

ROCKET SEARCH



Die Hauptverwendungszweck der Software ist das Indizieren von Dateien auf Netzlaufwerken und dessen zur Verfügung stellen dieser Daten via Weboberfläche für den Endanwender.

Ein Anwendungsbeispiel:

an einem Server sind 3 Netzlaufwerke angebunden.

2x Samba, einmal normales Share, und einmal ein Windows DFS share
1x NFS

Filesystem	Size	Used	Avail	Use%	Mounted on
//172.17.190.34/dfs	7.0T	5.3T	1.8T	76%	/root/smb_mount/dfs
172.17.190.6:/usr/sap	466G	244G	222G	53%	/root/smb_mount/sap
//172.17.190.1/docs-team	150G	138G	12G	92%	/root/smb_mount/docs-team

Auf den 3 Netzlaufwerken liegen 15 mio. Dateien in 1.1 mio Verzeichnissen.

```
find "/root/smb_mount/" -noleaf -type f -print | wc -l  
15 182764  
find "/root/smb_mount/" -noleaf -type d -print | wc -l  
1 110377
```

Alle diese Dateien haben die unterschiedlichsten Ausprägungen aber besonders in den Docs Ordnern, befinden sich überwiegend Microsoft Office Dokumente (Excel & Word) .

Die Redis Datenbank und der auszuführende Server der Indizierung sollten auf einem Physikalischen System liegen.

Die Redis Datenbank starten und in einem Zug konfigurieren. Es empfiehlt sich dies in einem Startscript zu implementieren.

```
/usr/local/bin/redis-server &  
sleep 10  
/usr/local/bin/redis-cli config set save ""  
/usr/local/bin/redis-cli config set appendonly no  
/usr/local/bin/redis-cli config set protected-mode no
```

um Sicherzustellen das keine Datensätze in den SWAP geschrieben werden, diesen abschalten oder auf ein Minimum begrenzen. Maximale SWAP gröÙe der Partion 2GB .

```
swapoff -a  
free -m
```

	total	used	free	shared	buffers	cached
Mem:	516916	36312	480604	60	888	28435
-/+ buffers/cache:		6988	509928			
Swap:	0	0	0			

oder bei max. 2GB

```
free -m
```

	total	used	free	shared	buffers	cached
Mem:	516916	36312	480604	60	888	28435
-/+ buffers/cache:		6988	509928			
Swap:	2047	0	2047			

Einige Kernel Parameter für die Redis Datenbank einstellen

```
echo 1 > /proc/sys/vm/overcommit_memory
echo never > /sys/kernel/mm/transparent_hugepage/enabled
echo 1 > /proc/sys/net/ipv4/tcp_tw_reuse
```

Ermitteln wieviele Kerne dem System zur Verfügung stehen.

```
cat /proc/cpuinfo | grep -i processor | wc -l
72
```

Zur Ausführung der Indizierung empfiehlt es sich 75% der zur Verfügung stehenden CPU Kerne zu verwenden.

```
echo "(`cat /proc/cpuinfo | grep -i processor | wc -l` * 75)/100" | bc
```

Die Ausführung des Indizierungsdiensens außerhalb der Kernarbeitszeiten via Cron Job einplanen.

```
#Start 23:59 Uhr jeden Tag#
59 23 * * * root wrapper /root/smb_moun/ 54
```

sowie die Bandbreitenbegrenzung auf 5 MBit / Sek. begrenzen.

```
#QoS fuer SMB und NFS
tc qdisc del dev eth0 root
tc qdisc add dev eth0 root handle 1:0 htb default 10
#OUTPUT
tc class add dev eth0 parent 1:0 classid 1:123 htb rate 5mbit ceil 5mbit
tc filter add dev eth0 parent 1: prio 0 protocol ip handle 123 fw flowid 1:123
#INPUT
tc class add dev eth0 parent 1:1 classid 1:456 htb rate 5mbit ceil 5mbit
tc filter add dev eth0 parent 1: prio 0 protocol ip handle 456 fw flowid 1:456
#
tc qdisc show dev eth0
tc class show dev eth0
tc filter show dev eth0
tc -s -d qdisc show dev eth0
#
iptables -F -t mangle
iptables -t mangle -A INPUT -d 172.17.190.78 -s 172.17.190.6 -j MARK --set-mark 456
iptables -t mangle -A INPUT -d 172.17.190.78 -s 172.17.190.34 -j MARK --set-mark 456
iptables -t mangle -A INPUT -d 172.17.190.78 -s 172.17.190.1 -j MARK --set-mark 456
#
#Traffic Controll für SMB
iptables -t mangle -A OUTPUT -p tcp --dport 445 -j MARK --set-mark 123
#Traffic Controll für NFSv4
iptables -t mangle -A OUTPUT -p tcp --dport 2049 -j MARK --set-mark 123
iptables -L -v -n -t mangle
```

Je nach Anzahl der Daten kann der Indizierungsprozess mehrere Stunden oder Tage dauern, abhängig davon was alles indiziert wird. Nach der Indizierung befinden sich nun die Daten komplett im RAM der Redis Datenbank .

Um zu prüfen wie viel Datensätze sich in der Datenbank befinden, folgendes ausführen.

```
redis-cli dbsize  
(integer) 24603
```

```
redis-cli info memory  
# Memory  
used_memory:125252320  
used_memory_human:119.45M  
used_memory_rss:132771840  
used_memory_rss_human:126.62M  
used_memory_peak:125252320  
used_memory_peak_human:119.45M  
used_memory_peak_perc:100.00%  
used_memory_overhead:12790078  
used_memory_startup:786456  
used_memory_dataset:112462242  
used_memory_dataset_perc:90.36%  
total_system_memory:4008566784  
total_system_memory_human:3.73G  
used_memory_lua:37888  
used_memory_lua_human:37.00K  
maxmemory:0  
maxmemory_human:0B  
maxmemory_policy:noeviction  
mem_fragmentation_ratio:1.06  
mem_allocator:jemalloc-4.0.3  
active_defrag_running:0  
lazyfree_pending_objects:0
```

Da während der Indizierung kein Backup der Daten aus der Datenbank erfolgt, sollte man nach Beendigung der Indizierung ein Backup manuell durchführen.

```
redis-cli save
```

Der dump.rdb Datenbank Backup File befindet sich dort, wo die ausführbare Datei „redis-server“ gestartet wurde. Da diese über ein Startscript gestartet wurden, liegt es in diesem Fall unter /root/scripte

```
~/scripte # ls -ltr
total 95220
-rwxrwxrwx 1 root root 986 Jun 29 14:53 master_start_script.sh
drwx----- 1 root root 558 Jun 29 14:53 ..
-rw-r--r-- 1 root root 97497969 Jun 29 14:55 dump.rdb
drwxr-xr-x 1 root root 60 Jun 29 14:56 .
```

Den Backup File sollte man nun sicher verwahren.

Der Bereich für das Backup zur Indizierung der Daten ist nun abgeschlossen. Hier geht es weiter mit dem Webfrontend.

Dieses sollte aus Performance Gründen nicht auf dem Rocket-Search System Server liegen, sondern separat. Als Web-Server sollte ein Nginx zum Einsatz kommen.

Nginx mit folgendem Kommando starten:

```
nginx  
sowie php-cgi: „nohup php-cgi -b 127.0.0.1:9000 &“
```

Im folgenden Schritt mittels Browsers, empfehlenswert Firefox, auf den Nginx Server zugreifen.

`http://<nginx webserver>`



Das WebUI ist in zwei größer Bereich aufgeteilt. Rechts und mittig die Suche sowie links der Statistik Bereich.

Um etwas zu suchen, einfach einen Suchbegriff im Textfeld eingeben und auf suchen klicken.

Möglichen Suchbegriffe wären zum Beispiel:

- Der Name einer Datei oder eines Verzeichnisses
- Dateiendungen
- Erstelldatum einer Datei
- Versionsnummer einer EXE oder DLL Datei
- Inhalt eines ASCII Files

MD5 Hash Wert einer Datei

Das folgende Schaubild zeigt die einzelnen Ergebnisse der Suche.

The screenshot shows the Rocket Search interface with a search for 'konfig_commands.txt'. The search results table is as follows:

Netzlaufwerk auf dem sich die Datei befindet	Suchstring: "konfig_commands.txt" Anzahl Rückgabewerte: 1	Suchbegriff	Letzter Zugriff der Datei (nicht Flocket Search)	Letzte Modifikation der Datei	Größe in MB	MD5 Hash Wert	Inhalt der Datei
\\172.17.150.1\tech.doc\smux\keph\konfig_commands.txt		konfig_commands.txt	2016-12-27 11:37:24	2017-04-05 11:16:28	0.01 MB	b492b07db50652109a373d9d95a1b4bf	##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem##### unicode text, with very long lines#12- data zeichenketten problem#####

Annotations in the image include:

- Suchstring, nach was gesucht wurde
- Suchbegriff
- Letzter Zugriff der Datei (nicht Flocket Search)
- Letzte Modifikation der Datei
- Größe in MB
- MD5 Hash Wert
- Inhalt der Datei
- Suchzeit: 0.65269899368286 Sekunden
- Suchzeit in der Datenbank für den Suchbegriff
- Netzlaufwerk auf dem sich die Datei befindet
- Vorkommen des Suchbegriffs in der Datenbank bzw. in welchem Datensatz sich der Suchbegriff befindet, hier der Datenname

Mit z.B. Doppelklick auf den Netzlaufwerkpfad unter „Pfad“, ist es möglich mittels Kopieren und Einfügen die Datei ganz einfach zu starten oder zu betrachten.