Wie entgehe ich der I/O-Hölle

Der RRDtool Caching Daemon

Sebastian „tokkee“ Harl
<sh@teamix.net>

Linuxtag 2012
25. Mai 2012

Solide IT-Infrastruktur
Sitz: Nürnberg

Open-Source	Monitoring	Netzwerke
N-IX	NetApp	Juniper
Riverbed	VMWare	Schulungen

We're hiring: `http://teamix.net/jobs/`

Was ist RRDCacheD?

- RRDCacheD = RRDtool Caching Daemon
- Gedacht für große Setups mit I/O-bezogenen Problemen

Arbeitsweise

1. „Abfangen“ von RRD `updates`
2. Akkumulieren der Daten
3. Schreiben der gesammelten Daten

Grundlagen: RRDtool Internas

Arbeitsweise von RRDCacheD

Verwendung von RRDCacheD

Integration von RRDCacheD

Ausblick

Grundlagen: RRDtools Grundidee

- Aktuelle Daten sind im Detail am interessantesten
- Ältere Daten werden mit geringerer Auflösung benötigt ($\rightarrow$ Überblick über längere Zeiträume)
- $\Rightarrow$ Datenhaltung nach der Round-Robin Methode
- $\Rightarrow$ Daten zunehmend verdichten (Konsolidierung)

RRD, RRA, PDP, CF, ... WTF?

teamix
SOLIDE IT-INFRASTRUKTUR

Zur Wiederholung, zunächst ein paar Grundbegriffe ...

- RRD: Round Robin Database
- DS: Data Source
- RRA: Round Robin Archive
- PDP: Primary Data Point
- CF: Consolidation Function
  $\rightarrow$ AVERAGE, MINIMUM, MAXIMUM, ...
- CDP: Consolidated Data Point

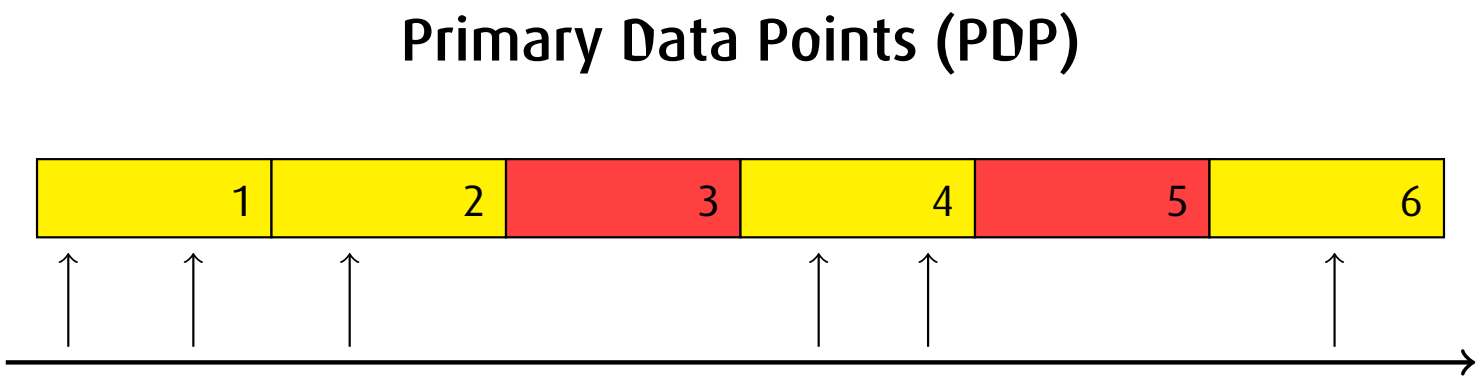

- Step: Interval der PDPs (Sekunden)
- Durchschnitt der Messwerte pro Step bilden einen PDP
- Heartbeat: maximaler Abstand zwischen zwei Messwerten, sonst „unknown“

Round Robin Archive (RRA)

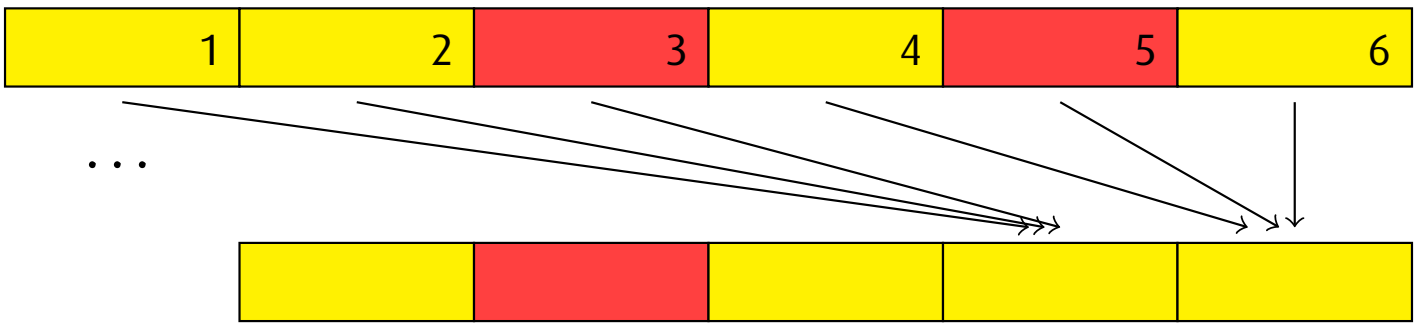

- Konsolidierungsfunktionen: `AVERAGE`, `MIN`, `MAX`, `LAST`
- xff (xfiles factor): maximale Anteil der unbekannten PDPs, sonst „unknown“
- Steps: Anzahl der PDPs
- Rows: Anzahl der CDPs

updates animiert

RRD `file.rrd`
Step = 300 s

RRA 0: 5 Minuten-Durchschnitt
RRA 1: 10 Minuten-Durchschnitt
RRA 2: 60 Minuten-Durchschnitt
RRA 3: 60 Minuten-Maximum

Zeit: 45 Minuten

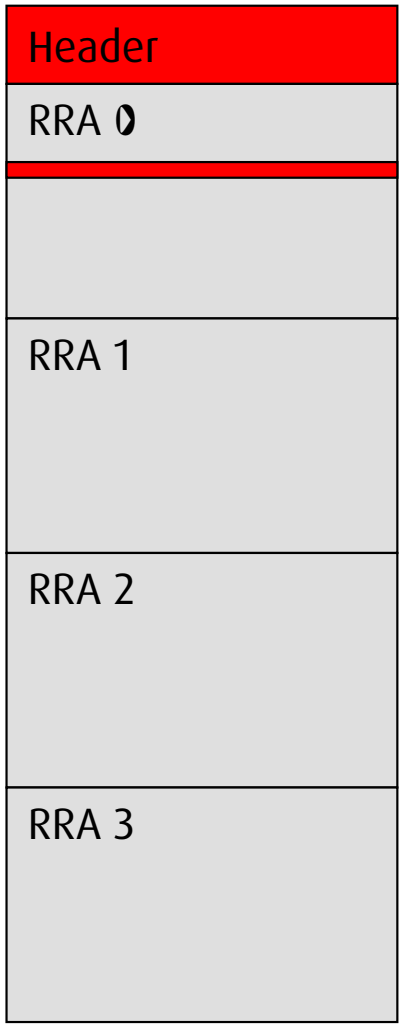

updates animiert

RRD `file.rrd`
Step = 300 s

RRA 0: 5 Minuten-Durchschnitt
RRA 1: 10 Minuten-Durchschnitt
RRA 2: 60 Minuten-Durchschnitt
RRA 3: 60 Minuten-Maximum

Zeit: 50 Minuten

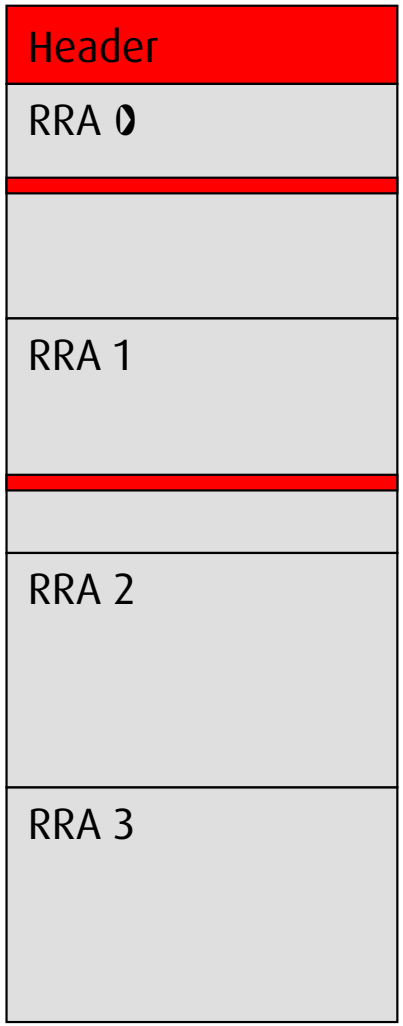

updates animiert

RRD `file.rrd`
Step = 300 s

RRA 0: 5 Minuten-Durchschnitt
RRA 1: 10 Minuten-Durchschnitt
RRA 2: 60 Minuten-Durchschnitt
RRA 3: 60 Minuten-Maximum

Zeit: 55 Minuten

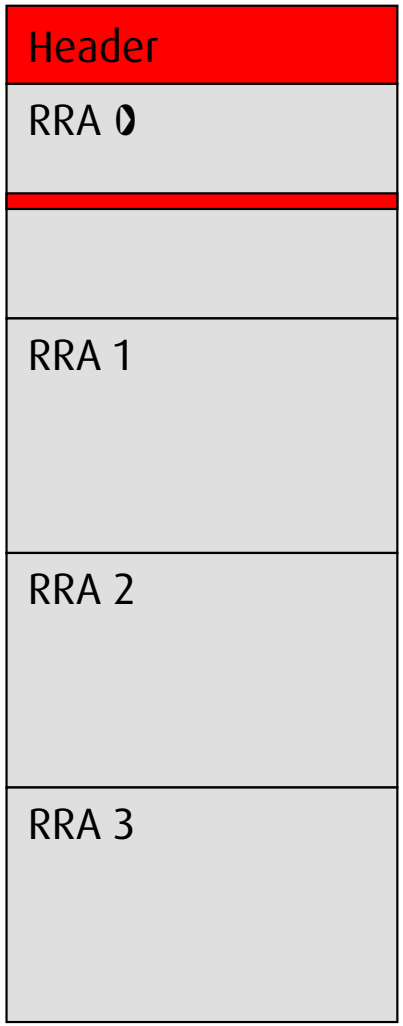

`update`s animiert

RRD `file.rrd`
Step = 300 s

RRA 0: 5 Minuten-Durchschnitt
RRA 1: 10 Minuten-Durchschnitt
RRA 2: 60 Minuten-Durchschnitt
RRA 3: 60 Minuten-Maximum

Zeit: 60 Minuten

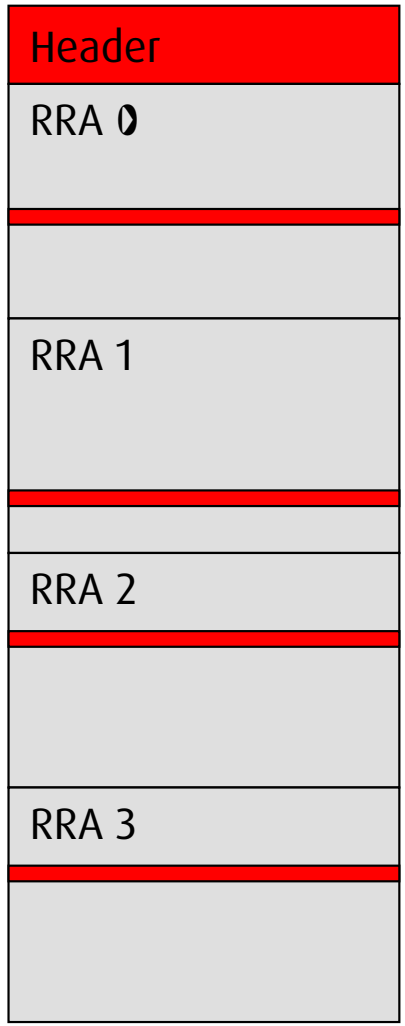

`update`s im Detail

`update` Algorithmus (schematisch):

1. Lesen der Header
2. foreach RRA, das aktualisiert wird:
   - `seek`
   - Lesen der Daten
   - `seek`
   - Schreiben der aktualisierten Daten
3. `seek`
4. Lesen der Header
5. `seek`
6. Schreiben der Header

updates im Detail

```
open("file.rrd", O_RDWR) = 4
read(4, "RRD\0000001\0\0\0\0/%\300\307C+\37[\2\0\0\0"..., 4096) = 4096
_llseek(4, 0, [4096], SEEK_CUR)          = 0
_llseek(4, 4096, [4096], SEEK_SET)       = 0
_llseek(4, 4096, [4096], SEEK_SET)       = 0
_llseek(4, -1324, [2772], SEEK_CUR)      = 0
write(4, "\2557Q$<\314\0@\303k\327.8\316\363?", 16) = 16
_llseek(4, 53248, [53248], SEEK_SET)     = 0
read(4, "\0\0\370\377\0\0\0\0\0\0\370\377\0\0\0\0\0\0"..., 4096) = 4096
_llseek(4, -3372, [53972], SEEK_CUR)     = 0
write(4, "\2557Q$<\314\0@\303k\327.8\316\363?", 16) = 16
_llseek(4, 0, [0], SEEK_SET)             = 0
read(4, "RRD\0000001\0\0\0\0/%\300\307C+\37[\2\0\0\0"..., 4096) = 4096
_llseek(4, -2880, [1216], SEEK_CUR)      = 0
write(4, "t \370E832936\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0\0"..., 1540) = 1540
close(4)
```

(RRDtool ohne mmap, aber prinzipiell mit identisch)

Problem: Festplatten I/O

Problem: In großen Setups kommen Platten schnell an ihr Limit

- Update schreibt i.d.R. ein Wert („double“, 8 Bytes)
- Konsolidierung ändert wenige Werte verteilt über die Datei
- **Aber:** Lesen von / Schreiben auf Platte geschieht in Einheiten der Seitengröße (engl.: page size), z. B. 4096 Bytes
- Zusätzlich: viele Seeks notwendig

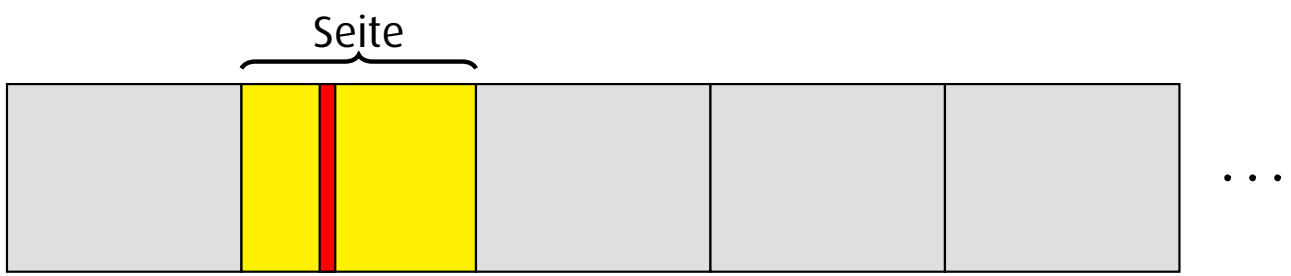

Problem: Festplatten I/O

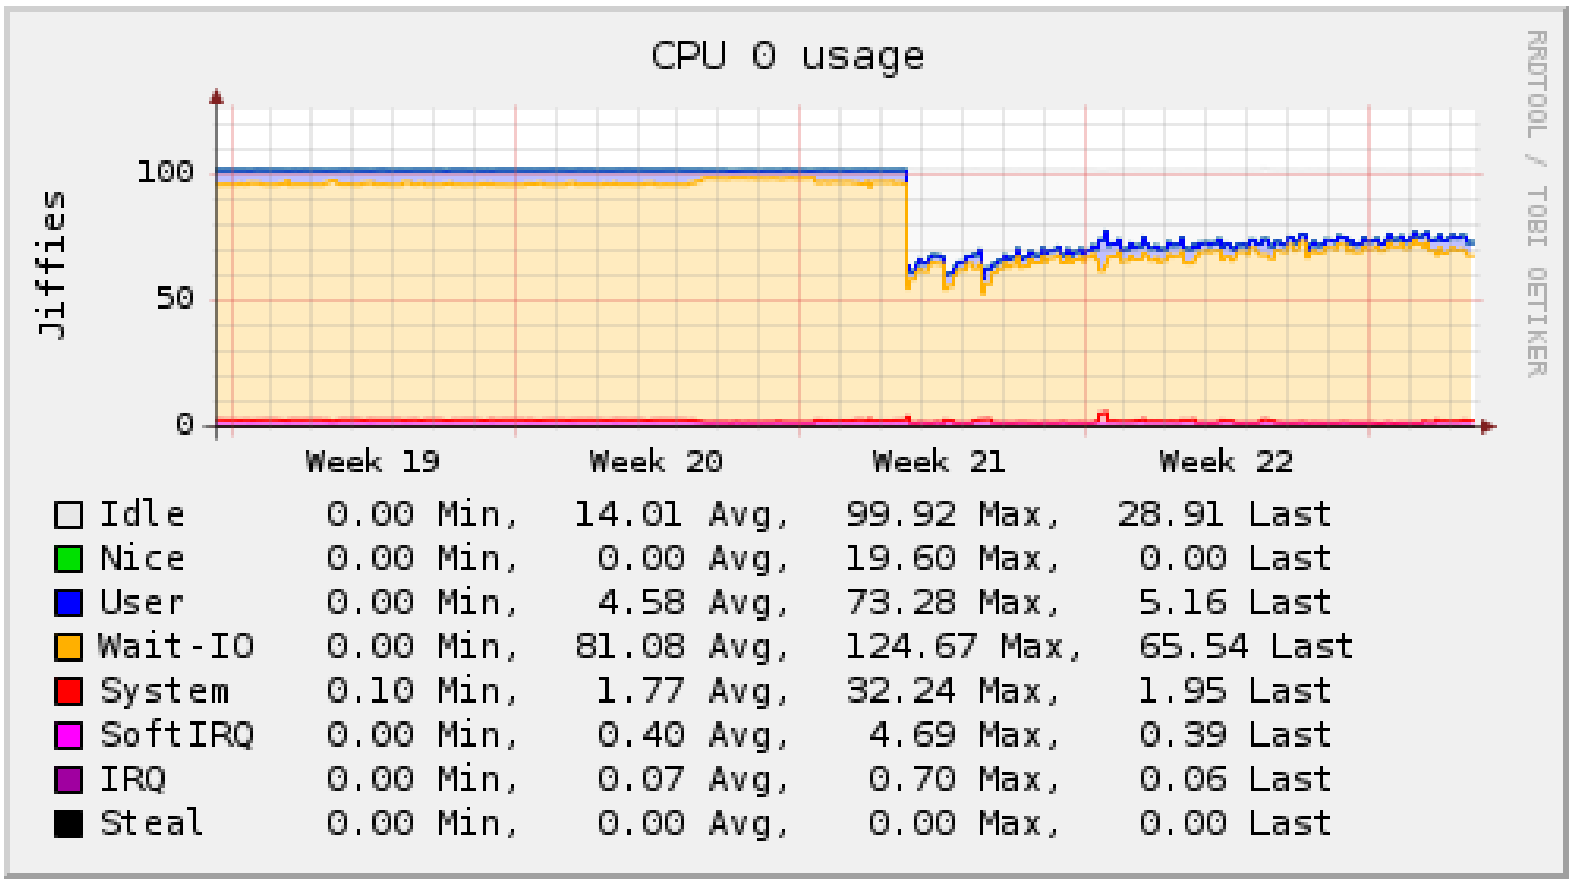

Quelle: `http://collectd.org/wiki/index.php/Inside_the_RRDtool_plugin`

Lösungsansätze

- Klassisch: `tmpfs` und regelmäßige „manuelle“ Synchronisation

  $\Rightarrow$ unflexibel, fehleranfällig, sync von vielen unnötigen Daten

- Seit RRDtool 1.3: `madvise/fadvise`
  $\rightarrow$ kein read-ahead; alte Daten weg; wichtige Daten behalten

  $\Rightarrow$ weiterhin lesen/schreiben von ganzen Blöcken pro `update`

- $\Rightarrow$ `updates` zusammenfassen und ganze Blöcke schreiben

  $\rightarrow$ RRDCacheD (seit Version 1.4, Oktober 2009)

Grundlagen: RRDtool Internas

Arbeitsweise von RRDCacheD

Verwendung von RRDCacheD

Integration von RRDCacheD

Ausblick

RRDCacheD: Grundidee

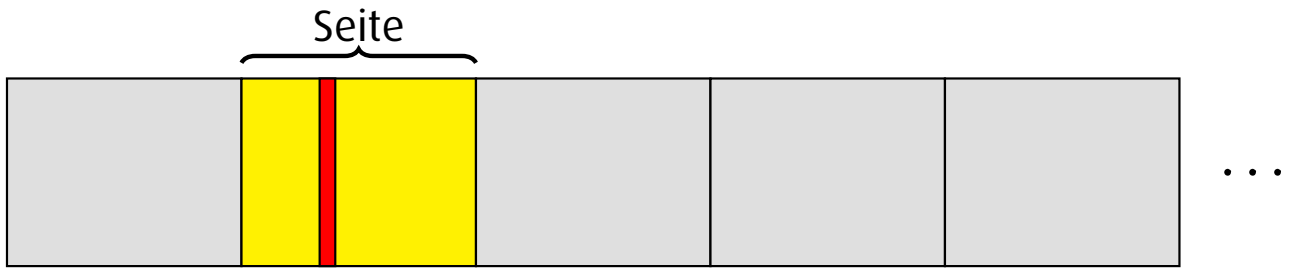

⇒ 1 Seite lesen (z.B. 4096 Bytes); 8 Bytes ändern; 1 Seite schreiben hat nahezu den gleichen Aufwand, wie:

RRDCacheD: Grundidee

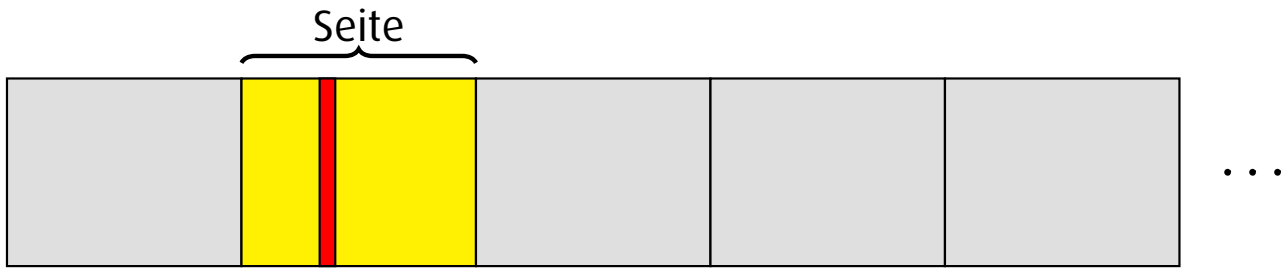

⇒ 1 Seite lesen (z.B. 4096 Bytes); 8 Bytes ändern; 1 Seite schreiben hat nahezu den gleichen Aufwand, wie:

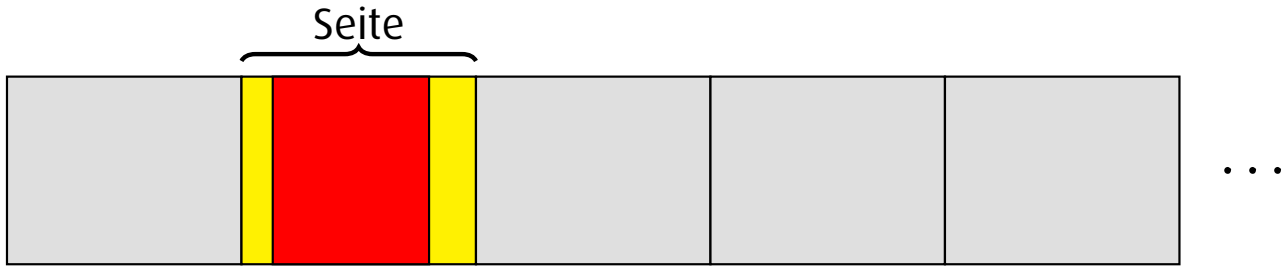

... 1 Seite lesen; viele Daten ändern; 1 Seite schreiben

⇒ 4096 / 8 = 512 mal mehr `updates` ohne Overhead machbar

RRDCacheD: Grundidee

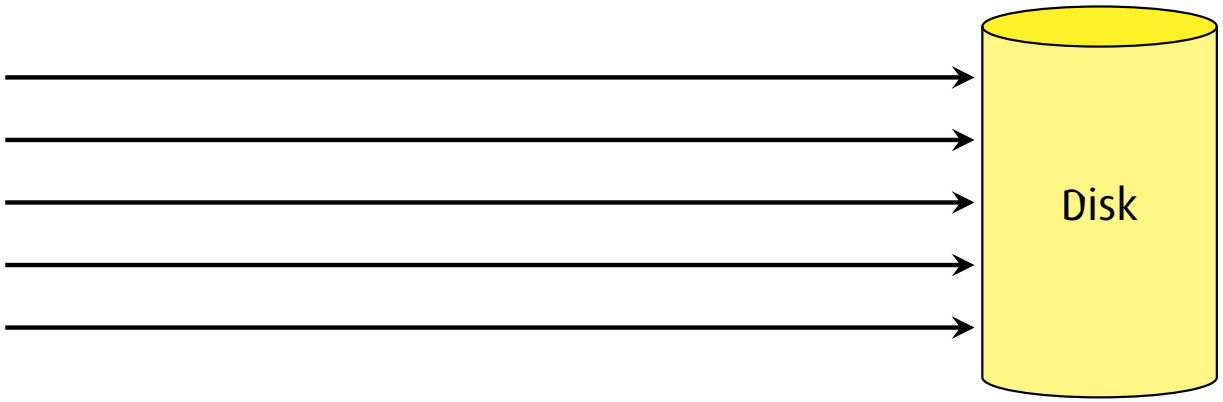

RRDCacheD: Grundidee

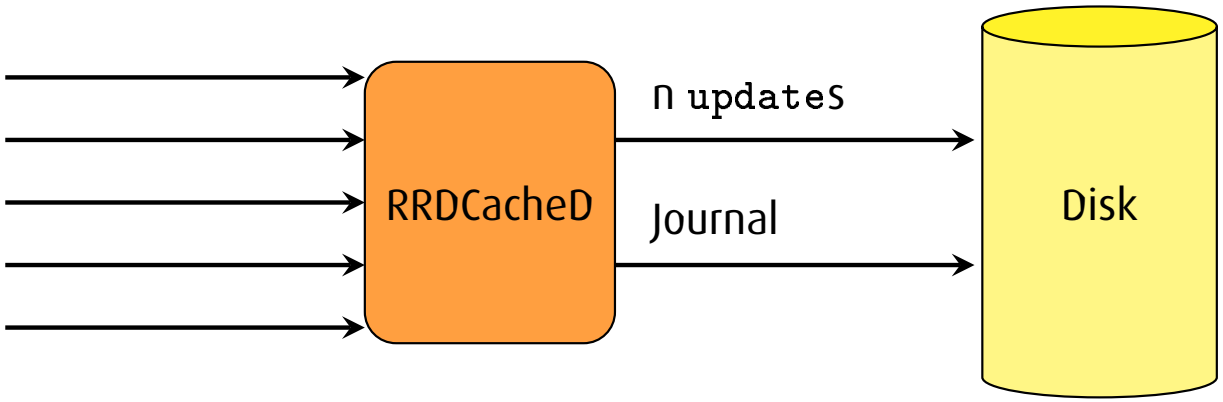

- „Abfangen“ von `updates`
- Ansammeln von Werten
- Nach Timeout: gesammelte Werte in RRD schreiben

RRDCacheD: Grundidee

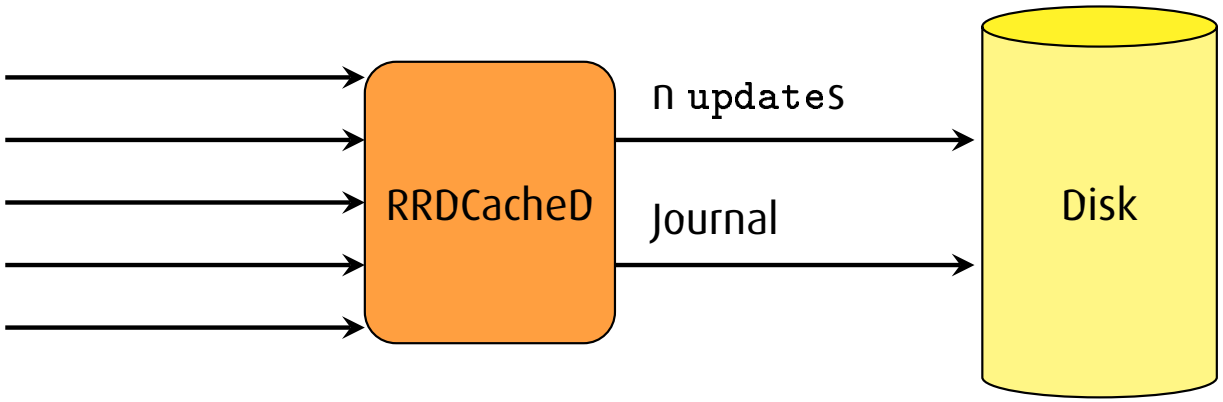

- „Abfangen“ von `updates`
- Ansammeln von Werten
- Nach Timeout: gesammelte Werte in RRD schreiben

- Journal vermindert Datenverlust bei Absturz
- `flush` schreibt (einzelne) Werte sofort

RRDCacheD: Umsetzung

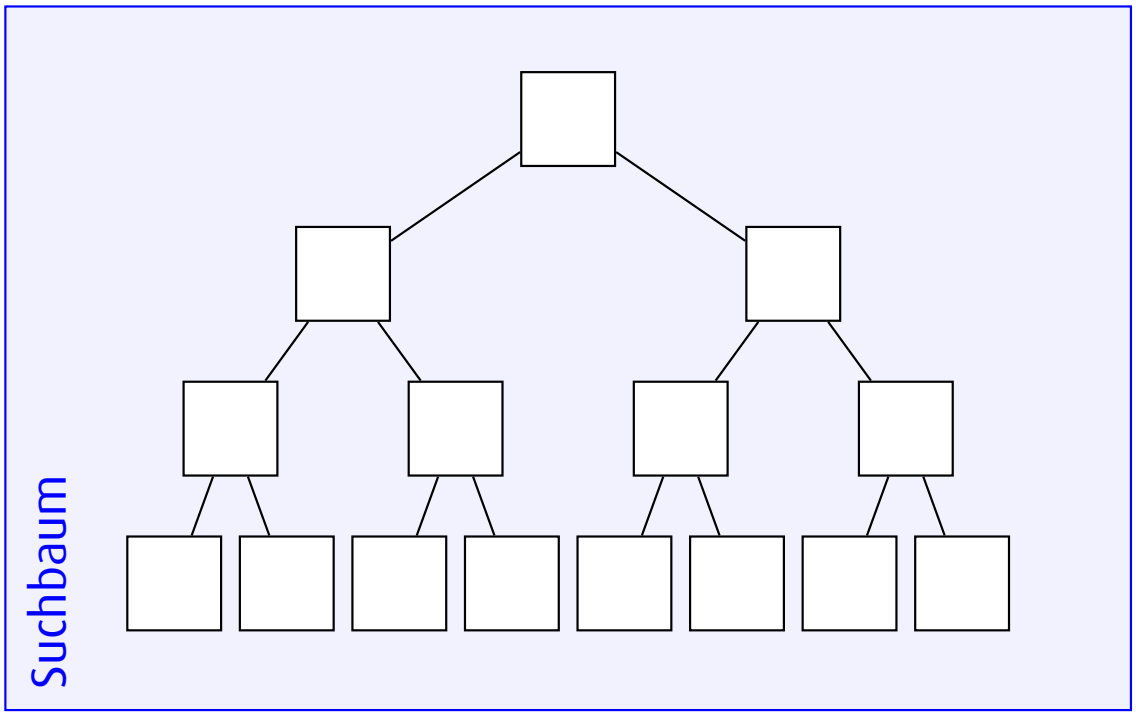

Graphik © Florian „octo“ Forster

RRDCacheD: Umsetzung

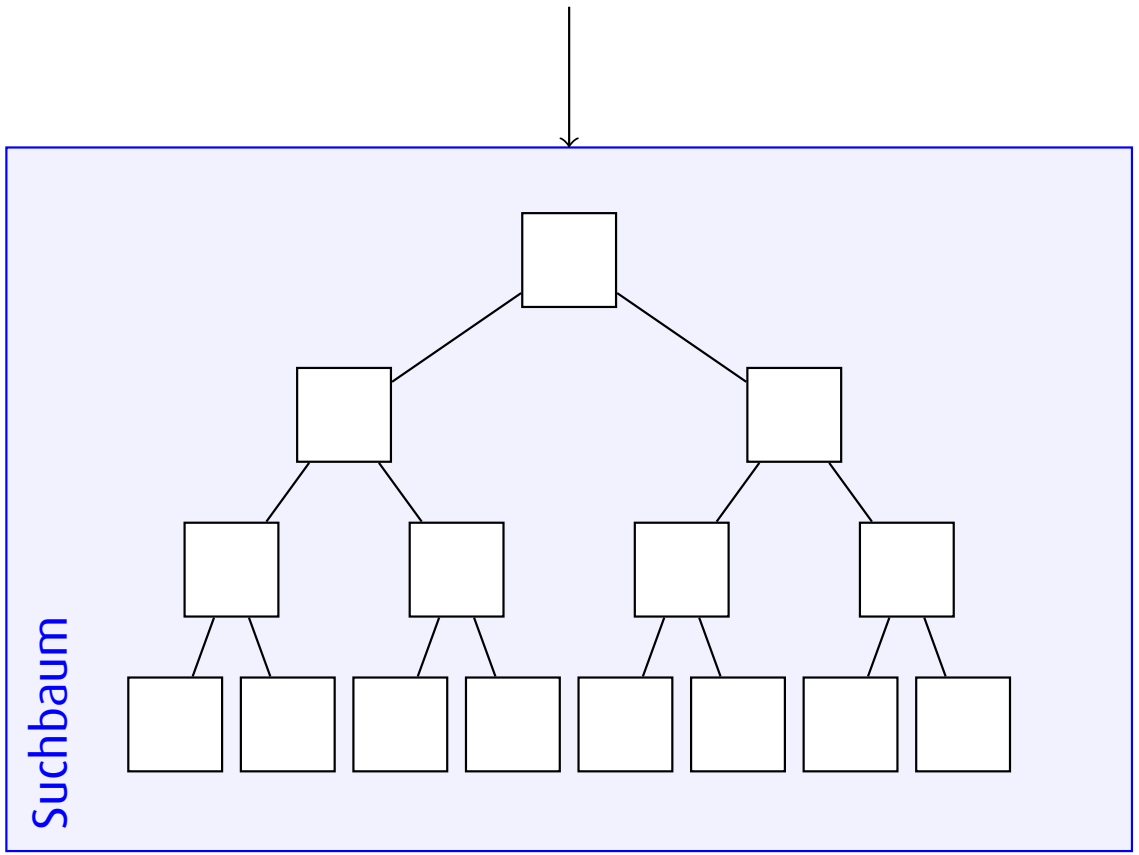

Graphik © Florian „octo“ Forster

RRDCacheD: Umsetzung

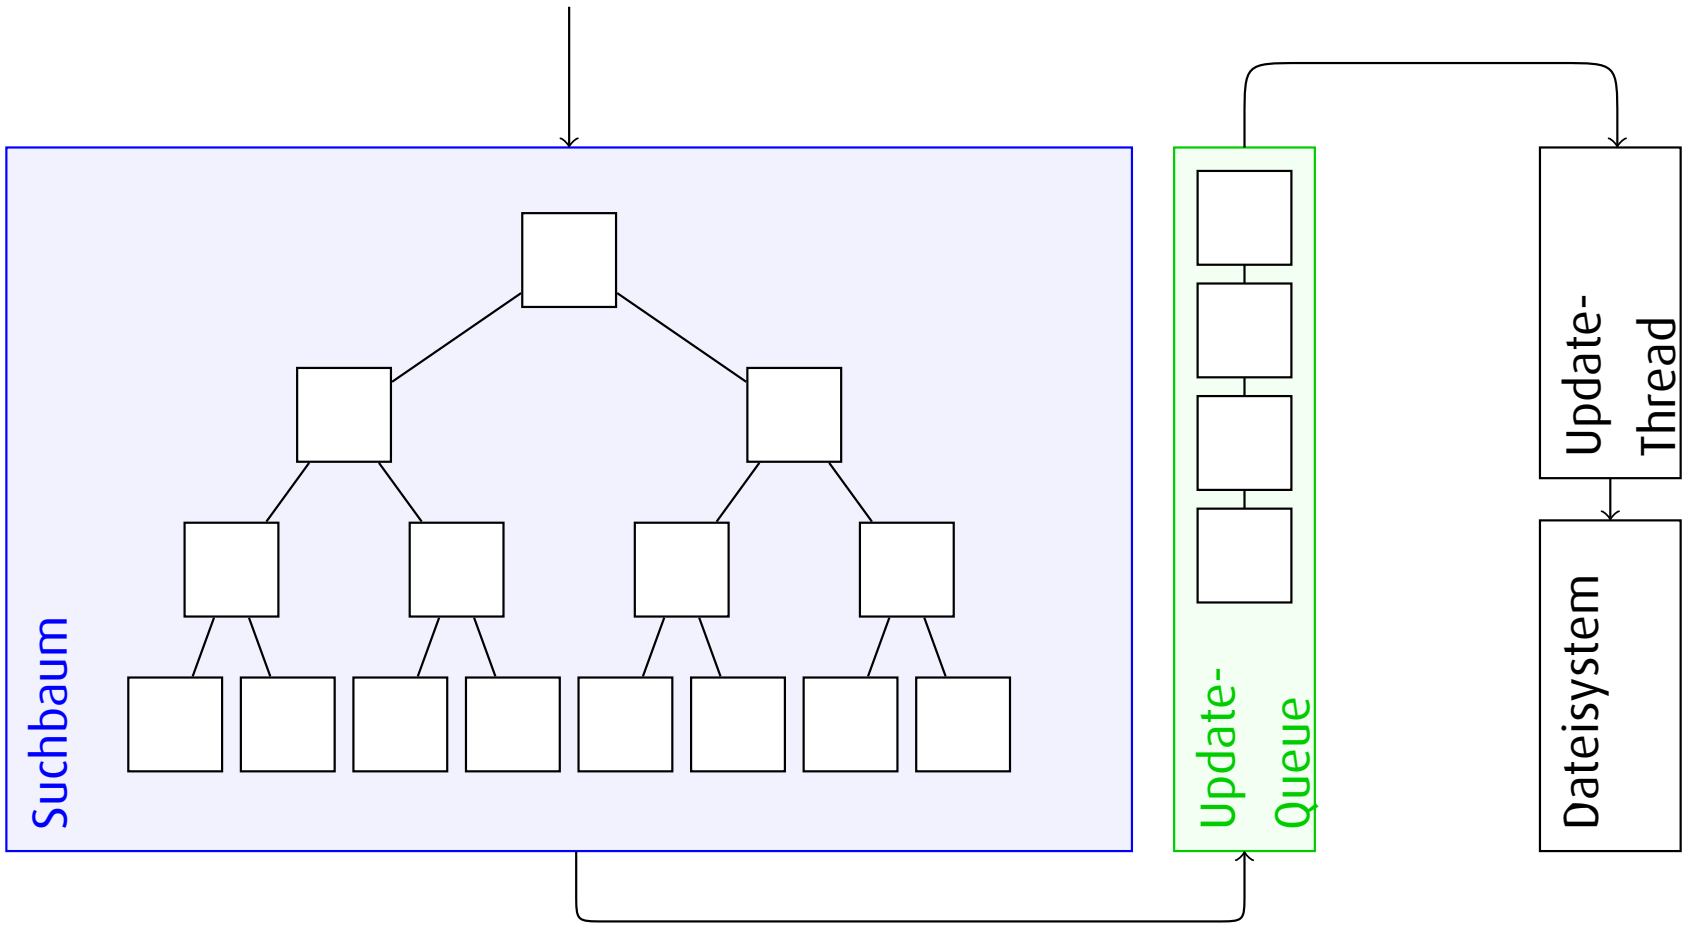

Graphik © Florian „octo“ Forster

RRDCacheD: Umsetzung

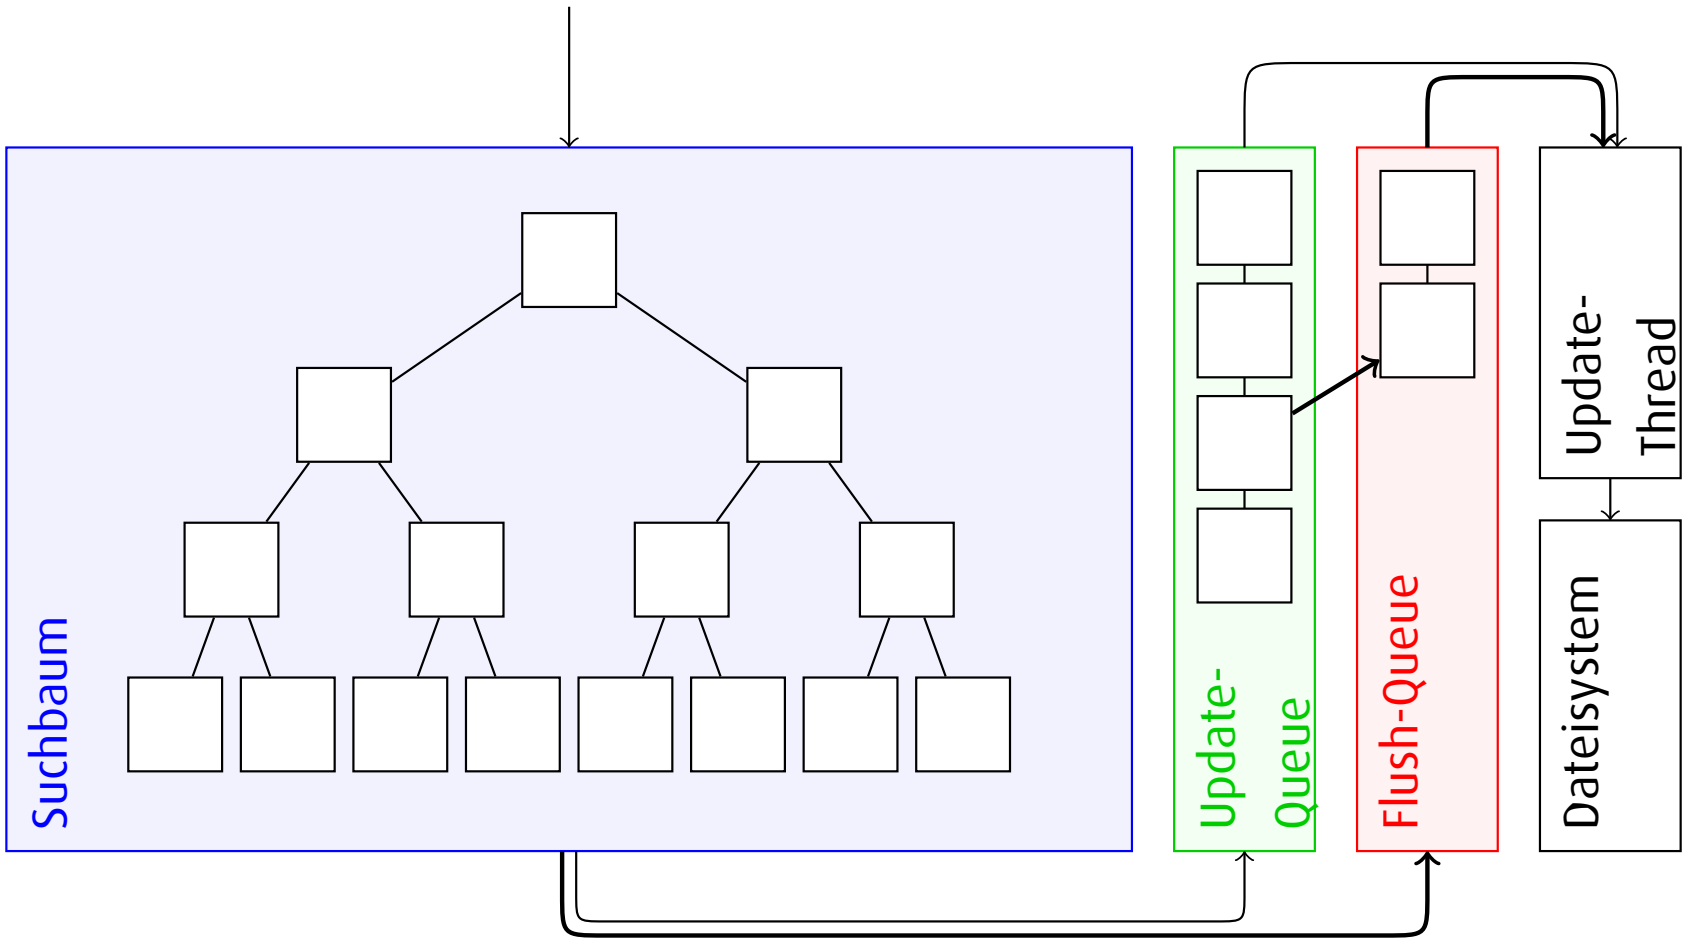

Graphik © Florian „octo“ Forster

RRDCacheD: Umsetzung

teamix
SOLIDE IT-INFRASTRUKTUR

Server

- Der eigentliche Caching Daemon
- Kommunikation über Sockets:
  UNIX Domain oder TCP (IPv4 / IPv6)
  $\rightarrow$ Kommunikation mittels Text-basiertem Protokoll

Client

- Teil von `librrd`
- Verbinden zum Daemon
- Abstraktion des Netzwerk-Protokolls

RRDCacheD: Parameter/Features

Benutzergruppe des UNIX Sockets

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Dateirechte des UNIX Sockets

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

UNIX Socket

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Einschränkungen für folgende Sockets

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

TCP IPv4 Socket

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Journal Einstellungen

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Basisverzeichnis Einstellungen

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Timeout

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

Verzögerung

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Parameter/Features

„garbage collection“

```
man rrdcached; # ;-)
rrdcached \
      -s rrdcached \
      -m 0660 \
      -l unix:/var/run/rrdcached.sock \
      -P FLUSH \
      -l 10.42.23.1 \
      -j /var/lib/rrdcached/journal/ -F \
      -b /var/lib/rrdcached/db/ -B \
      -w 3600 \
      -z 3600 \
      -f 86400
```

RRDCacheD: Basisverzeichnis

Basisverzeichnis: `/var/lib/rrdcached/db/`
(Standard: `/tmp/`!)

Kommandozeile	verwendete Datei
`foo.rrd`	`/var/lib/rrdcached/db/foo.rrd`
`foo/bar.rrd`	`/var/lib/rrdcached/db/foo/bar.rrd`
`/tmp/foo.rrd`	`/tmp/foo.rrd` mit `-B`: nicht akzeptiert

Grundlagen: RRDtool Internas

Arbeitsweise von RRDCacheD

Verwendung von RRDCacheD

Integration von RRDCacheD

Ausblick

Verfügbare Kommandos

- `dump*`
- `fetch*`
- `flush`
- `graph*`
- `graphv*`
- `info*`
- `last*`
- `lastupdate*`
- `update`
- `xport*`

Verwendung von RRDCacheD

- `-daemon` Kommandozeilen Option
- `RRDCACHED_ADDRESS` Umgebungsvariable
  $\Rightarrow$ erlaubt vollkommen transparente Integration

Verwendung von RRDCacheD

- `-daemon` Kommandozeilen Option
- `RRDCACHED_ADDRESS` Umgebungsvariable
  $\Rightarrow$ erlaubt vollkommen transparente Integration

- Achtung:
  - Basisverzeichnis Einstellungen
  - `rrdupdate`s `-template` nicht unterstützt
  - Ausreichend RAM verfügbar haben!

Verwendung von RRDCacheD

- `-daemon` Kommandozeilen Option
- `RRDCACHED_ADDRESS` Umgebungsvariable
  $\Rightarrow$ erlaubt vollkommen transparente Integration

- Achtung:
  - Basisverzeichnis Einstellungen
  - `rrdupdateS -template` nicht unterstützt
  - Ausreichend RAM verfügbar haben!

C API

```c
int status;

char *values[] = { "1234567890:42", "1234567900:23" };
int   values_num = 2;

/* daemon_address == NULL => verwende RRDCACHED_ADDRESS */
status = rrdc_connect(daemon_address);
if (status) {
    fprintf(stderr, "ERROR: %s\n", rrd_get_error());
    exit(1);
}

status = rrdc_update("file.rrd", values_num, values);
if (status) /* ... */;
```

Perl „API“


```
use RRDs;

RRDs::update("file.rrd", "--daemon", $daemon_address,
        "1234567890:42", "1234567900:23");
my $err = RRDs::error;
die "ERROR: $err" if $err;
```

Netzwerk-Protokoll

- Text- und Zeilen-basiert
- Kommandos bestehen aus dem Befehlsnamen und ggf. Parametern

  z.B. `FLUSH foo.rrd`
- Antwort des Servers besteht aus Status-Code und kurzer Nachricht
  - Status < 0: Fehler (Beschreibung folgt in gleicher Zeile)
  - Status ≥ 0: Erfolg; Status entspricht Anzahl weiterer Zeilen

  z.B. `0 Success`

Netzwerk-Protokoll: BATCH

- „Block-Abarbeitung“ von vielen Kommandos
- Spart `read` und `write` Aufrufe
  → für sehr große Setups mit sehr großen Datenraten

```
->:  BATCH
<-:  0 Go ahead.  End with dot '.' on its own line.
->:  UPDATE x.rrd 1223661439:1:2:3
->:  UPDATE y.rrd 1223661440:3:4:5
->:  ...
->:  .
<-:  2 Errors
<-:  1 <Fehlermeldung für das 1. Kommando>
<-:  12 <Fehlermeldung für das 12. Kommando>
```

Sicherheit

- Bislang nur Einschränkung von erlaubten Kommandos möglich
- **Alles**, was an einem Socket ankommt, wird angenommen
- Netzwerk-Verkehr ist unverschlüsselt
- Daemon sollte mit eingeschränkten Benutzerrechten laufen

- $\Rightarrow$ Admin muss sich um geeignete Abschottung kümmern, z.B. dediziertes (V)LAN, VPN, o.ä.

Grundlagen: RRDtool Internas

Arbeitsweise von RRDCacheD

Verwendung von RRDCacheD

Integration von RRDCacheD

Ausblick

Integration in collectd

- `rrdcached` Plugin

  `http://collectd.org/wiki/index.php/Plugin:RRDCacheD`
- seit Version 4.6 (02/2009)

```
LoadPlugin rrdcached
<Plugin rrdcached>
    DaemonAddress "unix:/var/run/rrdcached.sock"
</Plugin>
```

Integration in Nagios

- PNP4Nagios unterstützt RRDCached seit Version 0.4.11
- `http://www.pnp4nagios.org/pnp/rrdcached`
- `http://www.semintelligent.com/blog/articles/40/nagios-performance-tuning-early-lessons-learned-lessons-shared-part-45-scalable-performance-data-graphing`

Integration in PNP4Nagios

process_perfdata.cfg

```
RRD_DAEMON_OPTS = 127.0.0.1:8888
```

config_local.php

```
$conf['RRD_DAEMON_OPTS'] = '127.0.0.1:8888';
```

Integration in andere Software

- Cacti:
  - `http://binaryfury.wann.net/2010/01/rrdcached-and-cacti-not-quite-there-yet/`
  - `https://lists.oetiker.ch/pipermail/rrd-developers/2010-March/003664.html`
- Ganglia:
  - `http://sourceforge.net/apps/trac/ganglia/wiki/rrdcached_integration`
- Munin:
  - `http://munin-monitoring.org/ticket/444`
- openNMS:
  - `http://www.opennms.org/wiki/Rrdcached`

Grundlagen: RRDtool Internas

Arbeitsweise von RRDCacheD

Verwendung von RRDCacheD

Integration von RRDCacheD

Ausblick

Ausblick

- Echte Unterstützung für `fetch` und `graph`
  `DEF:v1=path/to/example.rrd:value:AVERAGE:daemon=r2d2.example.org`
  $\rightarrow$ Graph von verteilten Daten (in `trunk`)
- Verschlüsselung
- Echte Authentifizierung
- Redundante Setups?
- Drosselung (bessere Alternative zu `-z`?)

Ausblick

- Echte Unterstützung für `fetch` und `graph`
  `DEF:v1=path/to/example.rrd:value:AVERAGE:daemon=r2d2.example.org`
  → Graph von verteilten Daten (in `trunk`)
- Verschlüsselung
- Echte Authentifizierung
- Redundante Setups?
- Drosselung (bessere Alternative zu `-z`?)

- It's OpenSource! ... send patches! ;-)

Vielen Dank für die Aufmerksamkeit!

Gibt es Fragen?

Kontakt:
Sebastian „tokkee“ Harl
<sh@teamix.net>

We’re hiring: `http://teamix.net/jobs/`