

**1C02**


## RAID Performance Grundlagen

Hermann Brunner  
Angerwiese 15  
85567 Grafing  
Tel 080 92 / 328 29  
Fax 080 92 / 328 42  
hermann@brunner-consulting.de  
www.brunner-consulting.de

brunner consulting RAID Performance Grundlagen 1



## Wozu überhaupt über I/O Performance nachdenken?



Jahr	Memory Größe (10 000x-1 000 000x)	CPU Geschwindigkeit (500x - 5000x)	I/O Geschwindigkeit (ca. 5x - 50x)
1978	1	1	1
1980	~10	~10	~10
1982	~100	~100	~10
1984	~1 000	~1 000	~10
1986	~10 000	~10 000	~10
1988	~100 000	~100 000	~10
1990	~1 000 000	~1 000 000	~10
1992	~10 000 000	~10 000 000	~10
1994	~100 000 000	~100 000 000	~10
1996	~1 000 000 000	~1 000 000 000	~10
1998	~10 000 000 000	~10 000 000 000	~10
2000	~100 000 000 000	~100 000 000 000	~10
2002	~1 000 000 000 000	~1 000 000 000 000	~10
2004	~10 000 000 000 000	~1 000 000 000 000	~50


brunner consulting RAID Performance Grundlagen 2



## Die wichtigsten Maßzahlen

Deutsch	Englisch	Einheit
<b>Bandbreite</b>	Bandwidth Data Rate / Throughput	<b>MB/sec</b>
Datenrate <b>Durchsatz</b> I/O Leistung	I/O Request Rate	<b>I/Os/sec</b>
<b>Mittlere Suchzeit</b>	Average Seek Time	<b>msec</b>
<b>Drehwartezeit</b> Latenzzeit	Rotational Latency	<b>msec</b>
<b>Mittlere Zugriffszeit</b> Mittlere Antwortzeit	Average Access Time Average Response Time	<b>msec</b>

brunner consulting
RAID Performance Grundlagen 3



## Bandbreite


*(Band Width) [MB/sec]*

**Beschreibt die Datenmenge, die pro Sekunde bewegt werden kann.**

**Meßverfahren:**

1. Geschwindigkeit, mit der die Leseköpfe die Information von der Oberfläche ablesen ( → „Peak Data Rate“)
  - ⇒ Nur elektrisch meßbar
  - ⇒ **Kein realistischer Performance-Indikator**
  
2. Geschwindigkeit, mit der die Daten bei „spiralförmigem Zugriff“ an der Schnittstelle das Laufwerk „verlassen“ ( → „Spiral Read Rate“)
  - ⇒ Gute Maßzahl für Datenrate
  - ⇒ Wichtiger Performance-Indikator für Anwendungen, die große Datenmengen in riesigen I/Os bewegen, z.B.
    - \* BACKUP/RESTORE
    - \* Bildverarbeitung
    - \* SEISMIK, Meteorologie
    - \* Also nur Spezialfälle...

brunner consulting
RAID Performance Grundlagen 4



## Durchsatz

( I/O Request Rate) [I/Os/sec]



**Beschreibt Anzahl der I/Os pro sec, NICHT die Geschwindigkeit eines I/O**


**Meßverfahren:**

1. Anzahl der I/O-Operationen, die nacheinander abgearbeitet werden können (1 oder mehrere Disks)
2. Anzahl der I/Os bei bestimmten Queue-Tiefen (z.B. 5)
3. Anzahl der I/Os bei mehreren (parallelen) Prozessen
4. Eine Mischung aus 2. und 3.

- Nur Verfahren 1 liefert eine Aussage über die Geschwindigkeit (= Antwortzeit) der einzelnen I/O-Operation
- Verfahren 2, 3 und 4 liefern „bessere“ Zahlen → dadurch beliebter
- Resultate von Verfahren 2, 3 und 4 nur aussagekräftig, wenn gleichzeitig weitere Angaben gemacht werden:
  - ↳ Mittlere Zugriffszeit
  - ↳ Queue Tiefe
  - ↳ Anzahl Dämon-Prozesse

brunner consulting RAID Performance Grundlagen 6





## Drehwartezeit

*(Rotational Latency) [msec]*

Zeit für 1/2 Umdrehung

- ⇒ Eindeutig
- ⇒ Direkt aus der Drehzahl abzuleiten

brunner consulting RAID Performance Grundlagen 9



## Mittlere Zugriffszeit

*(Average Access / Response Time) [msec]*

**Wie lange muß ich warten, um meinen I/O zurückzubekommen?**

**Meßverfahren:**

1. Mittlere Suchzeit + Drehwartezeit
2. Wie 1 + Transferzeit für 1 Block
3. Über Benchmark, abhängig von
  - ⇒ Betriebssystem
  - ⇒ Last
  - ⇒ Queueing
  - ⇒ Hardware
  - ⇒ I/O-Größen



} **unseriös, aber weit verbreitet**

} **beschreibt I/O-Geschwindigkeit der Gesamtkonfiguration**

**Probleme:**

- ⇒ Ändert sich mit der Last auf verschiedenen Komponenten
- ⇒ Asynchroner I/O

brunner consulting RAID Performance Grundlagen 10






## Achtung:

Die in der Fachpresse verbreiteten I/O Benchmarks prüfen meistens:

- ⇒ „Maximum Load“  
oder
- ⇒ „Maximum Bandwidth“  
...aber nur sehr selten
- ⇒ Service Time / Response Time

brunner consulting RAID Performance Grundlagen 13



## Dazu Tipps aus der Praxis

- Bandbreiten [MB/sec] sind in interaktiven Environments meist **unerheblich**.
- Disk Drive Response Zeiten [msec] sind meist der **wichtigste** Performance-Faktor.
  - ⇒ Ausnahmen: Große LOBs, Full Table Scans, etc.
- Der **Geschwindigkeitsverlust von IO-Serving** über Netzwerke (NAS!) wird häufig unterschätzt.
  - ⇒ Etwa 50% Erhöhung der Drive Response Time bei einwandfreiem Netzwerk können noch normal sein.
- Drives/Controller mit **eingebauten HW-Caches** bieten meist **erhebliche** Performance-Vorteile.

brunner consulting RAID Performance Grundlagen 14

## Queueing Theorie

Utilization = Service Time \* Demand

Queue = Utilization / ( 1 - Utilization )


Response Time = Service Time \* ( 1 + Queue)

brunner consulting RAID Performance Grundlagen 15

## Beispiel

Disk	Demand	Service Time	Utilization	Queue	Response Time
RZ26	30 IO/sec	20 ms	60 %	1,5	50 ms
RZ28	30 IO/sec	15 ms	45 %	0,81	27 ms
18GB	50 IO/sec	10 ms	50 %	1,00	20 ms
36GB	50 IO/sec	9 ms	45 %	0,81	16,3 ms
72GB	50 IO/sec	8 ms	40 %	0,67	13,3 ms
Formeln	D	S	$U = S * D$	$Q = U / (1 - U)$	$R = S(1 + Q)$

brunner consulting RAID Performance Grundlagen 16




### Schlußfolgerungen

Typischerweise wird die Zugriffszeit lange, bevor das Speichersystem die maximale Belastung erreicht hat, inakzeptabel.

**Normalerweise verdoppelt sich die Mittlere Zugriffszeit bereits bei ca. 50% der maximalen Last.**


brunner consulting RAID Performance Grundlagen 18




# Caching

brunner consulting

RAID Performance Grundlagen 19






- ### Einsatzmöglichkeiten
- I/O Vermeidung
  - I/O Beschleunigung
  - Werden wegen fallender Memory-Preise immer interessanter und sind inzwischen (fast) überall im Einsatz
  - Bei "Shared Devices" sollte auf der Hardware-Ebene "gecached" werden!
  - Nutzen häufig schwer bezifferbar
- brunner consulting RAID Performance Grundlagen 22



## Performance


- Performance-Gewinne über I/O-Vermeidung
- Meist "Write-Through" Caches, daher Nutzen nur bei READs
- I/O Response Time sinkt um Faktor 10 - 100 (CPU-abhängig)
- I/O-Kanal wird überhaupt nicht benutzt
- Statt dessen Memory → Memory Kopie
  - ⇒ Also **nicht** zu empfehlen bei überlasteter CPU! (Auch nicht, wenn Memory frei ist)

brunner consultingRAID Performance Grundlagen 23




## Hardware Caches

Write-Through



Auch "Read Cache" genannt

Write-Back



Auch "Write Cache" genannt

brunner consultingRAID Performance Grundlagen 24



## Hardware Caches


- **Write Through**
  - ⇒ Kein Geschwindigkeitsgewinn beim Schreiben
  - ⇒ Immer konsistente Daten auf der Disk
- **Write Back**
  - ⇒ Writes in 0,1 – 1,0 msec !!!
  - ⇒ Konsistenz nur über Batterie-Pufferung “einigermaßen” zu gewährleisten!
  - ⇒ Besonders geeignet, um das “Write Performance Hole” bei RAID3 und RAID5 Arrays zu beheben.

brunner consulting RAID Performance Grundlagen 25



## Controller Read Cache

- Vom Host angeforderte Daten werden aus der Cache gelesen (“cache hit”)
- Performance Vorteile
  - ⇒ Schnellere Antwortzeit
  - ⇒ Geringere Device und Device-Bus Utilization
- Cache-Strategie
  - ⇒ “zuletzt benutzt” = LRU optimiert Transaktions-I/Os
  - ⇒ “read-ahead” optimiert große I/Os




The diagram illustrates the data flow in a controller read cache. A 'System' (light blue box) sends a request to a 'Controller' (yellow box). The Controller is connected to a 'Cache' (pink box) and a disk (yellow cylinder). A red arrow points from the Controller to the Cache. A blue arrow labeled 'Read Cache Hit' loops from the Cache back to the System. A blue arrow labeled 'Read Cache Miss' loops from the Controller to the disk and back to the Controller.

brunner consulting RAID Performance Grundlagen 26



## Write Back Cache


- Verhalten wie Read-Cache, plus:
- Host schreibt Daten direkt in die Cache
- Sofortige Rückmeldung an Host
- Daten werden später auf Platte geschrieben
- Performance
  - ⇒ Schnellere Antwortzeit
  - ⇒ Verbessertes RAID WRITE
  - ⇒ Geringere Device und Device-Bus Utilization
- Optimierte Transaktions- und große I/Os
- Daten-Integrität sichern!!!



The diagram illustrates the Write Back Cache architecture. It shows a flow from System Memory to a Cache, and then to a storage device. A dashed arrow labeled 'READY' points from the Cache back to System Memory, indicating immediate acknowledgment. A solid arrow labeled 'W' points from System Memory to the Cache. Another solid arrow labeled 'W (verzögert)' points from the Cache to the storage device, indicating a delayed write. The Cache is labeled 'Cache' and 'Battery Backup'.

brunner consulting

RAID Performance Grundlagen 27



## RAID

RAID

brunner consulting


RAID Performance Grundlagen 28



## Motivationen für RAID

- \* Daten-Sicherheit
- \* Verfügbarkeit
- \* Disaster-Toleranz
- \* Performance
- \* Management / Handling
- \* Kosten-Reduktion

brunner consulting RAID Performance Grundlagen 29



## Auswahl aus folgenden Optionen

- ⇒ Host Based Shadowing
- ⇒ Host Based Striping
- ⇒ Controller Based Mirroring
- ⇒ Controller Based Striping
- ⇒ Controller Based Parity RAID
  
- ⇒ Controller Read Caching
- ⇒ Controller Write-Back Caching
- ⇒ Host Based Caching

brunner consulting RAID Performance Grundlagen 30

## Eine Kombination aller Marketing-Folien aller RAID-Anbieter

⇒ JBOD	okay
⇒ RAID 0	gut
⇒ RAID 0+1	sehr gut
⇒ RAID 3	exzellent
⇒ RAID 5	wundervoll
⇒ Our RAID 77++	hervorragend!

brunner consulting
RAID Performance Grundlagen 31

## RAID 0

Beispiel: Chunk Size = 10 Sectors  
Track Size = 100 Sectors


brunner consulting
RAID Performance Grundlagen 32



## RAID 1

Shadowing/Mirroring - Daten werden "gespiegelt"

- Vorteile:
  - ⇒ Hohe Sicherheit
  - ⇒ Performance-Gewinn bei Lesezugriffen
  - ⇒ **Wenig** Performance-Verlust beim Schreiben
- Nachteil:
  - ⇒ Teuer



brunner consulting

RAID Performance Grundlagen 33




## RAID 3

Beispiel: Chunk Size = 1 Sector  
Track Size = 100 Sectors



Physikalisch

Logisch



brunner consulting

RAID Performance Grundlagen 34



## Parallele Reads

Annahme: Array mit 6 Disks

Queue	Wahrscheinlichkeit paralleler Operationen	
1	1	1
2	$1 + 5/6$	1,83
3	$1 + 5/6 + 4/6 = 15/6$	2,5
4	$1 + 5/6 + 4/6 + 3/6 = 18/6$	3,0
5	$1 + 5/6 + 4/6 + 3/6 + 2/6 = 20/6$	3,33
6	$1 + 5/6 + 4/6 + 3/6 + 2/6 + 1/6 = 21/6$	3,5
$\infty$		6

brunner consulting
RAID Performance Grundlagen 37

## Parity RAID: Read - Modify - Write



**Read:**  
pro Disk: 10 msec  
**beide:** ~ 12 msec

**Modify:**  
"keine Zeit"  
(während Warten auf WRITE)

**Write:** Wartet eine volle Umdrehung  
pro Disk 4,33 msec  
XFER 0,5 msec  
Overhd. 0,1 msec  
**total:** ~ 5 msec

17ms

brunner consulting
RAID Performance Grundlagen 38



### Wahrscheinlichkeit gleichzeitiger Operationen

Disks im Array	Gleichzeitige R-M-W Zyklen	Gleichzeitige Reads
2	1,0	1,5
3	1,0	2,0
4	1,166	2,5
5	1,30	3,0
6	1,46	3,5

brunner consulting
RAID Performance Grundlagen 41

### Was lernen wir daraus? (1)

Resp **READ** = 10 msec → 100 Ops/sec

**Wenn wir ein Array mit 6 Disks haben:**

Resp **READ** ≥ 10 msec → 3,5 \* 100 Ops/sec

(Erforderliche Queue = 6) → ~ 350 Ops/sec

brunner consulting
RAID Performance Grundlagen 42



### Was lernen wir daraus? (2)


Resp **R-M-W** = 17 msec → 58 Ops/sec

Wenn wir ein Array mit 6 Disks haben :

Resp **WRITE** ≥ 17 msec → 1.46 \* 58 Ops/sec

(Erforderliche Queue = 3) → ~ 86 Ops/sec

brunner consulting RAID Performance Grundlagen 43



### Was lernen wir? (3)

...aber wenn wir keine Queue haben?

100 **READS** @ 10 msec

oder 58 **WRITES** @ 17 msec

... oder irgend etwas dazwischen ...

brunner consulting RAID Performance Grundlagen 44

### Performance der RAID Levels

	Transaktions-I/O		Large File I/O	
	Read	Write	Read	Write
JBOD	OK	OK	OK	OK
RAID 0 (Strip)	Sehr gut	Sehr gut	Gut	Gut
RAID 1 (Shad)	Gut	OK	OK	OK
RAID 0+1	Exzellent	Sehr gut	Gut	OK
RAID 3	Schlecht	Schlecht	Sehr gut	Sehr gut
RAID 4	Sehr gut	Sehr Schlecht	Sehr gut	OK
RAID 5	Sehr gut	Schlecht	OK	OK
RAID 6	Exzellent	Sehr Schlecht	Sehr gut	OK

brunner consulting
RAID Performance Grundlagen 45

- ### Vorteile dieser Tabelle?
- ⇒ Sie beschreibt Stärken und Schwächen der RAID Level
  - ⇒ Sie unterscheidet zwischen
    - \* Transaktions-I/O (klein, häufig, zufällig, Queues, Antwortzeit-orientiert) und
    - \* Großen Files / Stream I/O (große, sequentielle, Bandbreiten-orientierte)
- +
- brunner consulting
RAID Performance Grundlagen 46




## Nachteile der Tabelle?

- ⇒ Sie beschreibt **theoretisches Verhalten** des RAID Mapping Algorithmus
- ⇒ Sie ignoriert CACHES

aber ... heute... 

- ⇒ **alle** RAID-Anbieter benutzen WRITE CACHES, um die "schlechte" und "sehr schlechte" Performance des PARITY RAID bei Transaktions-Writes zu umgehen

brunner consulting RAID Performance Grundlagen 47



## Impact of Read and Write Caches

	XACTION I/O (Small)		Large File I/O	
	Read	Write	Read	Write
JBOD	OK	Sehr gut	OK	Gut
RAID 0 (Strip)	Sehr gut	Exzellent	Gut	Sehr gut
RAID 1 (Shad)	Gut	Sehr gut	OK	Gut
RAID 0+1	Exzellent	Exzellent	Gut	Sehr gut
RAID 3	Schlecht	Gut	Sehr gut	Exzellent
RAID 4	Sehr gut	Gut	Sehr gut	Gut
RAID 5	Sehr gut	Sehr gut	OK	Gut
RAID 6	Exzellent	Sehr gut	Sehr gut	Gut

brunner consulting RAID Performance Grundlagen 48

## Wichtige Faktoren der RAID Performance

- **Parallelität** in der Anwendung
  - ⇒ Mehrere parallele I/Os?
  - ⇒ Synchrone/Asynchrone I/Os?
- **Read/Write-Rate** der Anwendung
- **Read-Update-Zyklen** in Anwendung helfen Parity-RAID-Controllern, die READ-MODIFY-WRITE Operationen zu optimieren
- **I/O-“Muster“**
  - ⇒ Hat die Read-Cache eine ernsthafte Chance, hohe HIT-Raten zu erreichen?
- **Cache-Implementation**

brunner consulting RAID Performance Grundlagen 49

## Write Cache und RAID

- Schreiben zu einem RAID-System
  - 1 Daten vom Host holen
  - 2 Lesen vom alten BLOCK 07 und Daten prüfen
  - 3 Berechnen vom alten BLOCK 07 XOR alte Parity-Daten XOR neuer BLOCK 07
  - 4 Schreiben vom neuen BLOCK 07
  - 5 Schreiben der neuen Parity-Daten
- Schritte 2, 3, 4, and 5 können der „Fertig“-Meldung folgen


brunner consulting RAID Performance Grundlagen 50



## Cache und RAID

- Read Cache
  - ⇒ Vorteile wie bei einzelnen Disks plus:
  - ⇒ Hits auf „alter“ Parity-Information kann Overhead-Reads bei Write-Vorgängen sparen
- Write Cache
  - Der größte Effekt, das größte Risiko
  - ⇒ Neue Daten und neue Parity kann gecached werden
  - ⇒ „Untrustworthy Parity“ Flags können gecached werden
  - ⇒ Resultat: Zeit für virtuelles Disk WRITE ~ Zeit für physikalisches Disk WRITE

brunner consulting RAID Performance Grundlagen 51



## „Daumen x $\pi$ “-Regeln

### Erwartungen

- Erhoffen sie sich keine / nur geringe Performance-Gewinne von RAID (0, 1, 0+1, 5), wenn Sie **ohne** RAID keine I/O-Queues beobachten können.
  - ⇒ Wenn Sie dennoch große Performance-Gewinne erzielen:
    - \* Herzlichen Glückwunsch!
    - \* Kommen sie aber nicht einfach von der Write-Cache?
    - \* Oder ganz grundsätzlich von der neueren Technologie?


brunner consulting RAID Performance Grundlagen 52




## Planen Sie genau und gründlich!

- Entscheidungen für ein bestimmtes RAID-Verfahren sind häufig “unumkehrbarer” als Sie vorab denken würden...
  - ⇒ Backup - Restore von riesigen Arrays macht man nicht so gerne / oft.
  - ⇒ Der berühmte **“Wo geht's hier zum Bahnhof bitte?”** -Effekt schlägt erbarmungslos zu.
  - ⇒ Erklären Sie mal Ihrem Chef, daß Sie jetzt noch die Host-Based Shadowing Lizenzen nachkaufen müssen, weil es die RAID5-Option nicht gebracht hat.

brunner consulting RAID Performance Grundlagen 53



## Welches RAID?



```

            graph TD
            Q1{Räuml. Trennung erforderlich?} -- ja --> HB[Host-Based Shadowing]
            Q1 -- nein --> M[Mirroring]
            Q1 -- nein --> R5[RAID5]
            
            Q2{tiefe I/O Queues?} -- ja --> S[Striping]
            Q2 -- ja --> R5[RAID5]
            Q2 -- nein --> E[Einzeldisks]
            Q2 -- nein --> HBC[Host-Based Caching]
            
            Q3{Viele Writes (> 30%)?} -- ja --> WBC[Write-Back Cache]
            Q3 -- ja --> S[Striping]
            Q3 -- nein --> R5[RAID5]
            
            Q4{I/O Demand} -- Durchsatzorientiert [IO/sec] --> S[Striping]
            Q4 -- Durchsatzorientiert [IO/sec] --> R5[RAID5]
            Q4 -- Bandbreitenorientiert [MB/sec] --> U[Ultra-SCSI Oder FC!]
            Q4 -- Bandbreitenorientiert [MB/sec] --> R5[RAID5]
            
```

brunner consulting RAID Performance Grundlagen 54