter der eigenen UID ausgeführt (was im Einzelfall auch nützlich sein kann). Wird `strace` unter `root` ausgeführt, ist dies kein Problem mehr: `root` darf ohnehin alles, damit ist auch das Ausführen unter anderen Benutzer-IDs kein erweitertes Sicherheitsproblem.

Will man nun jedoch in einem komplexeren Skript, welches *nicht* unter `root` laufen soll/darf, ein einzelnes SUID-Kommando (z.B. `sudo`) starten, so kann man dies mit `strace` erreichen, wenn man das `strace`-Binary *selbst* auf `SUID root` setzt.

Aber **Vorsicht**: jedes mit diesem SUID-präparierten `strace` ausgeführten „getracete“ Programm läuft damit automatisch unter `root` – eine große Sicherheitslücke, falls andere Benutzer dieses SUID-`strace` ausführen dürfen! Daher sollte man entweder alle Zugriffsrechte für nicht-Owner entfernen (`chmod go= strace` bzw. `chmod 4100 strace`), oder diese „gefährliche“ Variante von `strace` als Kopie in einem für andere Benutzer unzugänglichen Verzeichnis „verwahren“.

3.4 Für alle Benutzer lesbarer Output von `strace`

Der Output von `strace` kann durchaus „interessante“ Inhalte offenlegen und sollte daher besser nicht für andere Benutzer lesbar sein! So können Teile von Dateien im Output von `read()` angezeigt werden, die nicht lesbar sind (z.B. der eigene private SSH-Key beim Tracen von `ssh ...`) oder gar die einzelnen Zeichen der Eingabe des eigenen Passworts oder ähnlich sensible Daten. Der Output von `strace`-Sessions durch `root` hat natürlich ein noch viel höheres Potential, unabsichtlich Informationen preiszugeben.

3.5 Dead-Locks

Wenn man „sich selbst“ straced, dann kann man wunderbare Dead-Locks erzeugen, z.B. wenn man einen Teil der Output-Kette für die Ausgabe von `strace` tracen will: die eigene `ssh`-Verbindung oder das `xterm`, in dem `strace` gerade läuft, oder gar der X-Server, auf dem die `strace`-Ausgabe durchblubbert. Wohl dem, der dann noch einen zweiten Zugang zum System hat und das `strace` beenden kann!

4 SEE ALSO

Neben `strace` gibt es weitere ähnliche Trace-Tools unter Linux, die ebenfalls hilfreich sein können:

`ltrace`: statt „S“ystem-Calls werden hier für die meisten „üblichen“ Shared-Libraries alle „L“ibrary-Calls ge„l“traced. Man erhält noch *viel* mehr Output (was dann auch die Ausführung sehr stark bremst), aber das explizite Tracen einzelner libc-Calls wie z.B. `getenv()` oder auch String-Funktionen wie `strlen()` oder `strcpy()` etc. können Informationen über den Programmablauf geben. Viele Optionen sind gleich wie bei `strace`, aber `ltrace` kann ausschliesslich ELF-Binaries tracen und keine Shell-Skripte o.ä., was in einigen Fällen die Anwendung erschweren kann.

`LTTng` könnte die Zukunft sowohl für Kernel- aus auch für User-Mode-Tracing sein. Leider fehlt mir hierzu bislang noch jegliche Praxis (`strace` sei Dank?!).

5 Conclusion

Nun einfach viel Spaß, Erfolg und neue UNIX-Erkenntnisse beim `stracen`!

Literatur

[1] RTFM: `man strace ltrace ptrace`

[2] http://linux.die.net/man/1/strace Man-Page von `strace`

[3] http://linux.die.net/man/2/ptrace Man-Page von `ptrace()`

[4] http://linux.die.net/man/1/ltrace Man-Page von `ltrace`

[5] http://lttng.org/ Das LTTng Projekt