# MySQL Replikation, Scale-Out, Master-Master Replikation, Backup

## DOAG Regioaltreffen, München
## 23. März 2011


## Oli Sennhauser

**Senior MySQL Consultant, FromDual GmbH**

**oli.sennhauser@fromdual.com**


# Inhalt

## MySQL Replikation

- Scale-Out
- MySQL Replikation
- Master-Master Replikation
- Binary Log Formate
- Semi-Synchrone Replikation
- Backup Methoden
- Restore
- SE Replikation mit PBXT

# Über FromDual GmbH

- **Wir bieten an:**
  - **Neutrale und Hersteller unabhängige Beratung für MySQL**
  - **Support für MySQL (7 x 24)**
  - **Remote-DBA / MySQL Betrieb (wir betreiben Ihre MySQL DB!)**
  - **Schulung und Workshops (DBA, Performance Tuning, Scale-Out, High Availability, MySQL Cluster)**
- **Wir sind:**
  - **Consulting Partner der Open Database Alliance (ODBA.org)**
  - **Oracle Silber Partner (OPN)**

**http://www.fromdual.com**

# Zuerst gab's da mal ein Problem:

- Kosten
- MySQL Design
- Physikalische Flaschenhälse
- „Relaxation of Constraints“

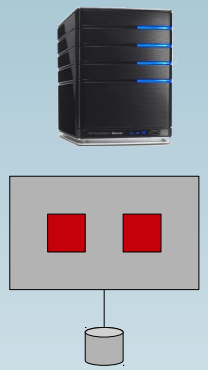

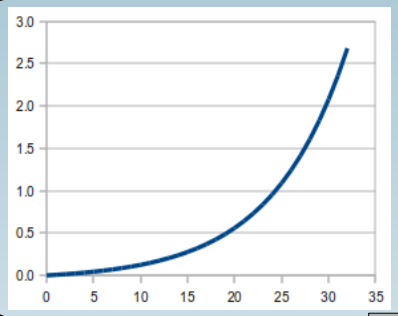


## Scale-Up

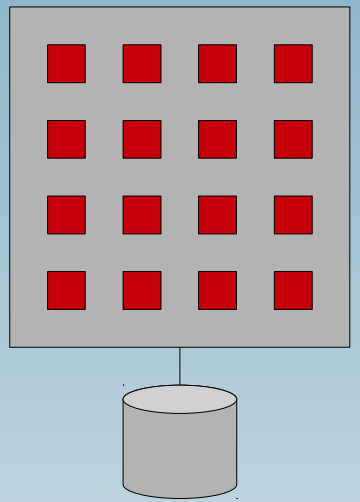

- Web-Applikationen typischerweise:
  r >> w

## Scale-Out

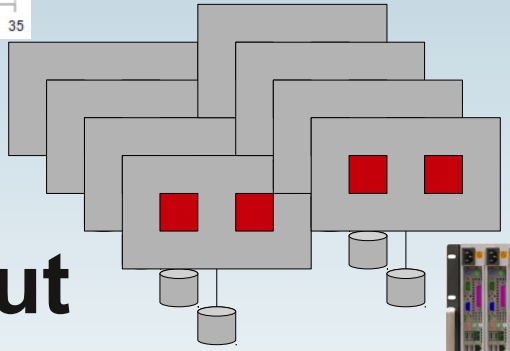

# Der MySQL Scale-Out Ansatz

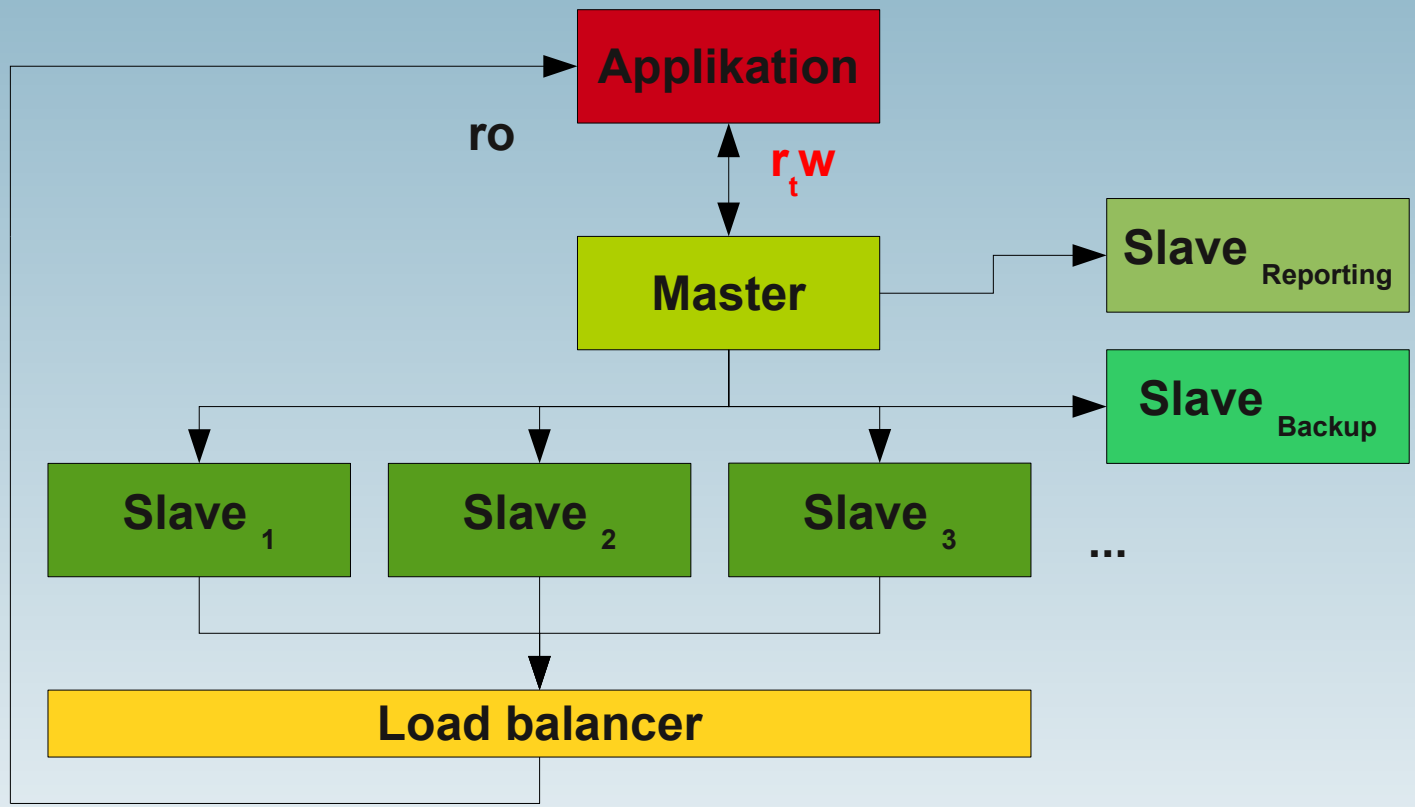


**Web-Applikationen typischerweise:**

**r >> w**

# Master – Slave Replikation

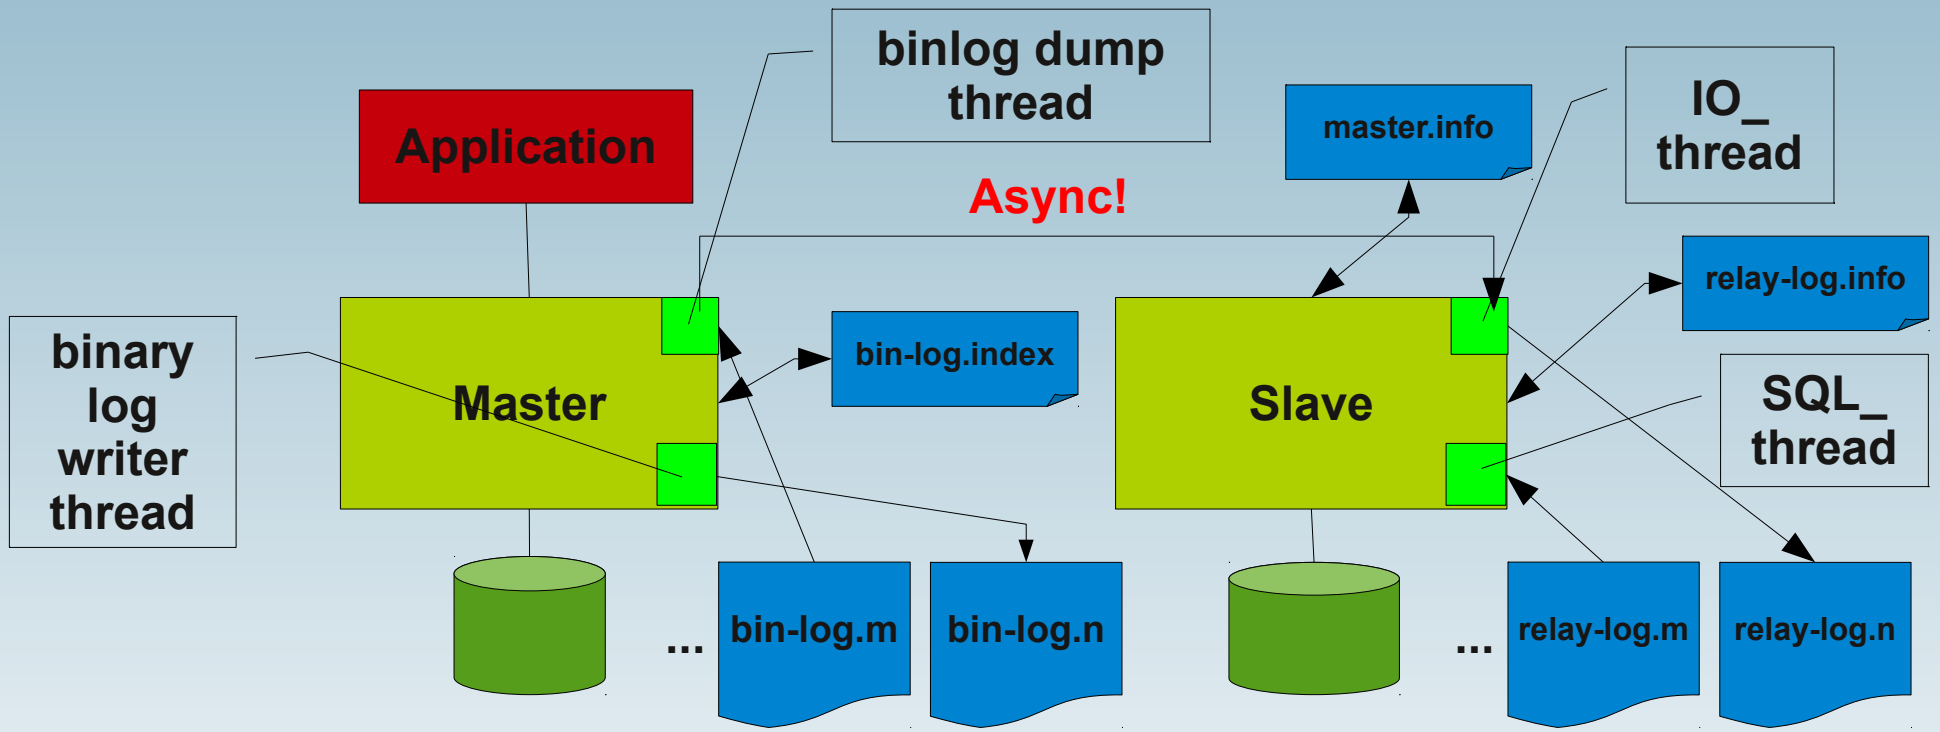

# Erstellen eines Masters

- Binary Log einschalten und Server ID setzen (erfordert Neutstart):

```
# my.cnf
[mysqld]
log_bin   = binary_log
server_id = 42
```

- User mit `REPLICATION SLAVE` Privileg anlegen:

```
CREATE USER replication@'%' IDENTIFIED BY 'secret';
GRANT REPLICATION SLAVE ON *.* TO replication@'%';
```

- Konsistentes Backup vom Master erstellen:

```
mysqldump --all-databases {--single-transaction | --lock-
all-tables} --master-data > full_dump.sql
```

- MySQL Dokumentation: How to Set Up Replication

  http://dev.mysql.com/doc/refman/5.5/en/replication-howto.html

# Erstellen eines Slaves

- `Server_id` in `my.cnf` setzen
- Dem Slave zeigen, wo sein Master sitzt:
  - `CHANGE MASTER TO master_host='masterserver', master_port=3306, master_user='replication', master_password='secret'`
- Einspielen des konsistenten Backups vom Master:

```
mysql -u root < full_dump.sql
```

- Überprüfen ob auf dem Slave alles i.O. ist:

```
SHOW SLAVE STATUS\G
```

- Slave starten:

```
START SLAVE;
```

# Für was kann man Slaves alles brauchen?

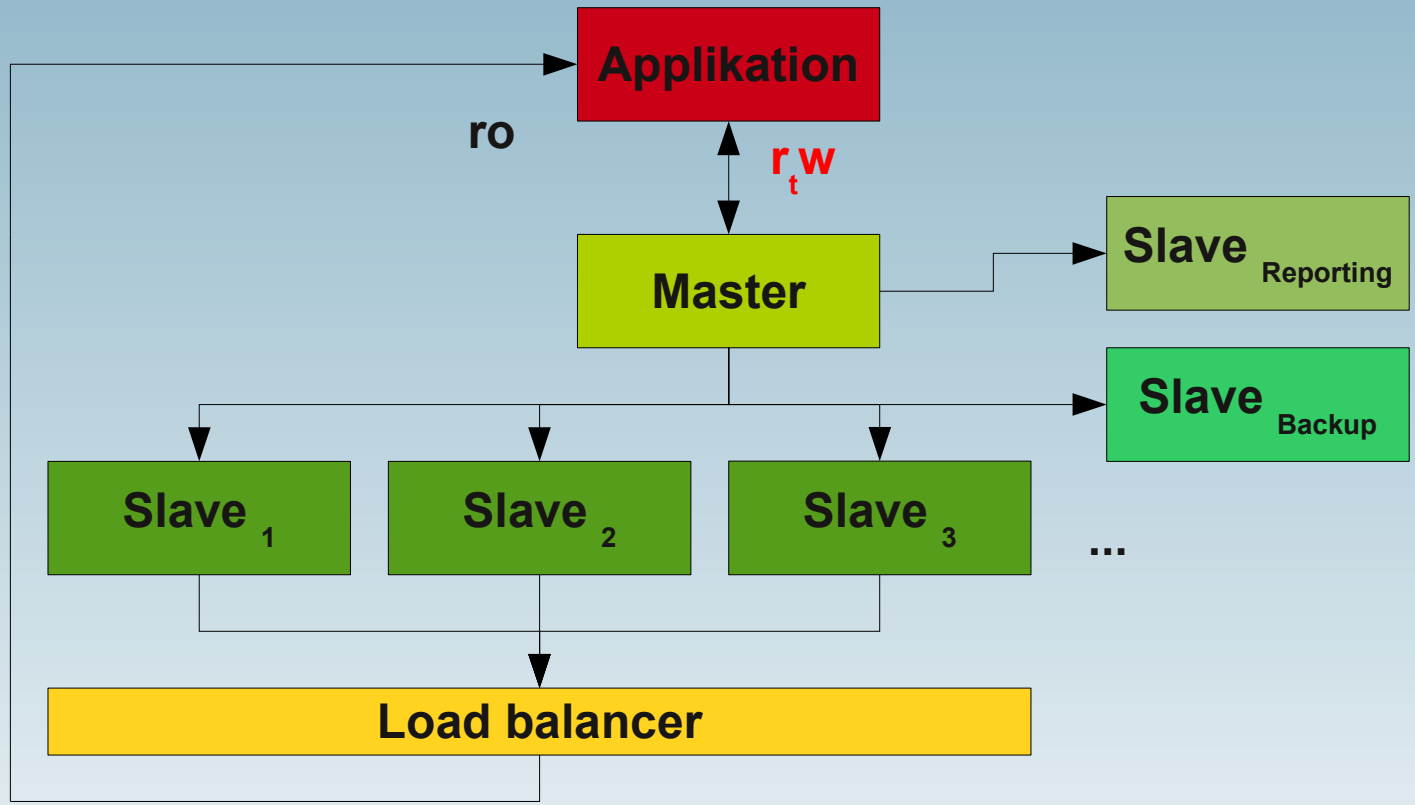


**Web-Applikationen typischerweise:**

**r >> w**

# Massives Scale-Out

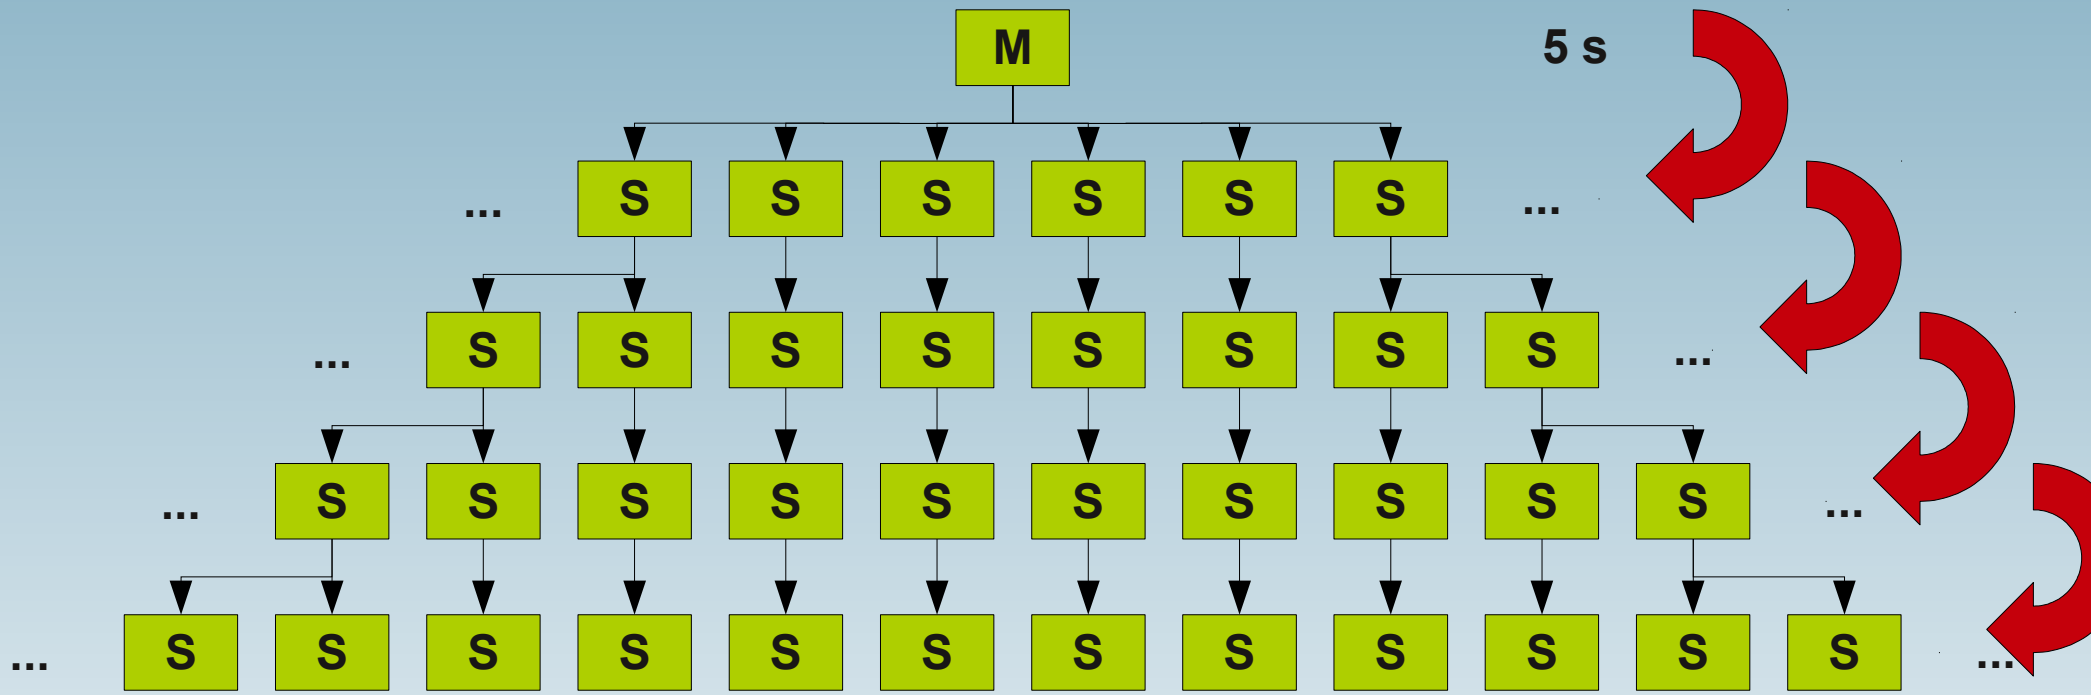


- **Jetzt können sie auch erahnen wozu die BLACKHOLE SE gebraucht wird...**

# Tool zur Verwaltung solcher Set-up's

- Problem: Wenn Master kaputt geht, müssen alle Slaves neu gebaut werden...
- Aber es gibt Tricks:
- Tool von Yandex.ru (Petya Kohts):
  - mmmf, multi-master mysql failover
  - http://www.nigilist.ru/nit/mmmf/
  - http://cpan.uwinnipeg.ca/~kohts/mmmf

# Master – Master Replikation

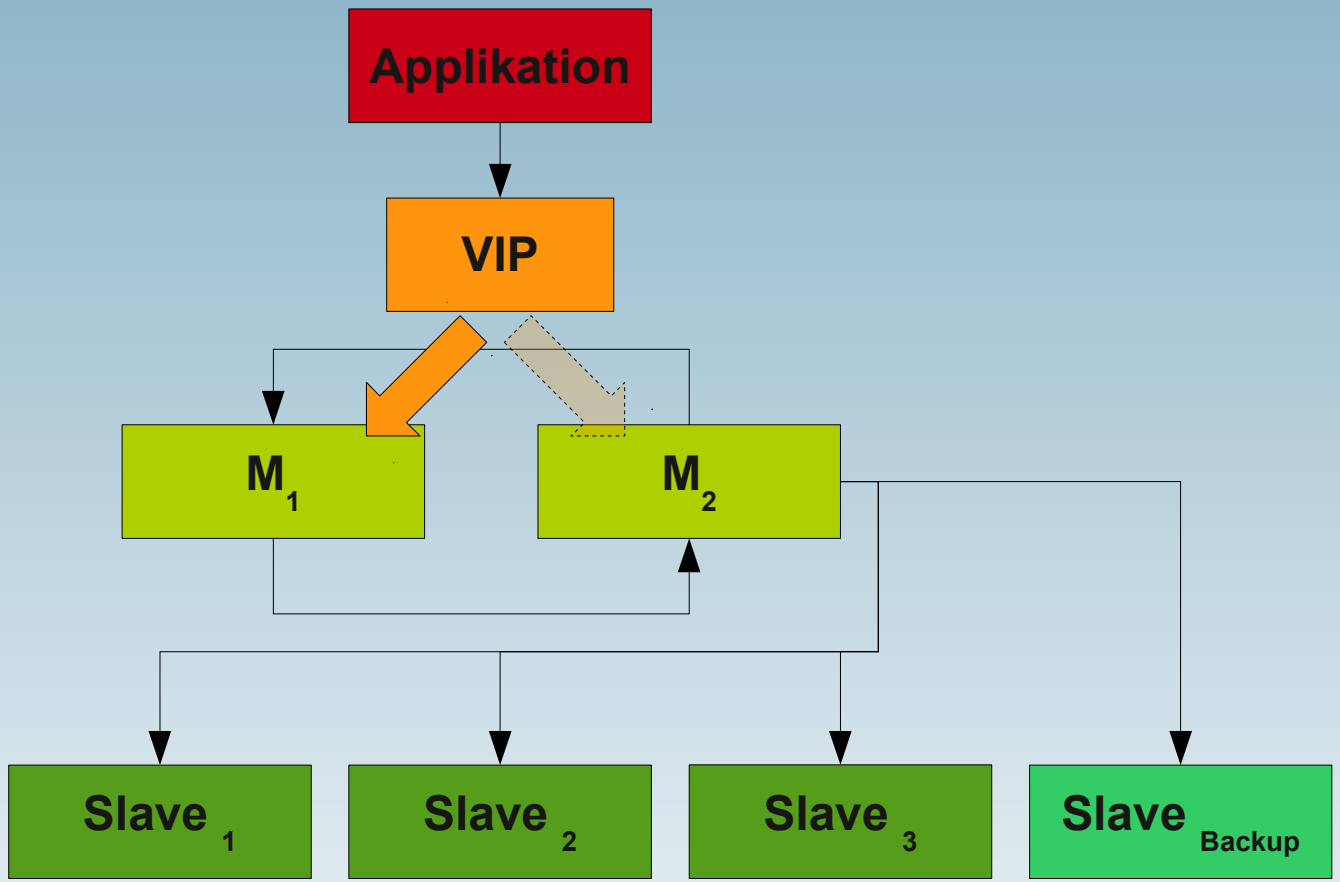


- **Vorsicht beim Schreiben auf beide Master**
- **Man erhält so NICHT mehr I/O-Durchsatz!**

# Tool zur Verwaltung solcher Set-up's

- Ähnliches Problem wie bei Master-Slave Replikation mit zusätzlicher Komplexität durch zirkuläre Replikation
- Keine Konflikt-Detektion/Auflösung!
- Achtung: Wir sind asynchron!
- Tool:
  - Multi-Master Replication Manager for MySQL
  - http://mysql-mmm.org/
  - https://launchpad.net/mysql-mmm

# Binary Log Formate

- **Bis MySQL 5.0 nur Statement Based Replikation (SBR)**
  - **+ Weniger Traffic**
  - **- Non-determistic Queries!**
  - **- Mehr Locking (grössere Locks)**

```
# at 786
#110321 20:55:40 server id 35154  end_log_pos 814       Intvar
SET INSERT_ID=3/*!*/;
# at 814
#110321 20:55:40 server id 35154  end_log_pos 944       Query   thread_id=3     exec_time=0     error_code=0
SET TIMESTAMP=1300737340/*!*/;
INSERT INTO test VALUES (NULL, 'Statement based replikation', NULL)
```

# Binary Log Formate

- Ab MySQL 5.1 auch Row Based Replication (RBR)
  - + All Änderungen können nun repliziert werden.
  - + Weniger Locking / manchmal schneller
  - - Binary Log ist weniger transparent / mehr Traffic
- Mixed (SBR default, wechselt auf RBR b. Bed.)

```
# at 844
#110321 20:57:36 server id 35154  end_log_pos 912       Query   thread_id=2     exec_time=0     error_code=0
SET TIMESTAMP=1300737456/*!*/;
BEGIN
/*!*/;
# at 912
# at 959
#110321 20:57:36 server id 35154  end_log_pos 959       Table_map: `test`.`test` mapped to number 15
#110321 20:57:36 server id 35154  end_log_pos 1019      Write_rows: table id 15 flags: STMT_END_F
BINLOG 'sK2HTRNSiQAALwAAAL8DAAAAAA8AAAAAAAEABHRlc3QABHRlc3QAAwMPBwJAAAI=
sK2HTRdSiQAAPAAAAPsDAAAAAA8AAAAAAAEAA//4BwAAABVSb3cgYmFzZWQgcmVwbGlrYXRpb26w
RydN'/*!*/;

mysqlbinlog --base64-output=decode-rows --verbose bin-log.000002
```

# Semi-Synchrone Replikation

- Bis 5.1 nur asynchrone Replikation!
- Ab 5.5 auch semi-synchrone Replikation:

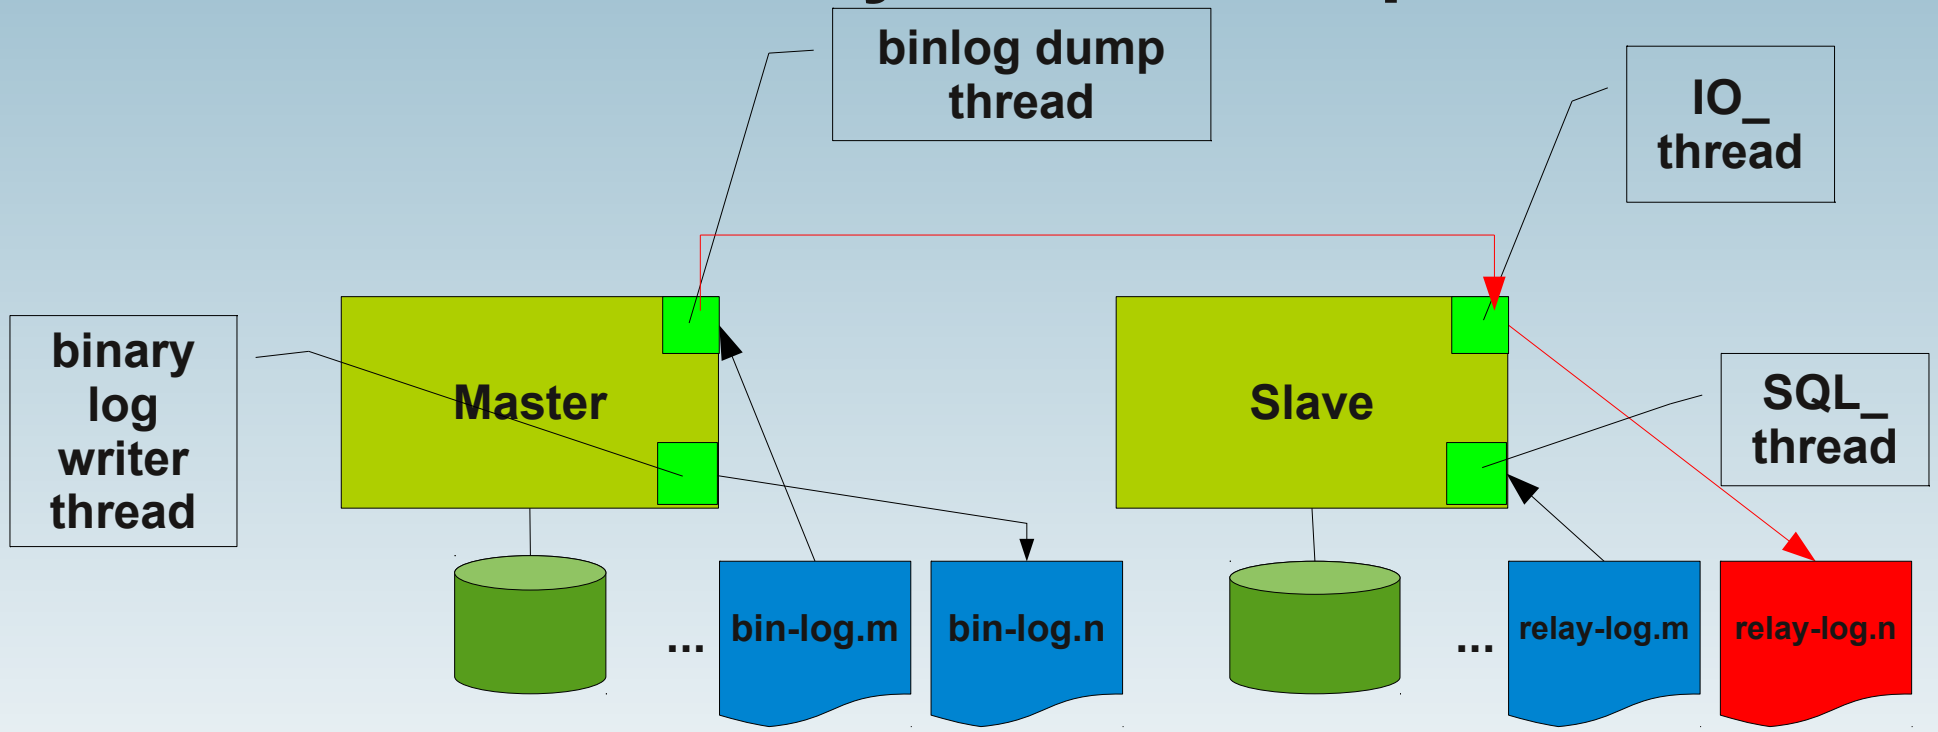

# Backup Methoden

# Backup Methoden

- `mysqldump`
- Filesystem Kopie / `mysqlhotcopy`
- Snapshot mit LVM / btrfs
- InnoDB Hot Backup (ibbackup/xtrabackup)
- Backup Replikation Slave

# mysqldump

- Charakteristik
  - Logisches Backup, hot/on-line, lokal oder remote, konsistent
- Vorteile
  - Einfach, lokal oder remote, Standard-Backup für MySQL, konsistent, Strukturdump möglich
- Nachteile
  - Kann falsch gemacht werden, blockiert MyISAM Tabellen fürs Schreiben, nicht geeignet für sehr grosse Datenmengen, Restore-Zeiten!

# Filesystem Kopie / `mysqlhotcopy`

- Charakteristik
  - Physisches Backup, hot, local
- Vorteile
  - Schneller Restore, konsistent
- Nachteile
  - Nur bedingt für InnoDB geeignet, blockiert Tabellen für Schreibzugriffe.

# Snapshot mit LVM / btrfs

- Charakteristik
  - Physisches Backup, hot, lokal
- Vorteile
  - Sehr schnelle Backup Methode, ziemlich schnelles Restore, konsistent
- Nachteile
  - Benötigt root Rechte, etwas komplizierter und Hardware intensiver, möglicherweise gefährlich mit InnoDB?

# Wie wird ein LVM Snapshopt Backup gemacht?

- Alle DB files müssen auf dem selben Logical Volume liegen (LV = Partition)
- Locken der Datenbank
- Erstellen eines Snapshots des Logical Volumes
- Unlocken der Datenbank
- Mounten des Snapshot Logical Volumes
- InnoDB Recovery testen
- Backup (tar, compress, tape) der Datenbank Files
- Löschen des Snapshot Logical Volumes

→ Etwas kompliziert: mylvmsnapshot

# Wie funktionieren LVM Snapshots?

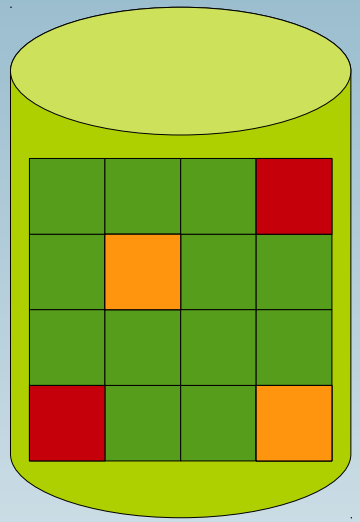

LVM device

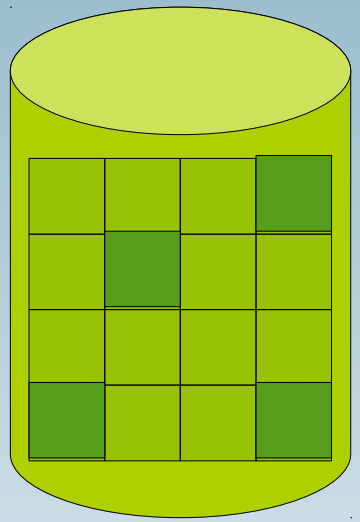

LVM snap-shot device

copy-on-write

# InnoDB Hot backup (ibbackup, xtrabackup)

- Charakteristik
  - Physisches Backup, hot/on-line, lokal, konsistent, inkremental
- Vorteile
  - Schnelles Backup/Restore für InnoDB
- Nachteile
  - Löst die MyISAM Probleme nicht

# Backup mit OEB/XtraBackup

- Volles Backup erstellen:

```
xtrabackup --backup --target-dir=...
```

- Prepare (~recovery):
  - `xtrabackup --prepare --target-dir=...`

- Restore?
  - Einfach MySQL auf den Files wieder starten...

# Backup Replikation Slave

- Charakteristik
  - Logisches oder physisches backup, hot/on-line, konsitent
- Vorteile
  - Betrifft Master überhaupt nicht. „Beste“ Methode aus Sicht des Masters.
- Nachteile
  - Braucht zusätzliche Hardware (oder zumindest Ressourcen)
  - Sicherstellen, dass Slave nicht driftet.
  - Achtung: Wir erstellen ein Backup auf dem Slave: != Master

# Restore / Recovery

# Restore / Recovery

- Restore / Recovery besteht aus bis zu 3 verschiedenen Schritten:
  - Restore der Daten oder der Tabellen oder den Files
  - Auto-recovery der transaktionalen SE (InnoDB, PBXT, NDB)
  - Point-in-Time-Recovery (PITR)
- Schritt 1 und 2 sind klar?
- Was ist PITR?

# Point-in-Time-Recovery (PITR)

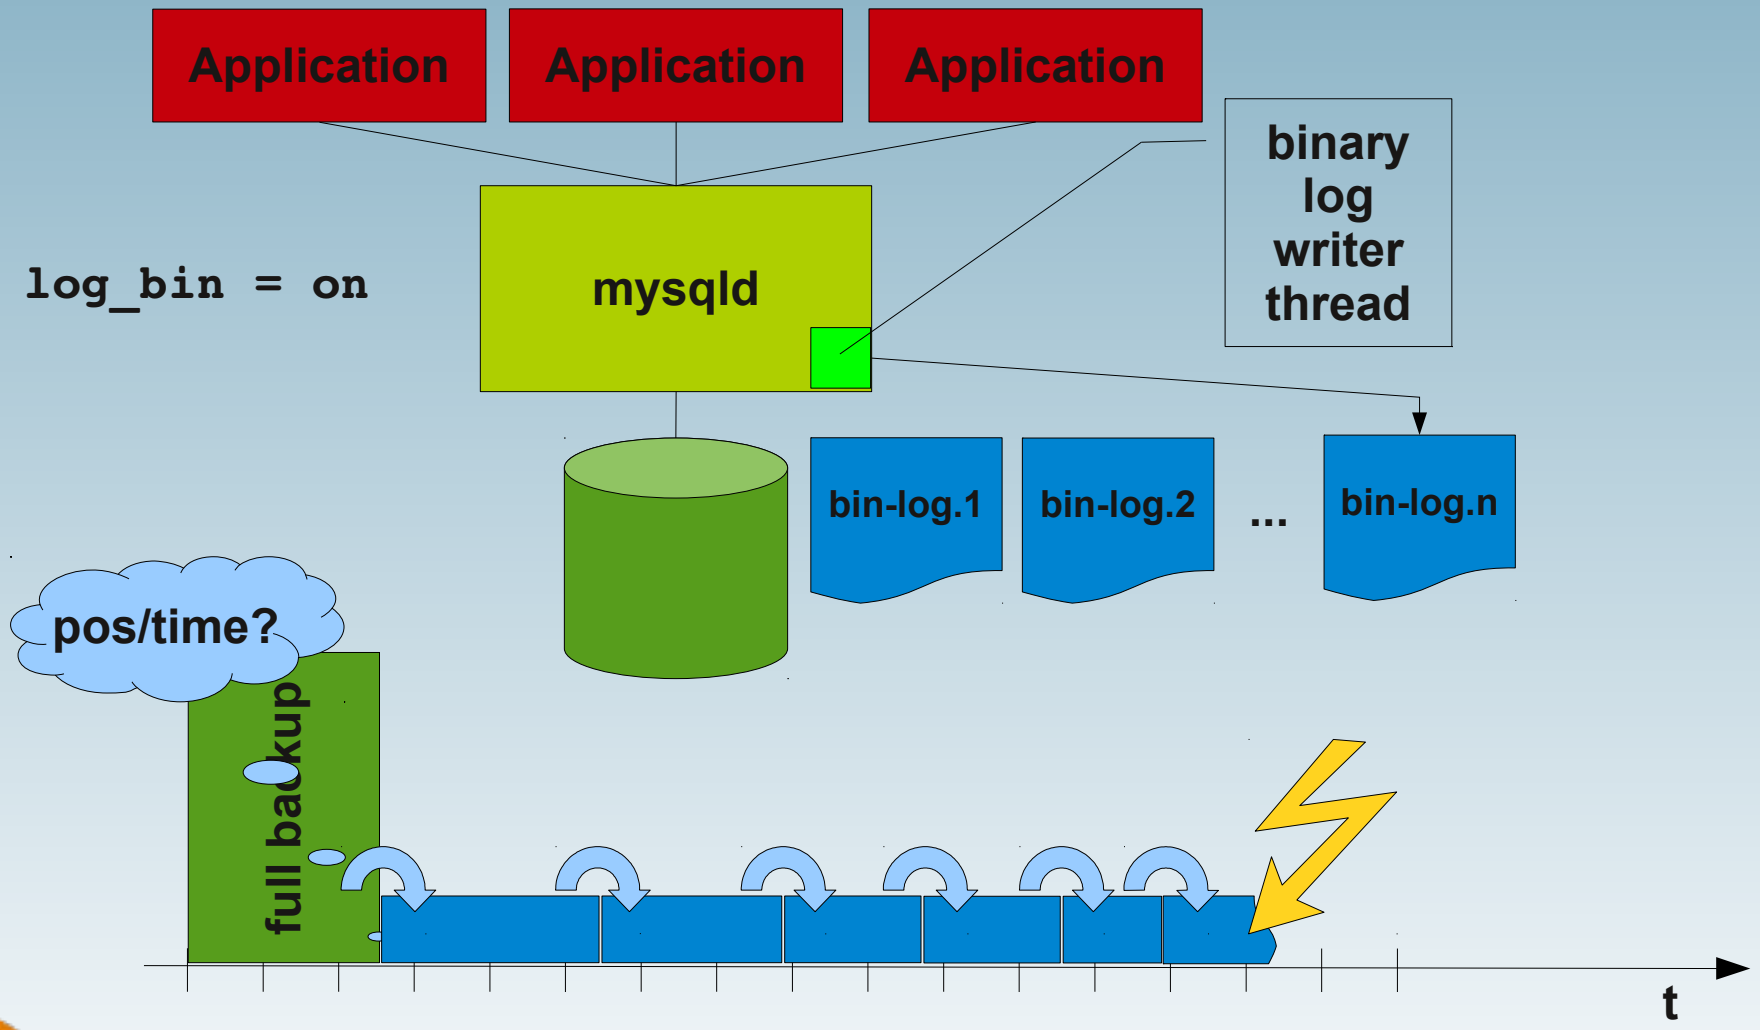

# Warum ein Restore getested werden sollte?

- Restore können sehr sehr lange dauern.....
  - Überprüfen Sie Ihre MTTR!
- Warum dauert der Restore eines logischen Backups so lange?

  → Restore Tabelle, Create Index → random I/O
  - So lange Ihr Index in den Cache/Buffer passt ist es OK, aber wehe wenn nicht...!
  - Man kann da etwas drum herum schummeln mit Fast Index Creation im InnoDB Plug-in oder MySQL 5.5...

# Justify your restore

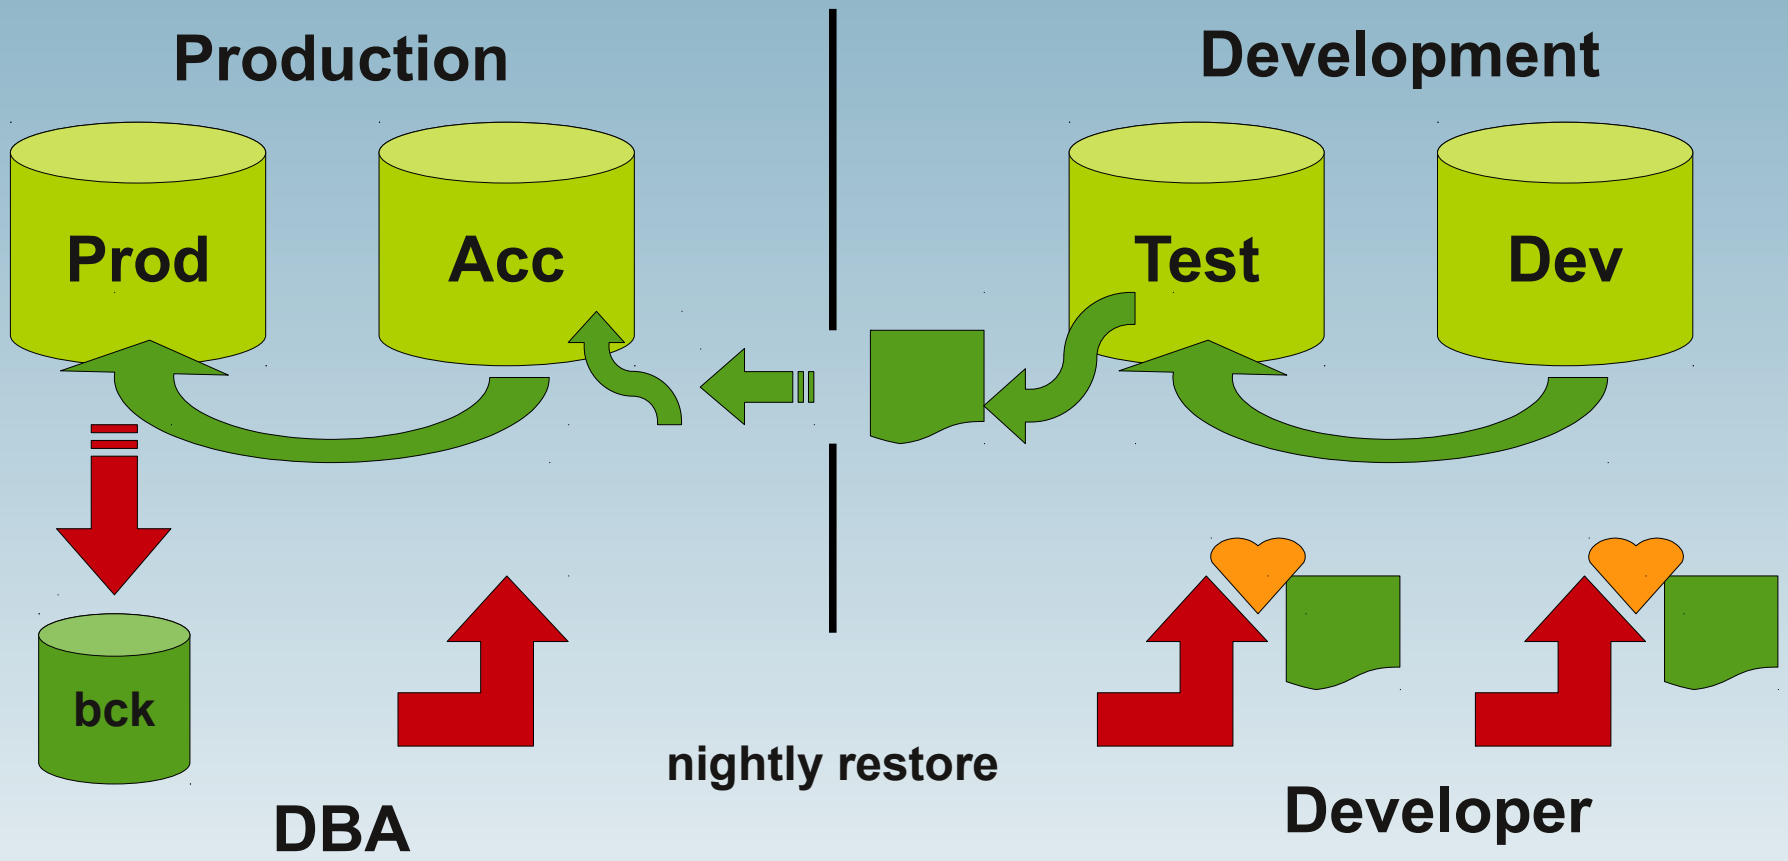

# Storage Engine Replikation mit PBXT

- MySQL Replikation ist nicht sehr schnell
- Man kann die Replikation leicht falsch aufsetzen / Fehler machen.
- Warum so kompliziert über mind. 3 Threads und 2 Files?

→ Die PBXT SE v2.0 implementiert Replikation auf Storage Engine Ebene:

# Overhead der MySQL Replikation

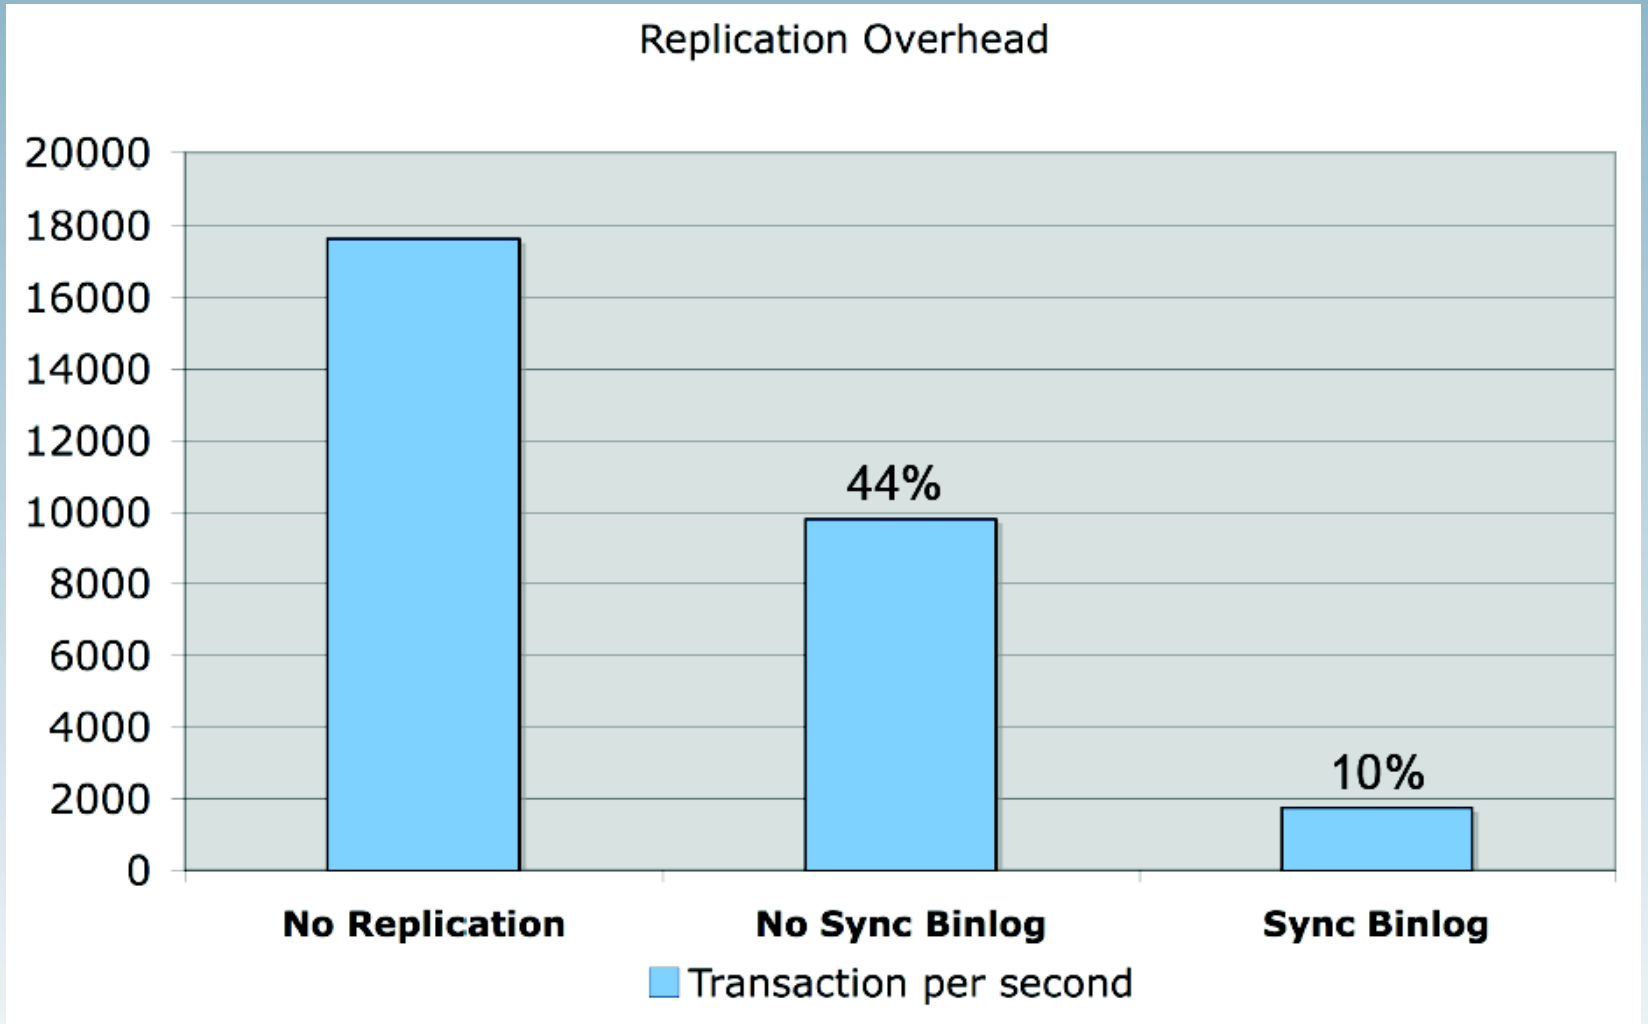

# Architektur der PBXT Replikation

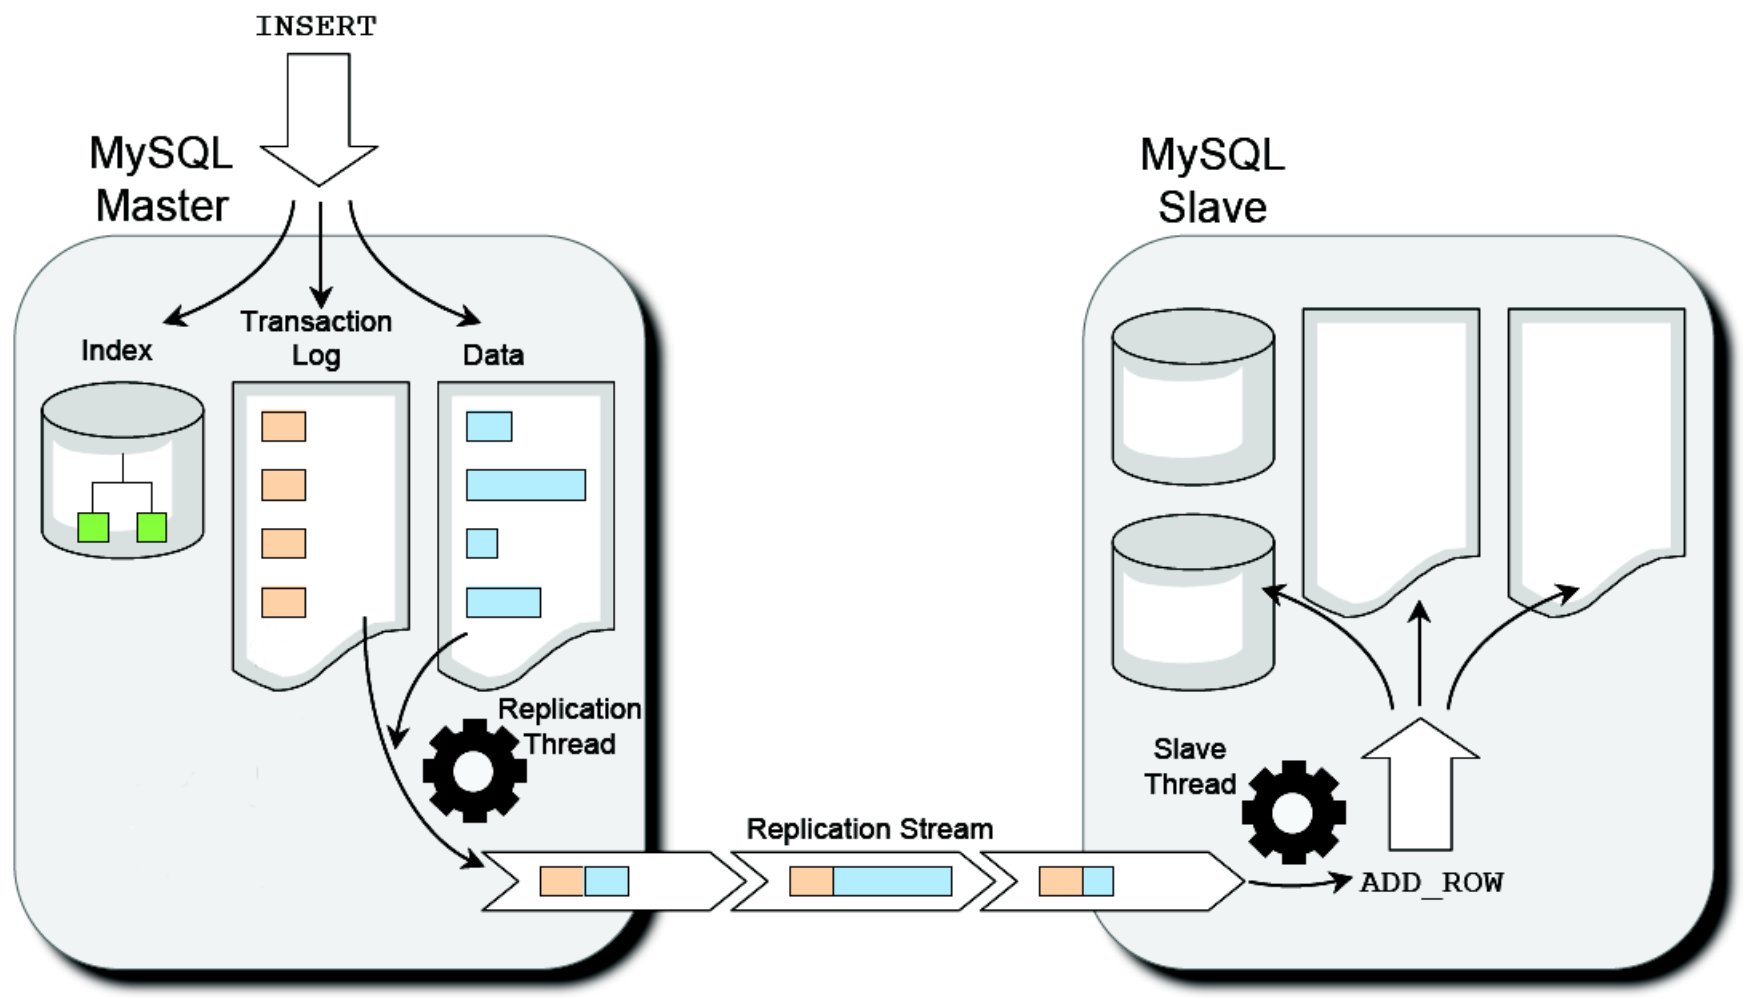

# Overhead der PBXT Replikation