






- **Debugging mit STRACE**
 - **Grundlagen**
 - **Systemaufrufe**
 - **Performance**



Grundlagen



- Ring 1-3


- User-Modus
- unprivilegierter Modus

- Ring 0

- Kernel Modus
- privilegierter Modus


- privilegierter Modus


- In diesem Modus steht dem Kernel der komplette CPU-Befehlssatz zur Verfügung
- dieser Modus darf auf die komplette Hardware und den Speicher zugreifen



- unprivilegiierter Modus


- Benutzerprozesse laufen aus Sicherheit in diesem Modus, in dem weniger Befehle zur Verfügung stehen
- Muss ein Benutzerprozess eine höhere Aufgabe erfüllen so sendet er dem Kernel einen **Systemaufruf (Syscall)**






Syscall Interface

- Systemcall-Interface (Dienstzugangsschnittstelle)
 - Über die Systemcall-Schnittstelle lassen sich aus der Applikation heraus die Dienste des Betriebssystems nutzen.
 - Diese Schnittstelle ist absolut **unabhängig von jeglicher Programmiersprache**. In den seltensten Fällen greift eine Applikation direkt auf das Systemcall-Interface zu, sondern nutzt zu diesem Zweck **Bibliotheksfunktionen**.
 - So lautet beispielsweise der Systemcall für die Ausgabe von Daten in eine Datei oder in ein Gerät **write()**



Ein Prozess möchte eine Datei speichern, darf aber nicht auf die HW zugreifen

Beispiel 2 - remote speichern **it**iversity



● Was ist strace?

- strace ist ein Programm und schaltet sich zwischen einen Benutzerprozeß und den Kernel und protokolliert alle Aktivitäten an dieser Schnittstelle.
- Wenn der verfolgte Prozeß einen Systemaufruf macht, gibt strace den **Namen**, die **Argumente** des Aufrufs und den **Rückgabewert** dieses Systemaufrufs aus.
- Wenn der verfolgte Prozeß ein Signal erhält, gibt strace den Namen des Signals aus.

- strace


- protokolliert Systemaufrufe eines Prozesses

- ltrace

- protokolliert Bibliotheksaufrufe und Systemaufrufe eines Prozesses

- Anwendungsgebiete von strace / ltrace
 - Debugging von Programmen
 - Debugging von laufenden Prozessen
 - Systemanalyse





strace

Einsatz von strace

```
peter@asterix:~> strace /bin/true
```

```
execve("/bin/true", ["/bin/true"], [/* 82 vars */]) = 0
brk(0)                                = 0x804d000
access("/etc/ld.so.preload", R_OK)    = -1 ENOENT (No such file)
open("/etc/ld.so.cache", O_RDONLY)    = 3
fstat64(3, {st_mode=S_IFREG|0644, st_size=119279, ...}) = 0
mmap2(NULL, 119279, PROT_READ, MAP_PRIVATE, 3, 0) = 0xb7f23000
close(3)                              = 0
open("/lib/libc.so.6", O_RDONLY)      = 3
read(3, "\177ELF\1\1\1\0\0\0\0\0\0\0\0\0@a\1\0004\0\0\0"... , 512) = 512
fstat64(3, {st_mode=S_IFREG|0755, st_size=1281488, ...}) = 0
mmap2(NULL, 4096, MAP_PRIVATE|MAP_ANONYMOUS, -1, 0) = 0xb7f22000
mmap2(NULL, 1254896, MAP_PRIVATE|MAP_DENYWRITE, 3, 0) = 0xb7def000
fadvise64(3, 0, 1254896, POSIX_FADV_WILLNEED) = 0
mmap2(0xb7f1c000, 12288, MAP_DENYWRITE, 3, 0x12c) = 0xb7f1c000
mmap2(0xb7f1f000, 9712, MAP_ANONYMOUS, -1, 0) = 0xb7f1f000
close(3)                              = 0
...
```

strace **optionen** **befehl** **argumente**

- protokolliert Systemaufrufe eines Prozesses

OPTIONEN

-p #	dockt an den Prozess Nr # an
-o D	lenkt die Ausgabe in Datei D um
-f	folgt auch Unterprozessen
-e A,B,...	zeigt nur die Systemaufrufe A,B,...
-c	Statistik
-v	zeigt die Argumente ungekürzt an (verbose)

```
# Einsatz von strace
```

```
peter@asterix:~> strace /bin/true
```

```
execve("/bin/true", ["/bin/true"], [/* 85 vars */]) = 0
```

```
....
```

• execve

- Dateinamen des Programmes `/bin/true`
- Liste der Argumente `[/bin/true]` wobei das erste Argument der Name des Programmes oder Prozesses ist
- Liste der Umgebungsvariablen `(/proc/PID/envron)` wird durch `/* # vars */` angedeutet
- Rückgabewert `= 0`

```
# Einsatz von strace
```

```
peter@asterix:~> strace /bin/true
```

```
execve("/bin/true", ["/bin/true"], [/* 85 vars */]) = 0
```

```
....
```

```
_exit(0) = ?
```

- `_exit(0) = ?` oder `exit_group(0) = ?`
 - Letzte Zeile enthält keinen Rückgabewert mehr
 - (0) ... ist der Rückgabewert der an den Vaterprozess gemeldet wird
 - kann mit `echo $?` abgefragt werden

- Vergleichen von Programmen

```
strace -o /tmp/true.trace /bin/true
```

```
strace -o /tmp/false.trace /bin/false
```

```
diff /tmp/{true,false}.trace
```

Sind die exit Zeilen gleich?

- Generelles zu strace

- jede Zeile protokolliert einen Systemaufruf
- jeder Aufruf gibt einen Rückgabewert zurück
- ein negativer Rückgabewert ist ein Fehler
- es gibt ~263 verschiedene Systemaufrufe
- Dokumentation zu Systemaufruf open

man 2 open

- Filtern von Systemaufrufen

```
strace -e execve,_exit /bin/true
```

```
strace -e execve,exit_group /bin/true
```

Einsatz von strace mittels Filter

```
peter@asterix:~> strace -e execve,exit_group /bin/true  
execve("/bin/true", ["/bin/true"], [/* 85 vars */) = 0  
exit_group(0) = ?
```

- /tmp/true2.trace erstellen
 - auszuführendes Programm: /bin/true
 - Filter: execve, exit_group
- /tmp/false2.trace erstellen
 - auszuführendes Programm: /bin/false
 - Filter: execve, exit_group
- Beide traces mit diff vergleichen

- Dateizugriffe

- open, read, write, close

- Verzeichnisse- & Dateiattribute

- chdir, mkdir, rename, unlink, ...
- chmod, chown, stat, fstat, lstat, ...

- Netzwerk

- socket, bind, listen, accept, connect

- **UIDs & GIDs**


- setguid, getuid, setgid, getid

- **Prozessverwaltung**

- select, fork, wait, execve

- **Diverse**

- mmap, munmap, mprotect, brk, uname,...



Systemaufrufe im Detail

- open, close -

```
# Einsatz von strace
```

```
open("/etc/ld.so.cache", O_RDONLY)    = 3
```

• open

- erhält als Argument einen Dateinamen und Zugriffsmodus und liefert als Rückgabewert eine positive Zahl den Dateideskriptor
- Eine negative Zahl als Rückgabewert ist ein Fehler
- Zeigt welche Konfigurationsdateien gelesen werden
- Zeigt in welche (Log-) Dateien geschrieben wird

Einsatz von strace

```
peter@asterix:~> strace -e execve,open /bin/true
execve("/bin/true", ["/bin/true"], [/* 85 vars */]) = 0
open("/etc/ld.so.cache", O_RDONLY)      = 3
open("/lib/libc.so.6", O_RDONLY)       = 3
...
```

OPEN FLAGS

O_RDONLY Datei nur zum LESEN öffnen

O_WRONLY Datei nur zum SCHREIBEN öffnen

O_RDWR Datei zum LESEN & SCHREIBEN öffnen

können noch zusätzlich mit anderen flags kombiniert werden

- Fehlerbehebung mit open

- Manche Programme klappen eine ganze Latte von möglichen Orten nach Konfigurationsdateien ab

- Aufgabe

- welche Konfigurationsdateien liest **ssh localhost**?
- welche hat eine größere Priorität?

```
# Beispiel für eine nicht gefundene Datei  
open("/root/. cups/client.conf", O_RDONLY|O_LARGEFILE) = -1 ENOENT \  
      (No such file or directory)
```

FEHLERMELDUNGEN BEI OPEN

EEXIST	pathname existiert bereits
EISDIR	pathname bezieht sich auf einen Verzeichnisnamen
EACCESS	Der Zugriff wurde verweigert
ENOENT	Der angegebene Verzeichnispfad existiert nicht
EROFS	Schreibfehler da read-only Dateisystem vorliegt


mehr FLAGS: man 2 open

Einsatz von strace

```
peter@asterix:~> strace -e open,read,close ssh localhost  
open("/etc/ssh/ssh_config", O_RDONLY|O_LARGEFILE) = 3  
read(3, "#\t$OpenBSD: ssh_config,v 1.22 20"... , 4096) = 2643  
read(3, "", 4096) = 0  
close(3) 0
```

● Systemaufruf: close(#)

- Ist das Gegenstück zu open
- Unbedeutend für die Fehlersuche
- Danach ist der Deskriptor X wieder frei und kann bei einem anderen open verwendet werden



Systemaufrufe im Detail

- read, write -

- Systemaufruf: read, write
 - dienen zum lesen und schreiben in durch open geöffneten Dateien
 - als Dateiname wird der Dateidiskriptor von open verwendet
 - zeigt welcher Datenstrom wirklich gelesen oder geschrieben wird



Beispiel für open & read

```
open("/root/.ssh/known_hosts", O_RDONLY|O_LARGEFILE) = 4  
read(4, "mail.triples.at,81.223.158.165 s"... , 4096) = 925  
read(4, "", 4096)
```

open (dateiname, OPEN_FLAGS) = Dateideskriptor

read (Dateideskriptor, "INHALT...", Bytes) = Bytes

```
read (3, "xx 32bytes xx", 4096) = 1823
```

- Systemaufruf: read, write

- strace zeigt als Debuginfo nur die ersten 32Byte an die gelesen oder geschrieben werden
- kann mit der Option **-s 500** z.B. auf z.b 500 Zeichen/Bytes erweitert werden

- Normale read Operation

```
strace -o pass.trace -e open,read cat /etc/passwd
```

- read Operation mit 1000 Zeichen

```
strace -s 1000 -o pass2.trace -e open,read \  
cat /etc/passwd
```

Beispiel für open & read

```
peter@asterix:~> strace -o pass.trace -e open,read cat /etc/passwd  
open("/etc/passwd", O_RDONLY|O_LARGEFILE) = 3  
read(3, "at:x:25:25:Batch jobs daemon:/va"..., 4096) = 1823  
read(3, "", 4096) = 0
```

read (3, "xx 32bytes xx", 4096) = 1823

Lese-Blockgröße in Bytes


wirklich gelesene Bytes

Wie groß ist die Datei passwd?

```
peter@asterix:~> ls -l /etc/passwd  
-rw-r--r-- 1 root root 1823 17. Okt 14:56 /etc/passwd
```

- Wo ist der Unterschied zwischen:
 - `dd if=/dev/zero of=/dev/null bs=300000 count=1`
 - `dd if=/dev/zero of=/dev/null bs=1 count=300000`
- Testen mit
 - `strace -e open,read,write`

- Welche Konfigurationsdateien liest samba?
 - rcsmb stop
 - `strace -o samba.read -e open,read rcsmb start`
- In welche Dateien schreibt samba?
 - rcsmb stop
 - `strace -o samba.write -e open,write rcsmb start`



- Folgen von Kinderprozessen

- rcsmb stop
- `strace -f -o samba.read -e open,read rcsmb start &`
- `strace -f -o samba.write -e open,write rcsmb start &`
strace muss mit kill aus einer anderen Konsole beendet werden
oder mit & als Hintergrundprozess gestartet werden

Beispiel für open & write

```
open("/var/log/samba/log.smbd", O_WRONLY|O_CREAT| \
    O_APPEND|O_LARGEFILE, 0644) = 4
write(4, "[2007/11/19 10:58:26, 0] smbd/se"..., 49) = 49
write(4, " smbd version 3.0.26a-3-1478-SU"..., 51) = 51
write(4, " Copyright Andrew Tridgell and "...., 57) = 57
```

open (dateiname, OPEN_FLAGS) = Dateideskriptor

write (Dateideskriptor, "INHALT...", Bytes) = Bytes

```
# Beispiel für das öffnen einer LOG Datei
```

```
open("/var/log/samba/log.smbd", O_WRONLY|O_CREAT| \
    O_APPEND|O_LARGEFILE, 0644) = 4
```

ERWEITERTE OPEN FLAGS

O_RDONLY, O_WRONLY, O_RDWR können erweitert werden durch

O_CREAT Wenn die Datei nicht existiert wird sie erstellt


O_TRUNC Wenn die Datei existiert wird sie überschrieben

O_APPEND Öffnen der Datei im Anhängemodus

O_SYNC synchron I/O Modi, der Prozess wird solange angehalten bis die Datei physikalisch geschrieben ist

0664 Rechte die beim erstellen gesetzt werden

mehr FLAGS: man 2 open



Systemaufrufe

- chdir, mkdir, rmdir, -
- rename, unlink -

- **chdir**
 - wechselt das aktuelle Arbeitsverzeichnis
- **mkdir, rmdir**
 - Erstellt bzw. löscht ein leeres Verzeichnis
- **unlink**
 - löscht eine Datei (entfernt Inode Eintrag)
- **rename**
 - Umbenennen oder verschieben innerhalb des Dateisystems


- Verschieben einer Datei
 - `echo "Kleine Datei" > datei.alt`
 - `strace -e rename mv datei.alt datei.neu`
`open,close,read,write,rename,unlink`
- Was passiert wenn:
 - die Datei auf der selben Partition verschoben wird
 - auf eine andere Partition verschoben wird

- Verschieben auf eine andere Partition
 - rename schlägt mit Fehler **EXDEV** fehl
 - Original wird geöffnet
 - Ziel wird geöffnet
 - Original wird gelesen und in Ziel geschrieben
 - Dateien werden geschlossen
 - Original wird entfernt (**unlink**)

- Kopieren von Dateien

- wo liegt der Unterschied zwischen dem Verschieben und dem kopieren einer Datei auf eine andere Partition?

- **chmod, chown, stat, stat64**
 - dienen zum abfragen und ändern von Dateiattributen.
(64 ist 64-bit Version)
- **fchmod, fchown, fstat und fstat64**
 - wie oben jedoch wird anstelle eines Dateinamens der Dateidiskriptor von open verwendet
- **lchown, lstat, lstat64**
 - verhalten sich anders bei symbolischen Links



Performance

Ausgabe einer Statistik

```
peter@asterix:~> strace -c ssh localhost
```

% time	seconds	usecs/call	calls	errors	syscall
94.76	0.003999	190	21		fadvise64
5.24	0.000221	5	49	14	open
0.00	0.000000	0	107		read
0.00	0.000000	0	42		write
0.00	0.000000	0	48		close
0.00	0.000000	0	1		execve
0.00	0.000000	0	3		time
0.00	0.000000	0	1	1	access
...					

```
peter@asterix:~> strace -c ssh localhost
```

% time	seconds	usecs/call	calls	errors	syscall
94.76	0.003999	190	21		fadvise64
5.24	0.000221	5	49	14	open

OPTIONEN

%time	Gesamtzeit verbraucht durch diesen Systemcall
--------------	---

seconds	Gesamtzeit in Sekunden
----------------	------------------------

usecs/call	Microsekunden pro Systemcall
-------------------	------------------------------

calls	Gesamtzahl diesen Typs
--------------	------------------------

errors	Anzahl der Fehler bei diesem Systemcall
---------------	---

time Befehl Argumente

- Der Befehl "time"

- misst wie lange ein Befehl für die Ausführung braucht
- liefert 3 Rückgabewerte

real x Millisekunden

user x Millisekunden

sys x Millisekunden





ZEIT	BEDEUTUNG
real	zeigt die real verbrauchte Zeit (Gesamtzeit)
user	vom Prozess verbrauchte Zeit im Usermodus
sys	vom Prozess verbrauchte Zeit im Kernelmodus

Zeitmessung eines find-Befehles

peter@tux~> time find /etc -name "*.conf"

/etc/reader.conf.d/reader.conf

/etc/powerd.conf

/etc/ntp.conf

/etc/wvdial.conf

...

real 0m3.798s

user 0m0.076s

sys 0m0.272s

- Interpretation der Rückgabewerte
 - user + sys = vom Prozess verbrauchte Zeit
 - user + sys = entspricht nicht der real Zeit!

real	0m3.798s
user	0m0.076s
sys	0m0.272s

Wo ist die restliche Zeit verschwunden?


● Der Zustand "wait"


- ein Systemaufruf versetzt einen Prozess sehr oft in den wait-Zustand
- in dieser Zeit verbraucht der Prozess keine CPU-Zeit
- Speicher wird in dieser Zeit nicht freigegeben

● Folgen

- belastet nicht die CPU
- belastet die Nerven des Benutzers

user + sys + wait = real





- Ursache für den Zustand "wait"
 - Prozess wartet auf ein Ereignis
 - auf die Benutzereingabe
 - auf ein Gerät
 - ein Netzwerkpaket
 -
 - Wartet darauf CPU-Zeit zu bekommen
 - abhängig von Prozesspriorität, nice-Wert, Anzahl
 - abhängig von freier Speicher und CPU-Auslastung




Ist ein hoher wait-Anteil schlecht?

- NEIN


- der Konqueror wird gestartet und er wird nicht benutzt. Belastet nicht meine CPU

- JA

- ein Backupjob wird gestartet und er muss andauernd auf die Daten warten. lange Backupzeit



- Mögliche Ursachen für hohen user-Anteil
 - aufwändige Berechnungen
 - verschlüsseln von Daten
 - komplizierte Algorithmen
 - ...
 - schlechte Programmierung
 - primitiver Sortieralgorithmus
 - schlechte Interpretersprache (C ist schneller wie bash)



- Mögliche Ursachen für hohen sys-Anteil
 - Ein-/Ausgabeoperationen mit schlechtem Übertragungsmodus. z.b ohne DMA
 - komplexe Dateisystemoperationen
 - verschlüsseln des Dateisystems
 - Dateisystemcheck
 - ...
 - viele Zugriffe auf die Hardware
 - unnötig viele Systemaufrufe

- Übung

- Kopieren von 300kB von /dev/zero nach /dev/null

- Beide Varianten mit time testen

- `dd if=/dev/zero of=/dev/null bs=300000 count=1`
- `dd if=/dev/zero of=/dev/null bs=1 count=300000`

Kopieren von 300kB

```
peter@asterix:~> time dd if=/dev/zero of=/dev/null bs=300000 count=1
```

1+0 Datensätze ein


1+0 Datensätze aus

300000 Bytes (300 kB) kopiert, 5,8945e-05 s, 5,1 GB/s

real 0m0.004s

user 0m0.000s

sys 0m0.004s



Kopieren von 300kB

```
peter@asterix:~> time dd if=/dev/zero of=/dev/null bs=1 count=300000
```

300000+0 Datensätze ein

300000+0 Datensätze aus

300000 Bytes (300 kB) kopiert, 0,231105 s, 1,3 MB/s

real 0m0.234s

user 0m0.068s

sys 0m0.164s

- time

- time zeigt nur eine kurze Zusammenfassung


- strace

- **strace -c** zeigt eine detaillierte Aufstellung
- strace zeigt genaue Informationen zu jedem ausgeführten Systemcall an
- perfekt für das Troubleshooting und das verbessern der Performance

Ausgabe einer Statistik

```
peter@asterix:~> strace -c ssh localhost
```

% time	seconds	usecs/call	calls	errors	syscall
94.76	0.003999	190	21		fadvise64
5.24	0.000221	5	49	14	open
0.00	0.000000	0	107		read
0.00	0.000000	0	42		write
0.00	0.000000	0	48		close
0.00	0.000000	0	1		execve
0.00	0.000000	0	3		time
0.00	0.000000	0	1	1	access
...					



Itrace

`ltrace` **optionen** **befehl** **argumente**

- protokolliert Bibliotheksaufrufe und Systemaufrufe eines Prozesses

OPTIONEN

-p #	dockt an den Prozess Nr # an
-o D	lenkt die Ausgabe in Datei D um
-f	folgt auch Unterprozessen
-e A,B,...	zeigt nur die Systemaufrufe A,B,...
-S	zeigt zusätzlich Systemaufrufe
-n X	rückt pro Aufrufebene um X Spalten ein

Ausgabe einer Statistik

peter@asterix:~> ltrace -c find /usr/share/doc

% time	seconds	usecs/call	calls	errors	syscall
86.27	1.071814	30	35327		write
10.15	0.126092	38	3297		getdents64
2.33	0.028931	3	10208		lstat64
0.55	0.006861	2	3122	1	chdir
0.39	0.004890	3	1567	2	open
[...]					
0.00	0.000003	3	1		uname
0.00	0.000001	1	1		time
100.00	1.242403		58269	3	total ...

it-ersity

Wolfgang Ziegler und Partner Ges.m.b.H.

Schottenfeldgasse 69

A – 1070 Vienna

Phone +43 (1) 5228222

servicecenter@it-ersity.com

© 2007 Wolfgang Ziegler und Partner GesmbH. All rights reserved.

This document / presentation is for informational purposes only.

WOLFGANG ZIEGLER UND PARTNER MAKES NO WARRANTIES, EXPRESS OR IMPLIED, IN THIS DOCUMENT and/or SUMMARY.

The names of actual companies and products mentioned herein may be the trademarks of their respective owners.