携程MySQL源码开发实践

关于我

- 编写代码17年
- 携程MySQL源码研究近3年
- 数据库研究与开发12年多

版本历程

- 5.6.12
  - 2012年引入，第一个MySQL版本
- 5.6.21
  - 2014-2017，绝大部分的源码功能添加与探索集中在该版本上
- 5.7.X
  - 正在上线中的版本

5.6.12的工作

- 异步复制
  - 针对携程监控场景的自定义改造
- flashback功能的移植
  - 移植自阿里数据库专家彭立勋所开发的代码

异步复制

- 背景
  - Zabbix监控下，复制分发延迟情况比较严重
- 特点
  - 部分表的update/insert的操作集中，且SQL相关性不强
- 改造目标
  - 提高slave的写入效率
- 改造手段
  - 在slave针对特定表的DML SQL进行事务拆分，由单线程转为多线程SQL运行

改造原理

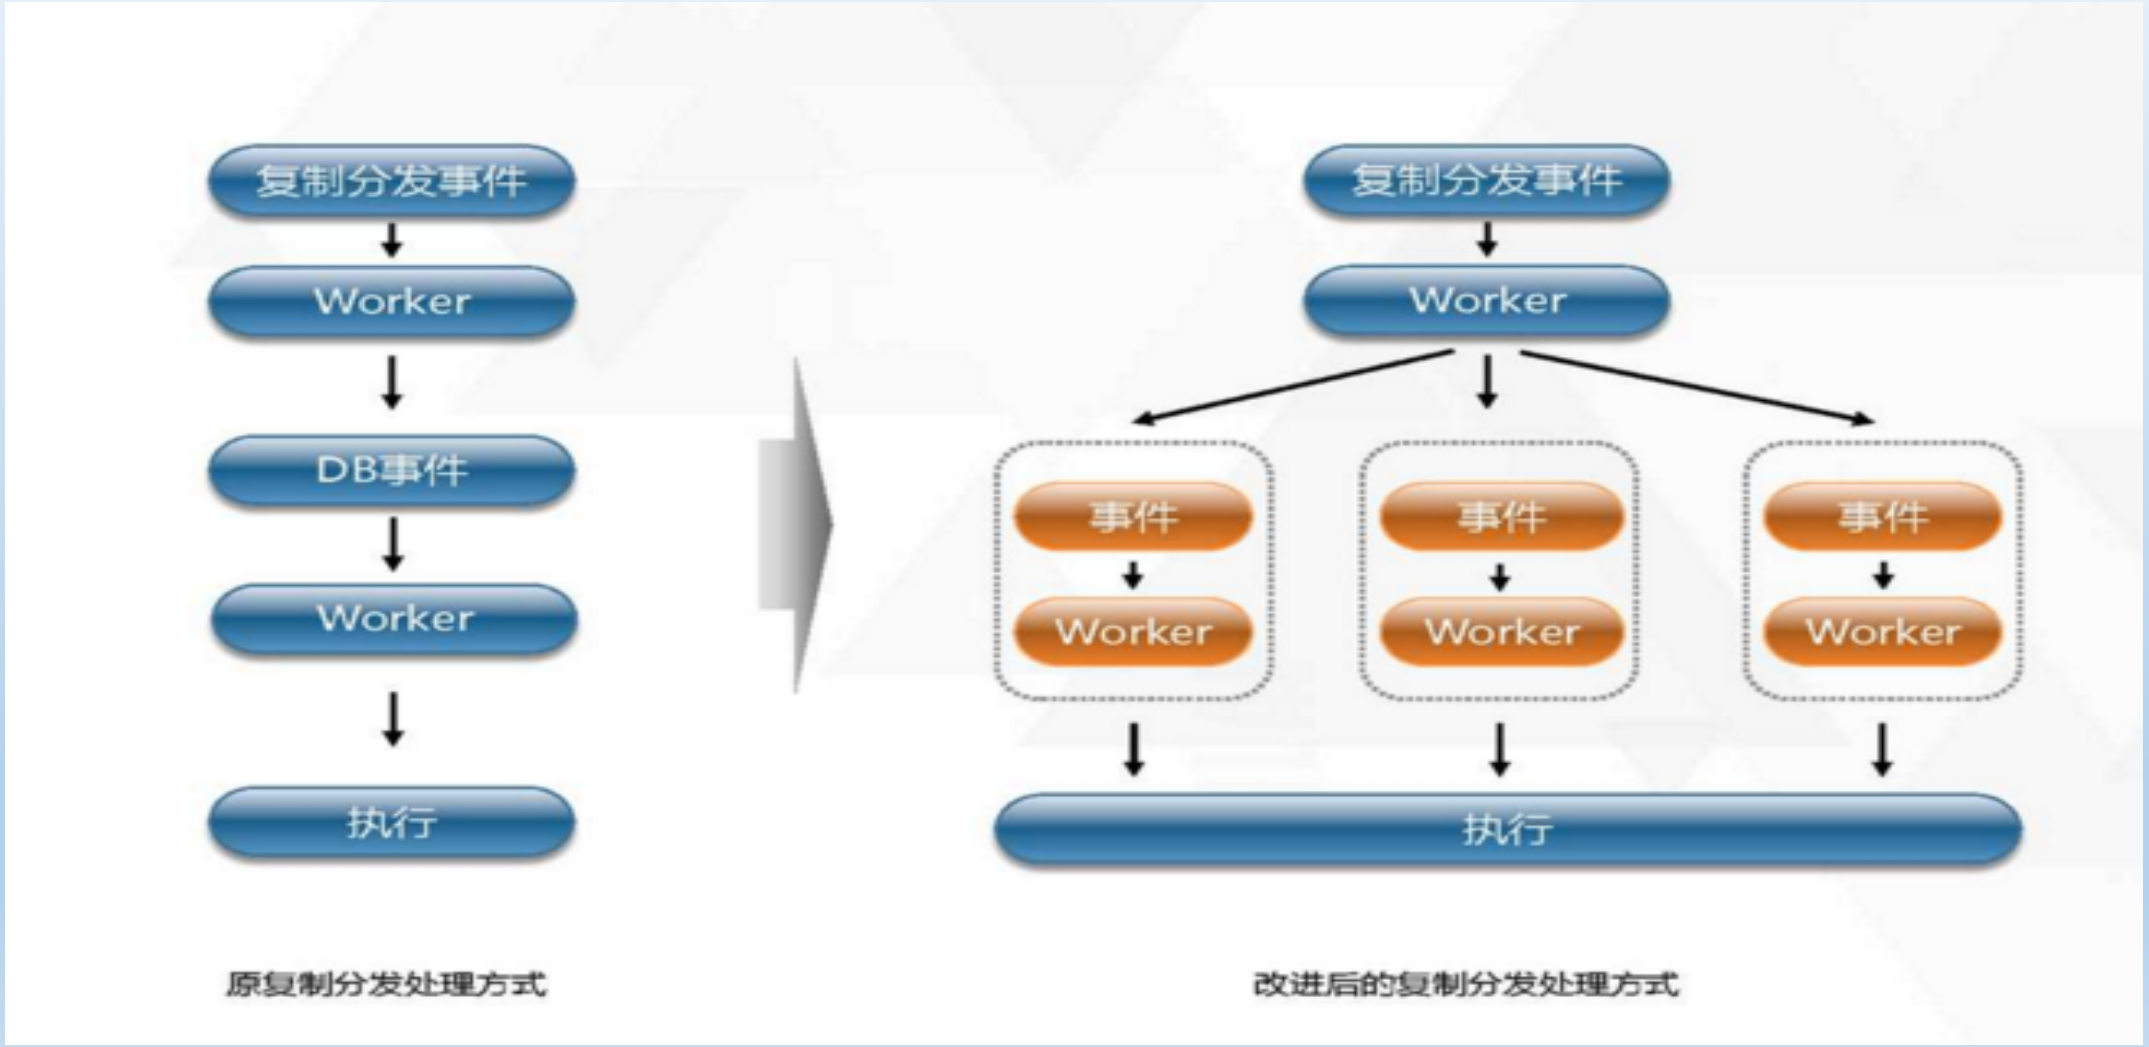
复制分发事件
Worker
DB事件
Worker
执行
原复制分发处理方式
复制分发事件
Worker
事件
Worker
事件
Worker
事件
Worker
执行
改进后的复制分发处理方式

异步复制对比测试

结果

测试场景	[1] 16Gbuf+2log	[2] 16Gbuf+4log	[3] 32Gbuf+2log	[4] 32Gbuf+4log	[5] 32Gbuf+4log+query
原生版均值(kWPS)	40.92	41.84	70	76.7	51.47
改进版均值(kWPS)	74.38	75.56	92.71	113.55	90.09
均值提升比例%	81.77%	80.59%	32.44%	48.04%	75.03%

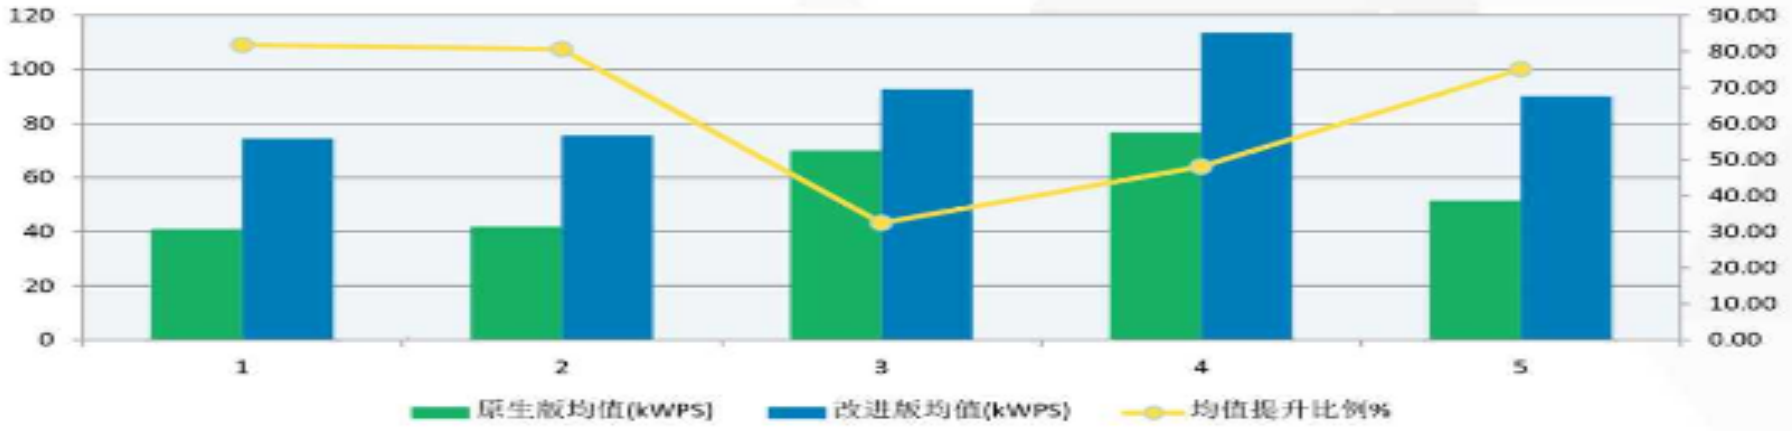

初试啼声

5.6.21

- 移植工作
  - flashback功能
- 新增修改
  - 审计插件
  - Slow log功能增强
  - Show processlist功能增强
- 探索性功能
  - 时间序列存储引擎

审计插件

- 目的
  - 线上操作监控
- 功能特性
  - 用户级审计设定
  - 语句级/关键词审计设定
  - 动态配置
  - Json格式输出
  - 缓存提速

```
[general]
audit_file=ctrip_audit.log
audit_error_file=ctrip_audit_error.log
enable_buffer=1

[audit rule]
name=rule1
user=root
#host=192.168
event=connection:connect;connection:disconnect;general:status;general:error
#command=query
#sql_command=set_option
#sql_keyword=names
```

```
{
        "timestamp":    "2017-02-06 15:31:54",
        "type": "general",
        "user": "root[root] @ localhost []",
        "host": "localhost",
        "ip":   "",
        "command_class":        "set_option",
        "sqltext":      "set global ctrip_audit_flush_log=1",
        "code": 0
},{
        "timestamp":    "2017-02-06 17:00:28",
        "type": "general",
        "user": "root[root] @ localhost []",
        "host": "localhost",
```

原理图

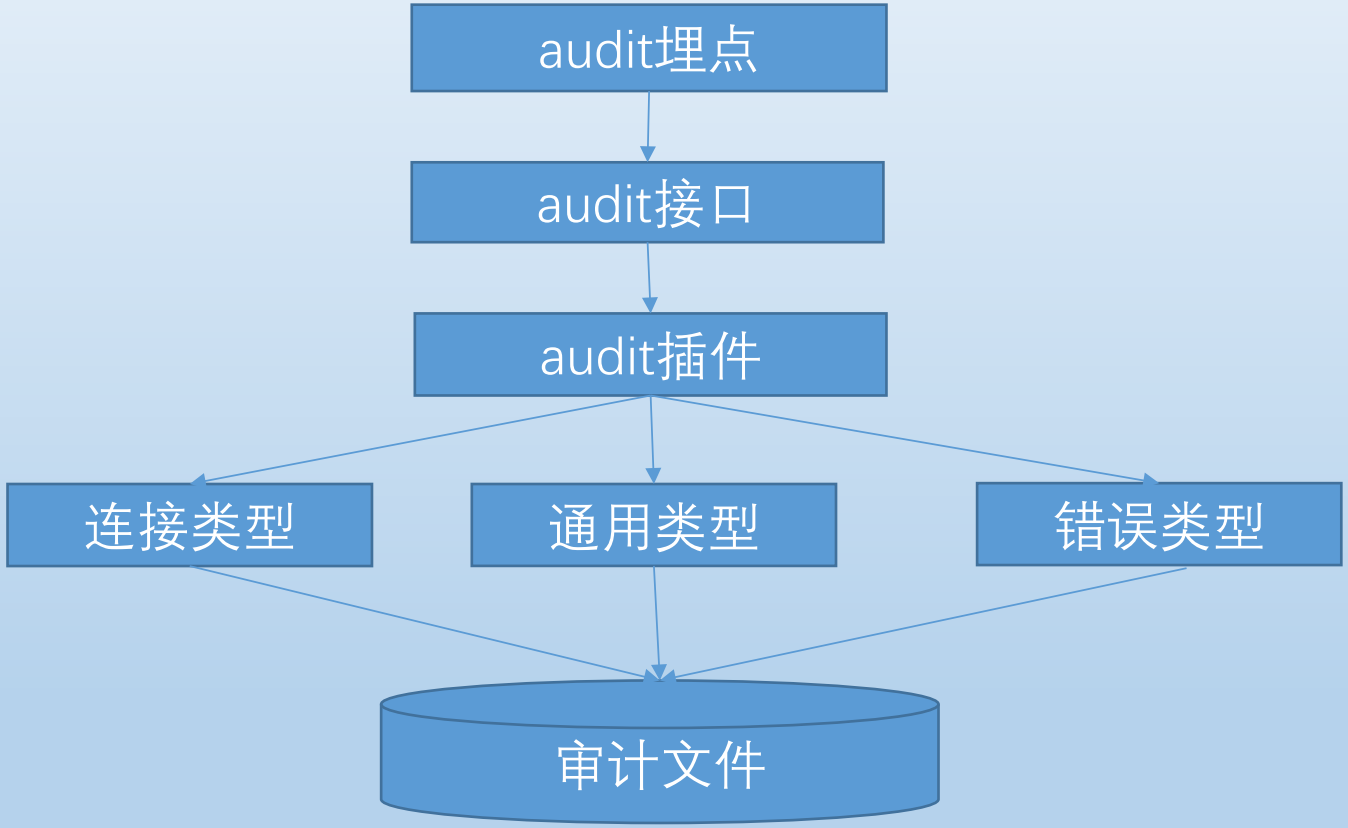

审计代码

- 插件声明

```
mysql_declare_plugin(ctrip_audit)
{
  MYSQL_AUDIT_PLUGIN,         /* type                            */
  &ctrip_audit_descriptor,    /* descriptor                      */
  "CTRIP_AUDIT",              /* name, install plugin's plugin_name */
  "Ctrip Corp Jiangyx",       /* author                          */
```

- 接口定义

```
static struct st_mysql_audit ctrip_audit_descriptor=
{
  MYSQL_AUDIT_INTERFACE_VERSION,                  /* interface version    */
  NULL,                                           /* release_thd function */
  ctrip_audit_notify,                              /* notify function      */
  { (unsigned long) MYSQL_AUDIT_GENERAL_ALL,
    (unsigned long) MYSQL_AUDIT_CONNECTION_ALL,
```

- 处理函数

```
static int ctrip_audit_notify(MYSQL_THD thd,
                              mysql_event_class_t event_class,
                              const void *event)
{
  number_of_calls++;

  ctrip_audit_process_event(thd, event_class, event);
```

Slow log功能增强

- DBA与用户的矛盾
  - slow log记录执行时间，不包括上锁时间
  - 用户关注命令发出到结果返回的时间
- 改进
  - 增加对上锁时间的记录

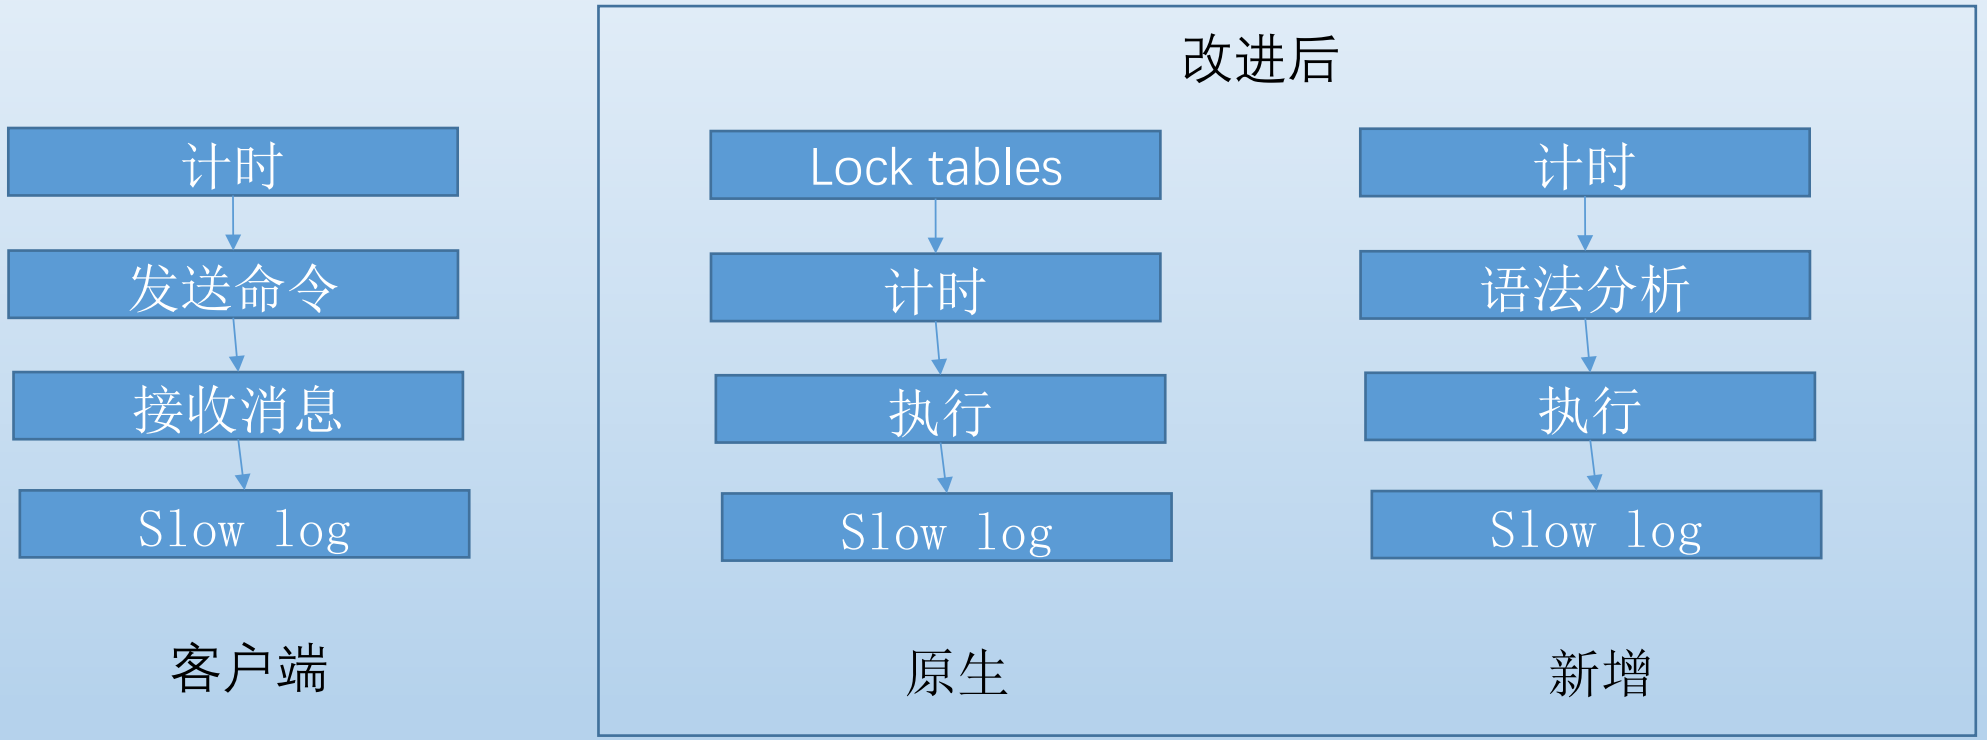
计时
发送命令
接收消息
Slow log
客户端
改进后
Lock tables
计时
执行
Slow log
原生
计时
语法分析
执行
Slow log
新增

Show processlist功能增强

- 与pstree等工具配合使用，更准确判断各个连接的状态

```
Thread 2 (Thread 0x7fe9f8179700 (LWP 24565)):
#0  0x0000003d130df113 in poll () from /lib64/libc.so.6
#1  0x0000000001d92d7a in vio_io_wait ()
#2  0x0000000001d91bbd in vio_socket_io_wait ()
#3  0x0000000001d91c99 in vio_read ()
#4  0x0000000001479103 in net_read_raw_loop(st_net*, unsigned long) ()
#5  0x00000000014792da in net_read_packet_header(st_net*) ()
#6  0x00000000014793e7 in net_read_packet(st_net*, unsigned long*) ()
#7  0x000000000147957a in my_net_read ()
#8  0x0000000001490410 in Protocol_classic::read_packet() ()
#9  0x0000000001490914 in Protocol_classic::get_command(COM_DATA*, enum_server_c
ommand*) ()
#10 0x0000000001569c8e in do_command(THD*) ()
#11 0x00000000016a15c4 in handle_connection ()
#12 0x00000000018f419a in pfs_spawn_thread ()
#13 0x0000003d13407a51 in start_thread () from /lib64/libpthread.so.0
#14 0x0000003d130e893d in clone () from /lib64/libc.so.6
```

```
mysql> show processlist\G
*************************** 1. row ***************************
     Id: 3
   User: root
   Host: localhost
     db: NULL
Command: Query
   Time: 0
  State: starting
   Info: show processlist
 Thd_id: 140642866403072
  Lwpid: 24565
1 row in set (0.00 sec)
```

时间序列存储引擎

- 出发点
  - 利用MySQL已有的网络框架
  - 利用MySQL已有的高可用架构
  - SQL语句降低开发者的学习曲线
  - SQL方式标准化时间序列存储引擎的操作方式

时间序列存储引擎-运维视图

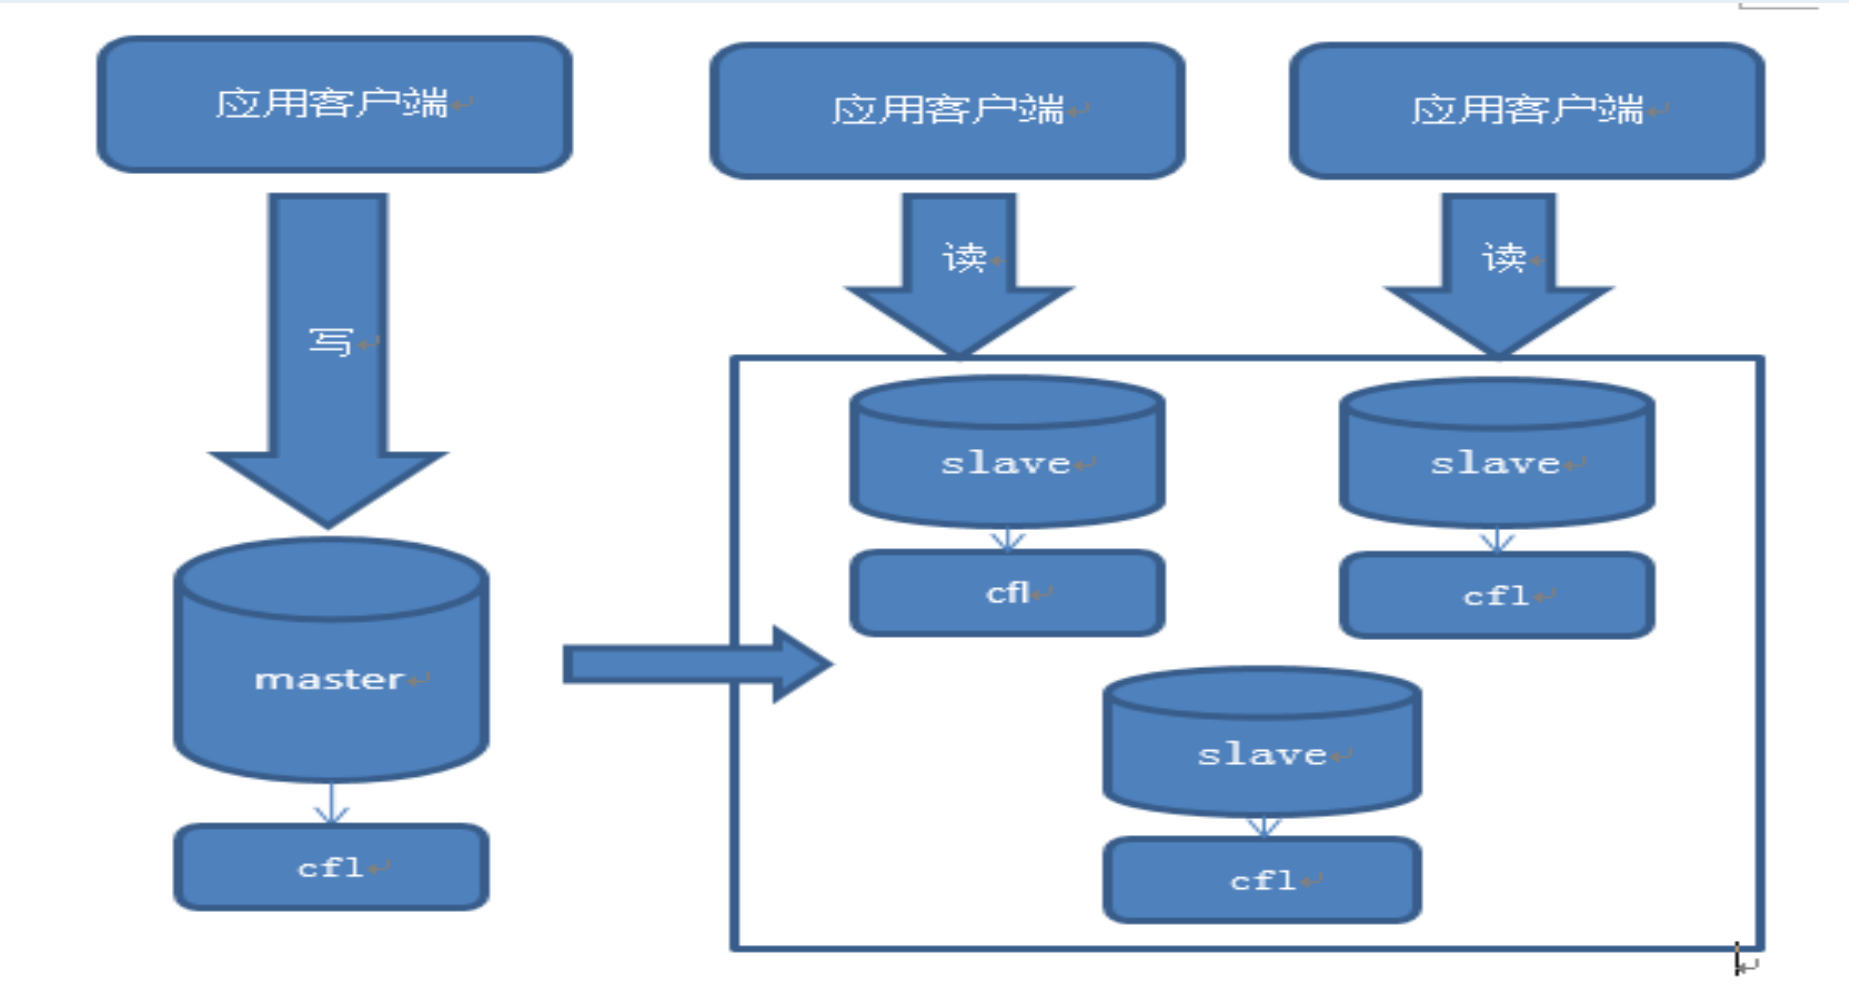

时间序列存储引擎-运行视图

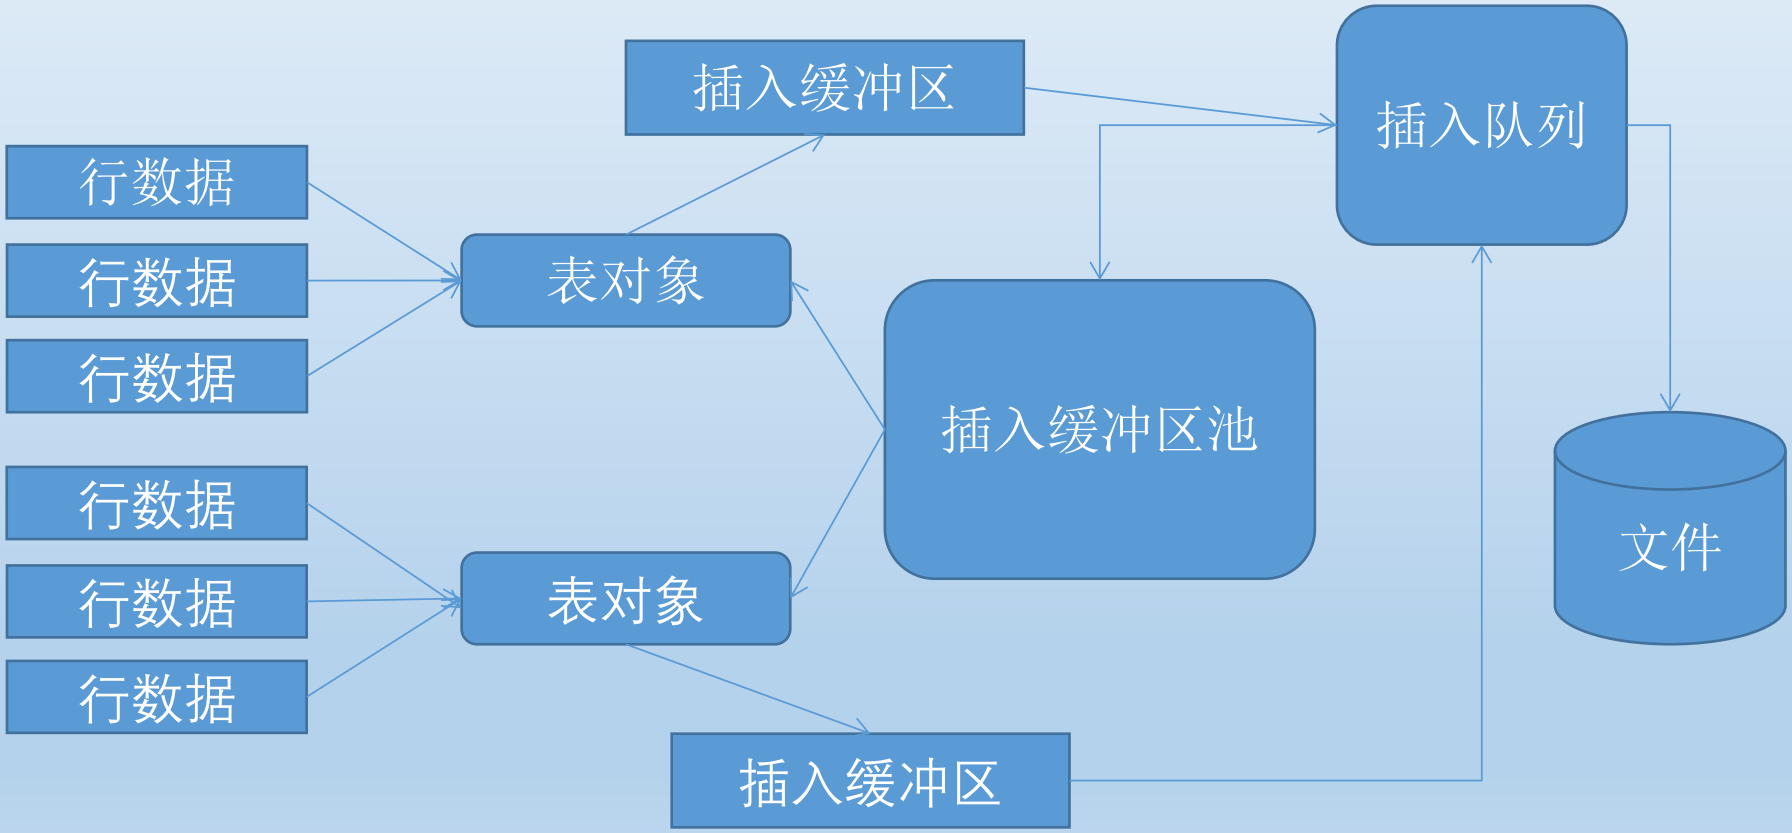

时间序列存储引擎-插入性能对比

引擎\线程	1线程（ips）	3线程（ips）	6线程（ips）
Cfl	3700	5700	8400
MyISAM	3300	4500	6000
InnoDB	1900	2100	3000
2核ssd虚拟机			

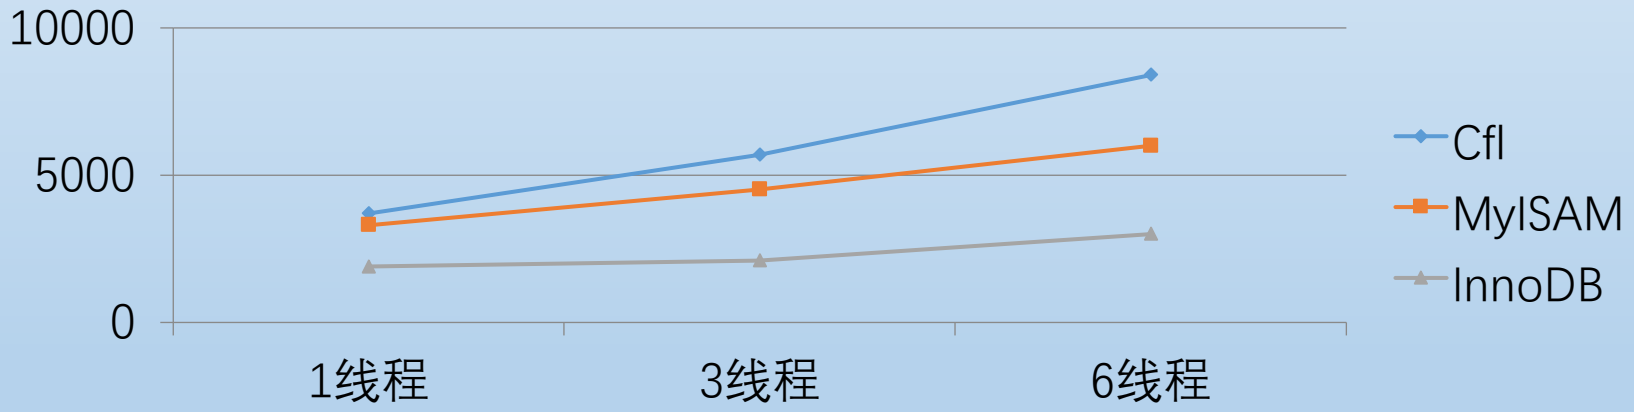

时间序列存储引擎-源码

- MySQL文件：handler.h/handler.c
- Cfl文件：

```
cfl_aio.h       cfl_dt.h       cfl_insert_buffer.cc  cfl_table.h
cfl_buffer.cc   cfl_endian.h   cfl_insert_buffer.h   CMakeCache.txt
cfl_buffer.h    cfl_file.cc    cfl_page.cc           CMakeFiles
cfl_cursor.cc   cfl_file.h     cfl_page.h            CMakeLists.txt
cfl_cursor.h    cfl.h          cfl_row.cc            ha_cfl.cc
cfl_data.cc     cfl_index.cc   cfl_row.h             ha_cfl.h
cfl_data.h      cfl_index.h    cfl_table.cc          readme
```

- 程序片段

```
class handler :public Sql_alloc
{
public:
  typedef ulonglong Table_flags;
protected:
  TABLE_SHARE *table_share;              /* The table definition */
  TABLE *table;                          /* The current open table */
  Table_flags cached_table_flags;        /* Set on init() and open() */
```

```
  int ha_open(TABLE *table, const char *name, int mode, int test_if_locked);
  int ha_close(void);
  int ha_index_init(uint idx, bool sorted);
  int ha_index_end();
  int ha_rnd_init(bool scan);
  int ha_rnd_end();
  int ha_rnd_next(uchar *buf);
  int ha_rnd_pos(uchar * buf, uchar *pos);
```

```
*/
class ha_cfl: public handler
{
  THR_LOCK_DATA lock;      ///< MySQL lock
  Cfl_share *share;    ///< Shared lock info
  Cfl_share *get_share(); ///< Get the share
```

渐入佳境

5.7.17

- 移植功能
  - 5.6.21的线上功能
- 新功能
  - 记录binlog中DML的发起者（invoker）
  - mysqlfbtool，flashback结果转换为可执行的SQL语句的工具
  - 保留连接的改造
  - performance shcema功能改进
  - RPM打包开发

binlog中的invoker

- 修改目的
  - 记录是谁进行了DML操作
  - 为后续的按用户操作回滚提供基础
- 效率问题
  - 以事务为单元进行记录
  - 写入量占比极低

mysqlfbtool

- 将mysqlbinlog工具解析出的语句还原为SQL

```
./bin/mysqlbinlog -v -B data/mysql-bin.000001 > mysql-bin.000001.fb
```

```
###flashback
### DELETE FROM `test`.`t1`
### WHERE
###   @1=1
###   @2='1'
```

```
./bin/mysqlfbtool -uroot -p -S mysql.sock mysql-bin.000001.fb
Enter password:
delete from test.t1 where f1=1 and f2='1';
```

Invoker&Flashback&Mysqlfbtool

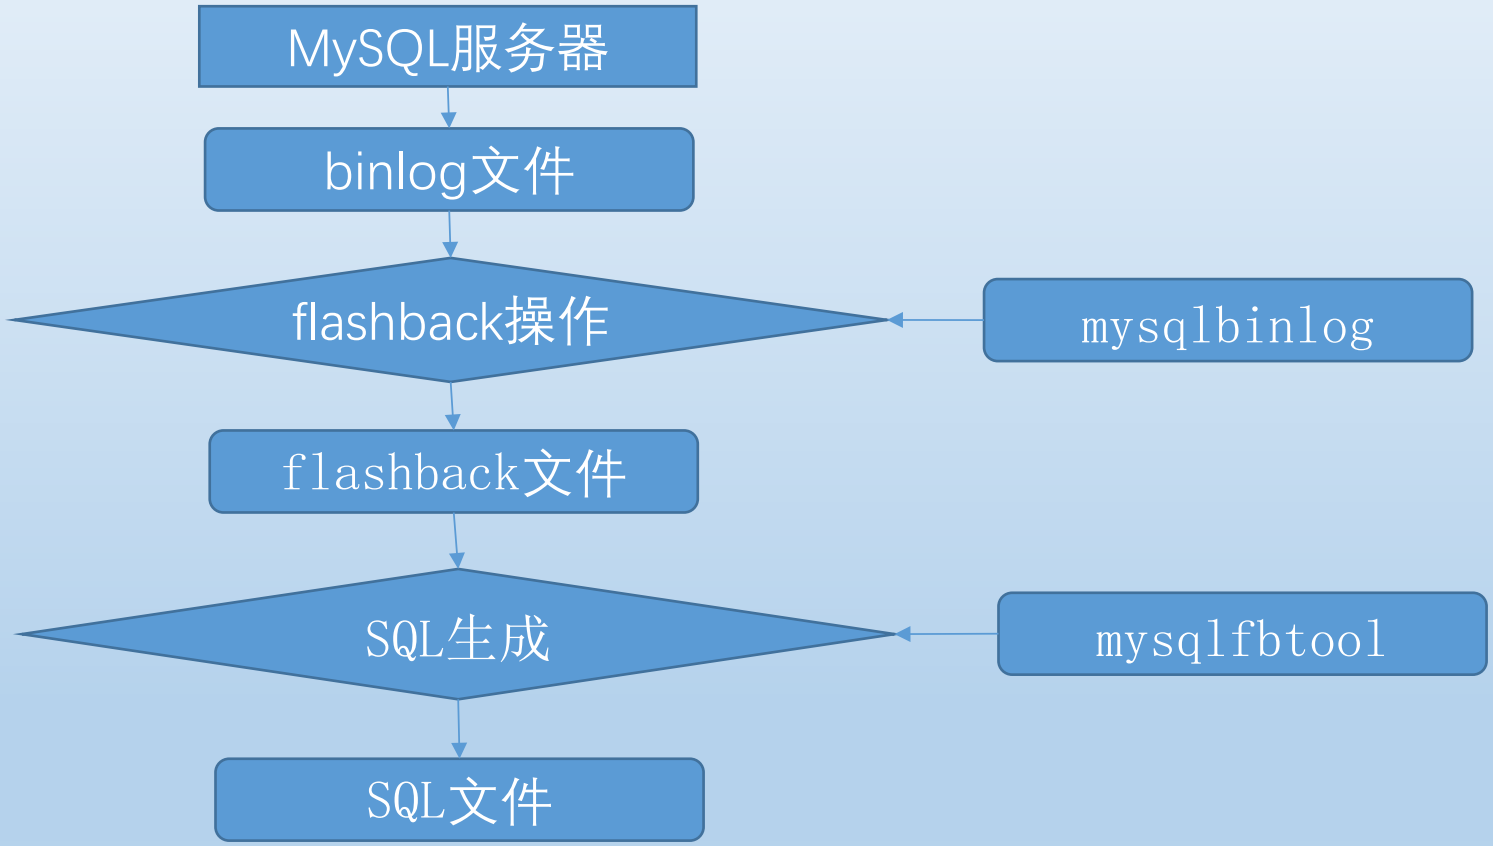

保留连接的改造

- MySQL达到最大连接数后，允许1个超级用户进行连接

mysqld actually permits `max_connections+1` clients to connect. The extra connection is reserved for use by accounts that have the `SUPER` privilege. By granting the `SUPER` privilege to administrators and not to normal users (who should not need it), an administrator can connect to the server and use `SHOW PROCESSLIST` to diagnose problems even if the maximum number of unprivileged clients are connected. See Section 13.7.5.30, “SHOW PROCESSLIST Syntax”.

- 增加配置项，预留更多的连接

```
max-connections = 5
reserved-connections = 2
```

performance shcema改进

- 目标
  - 期望如SQL Server一样生成语句的general log
- 效率问题
  - events_statements_history_long的数据针对每次查询都要重新生成
- 功能
  - 在events_statements系列表中增加host&user的输出
  - 运行中动态配置events_statements事件的记录写盘
    - 避免开启events_statements_history_long的读写效率问题
    - 便于备份和使用

performance shcema的运行图

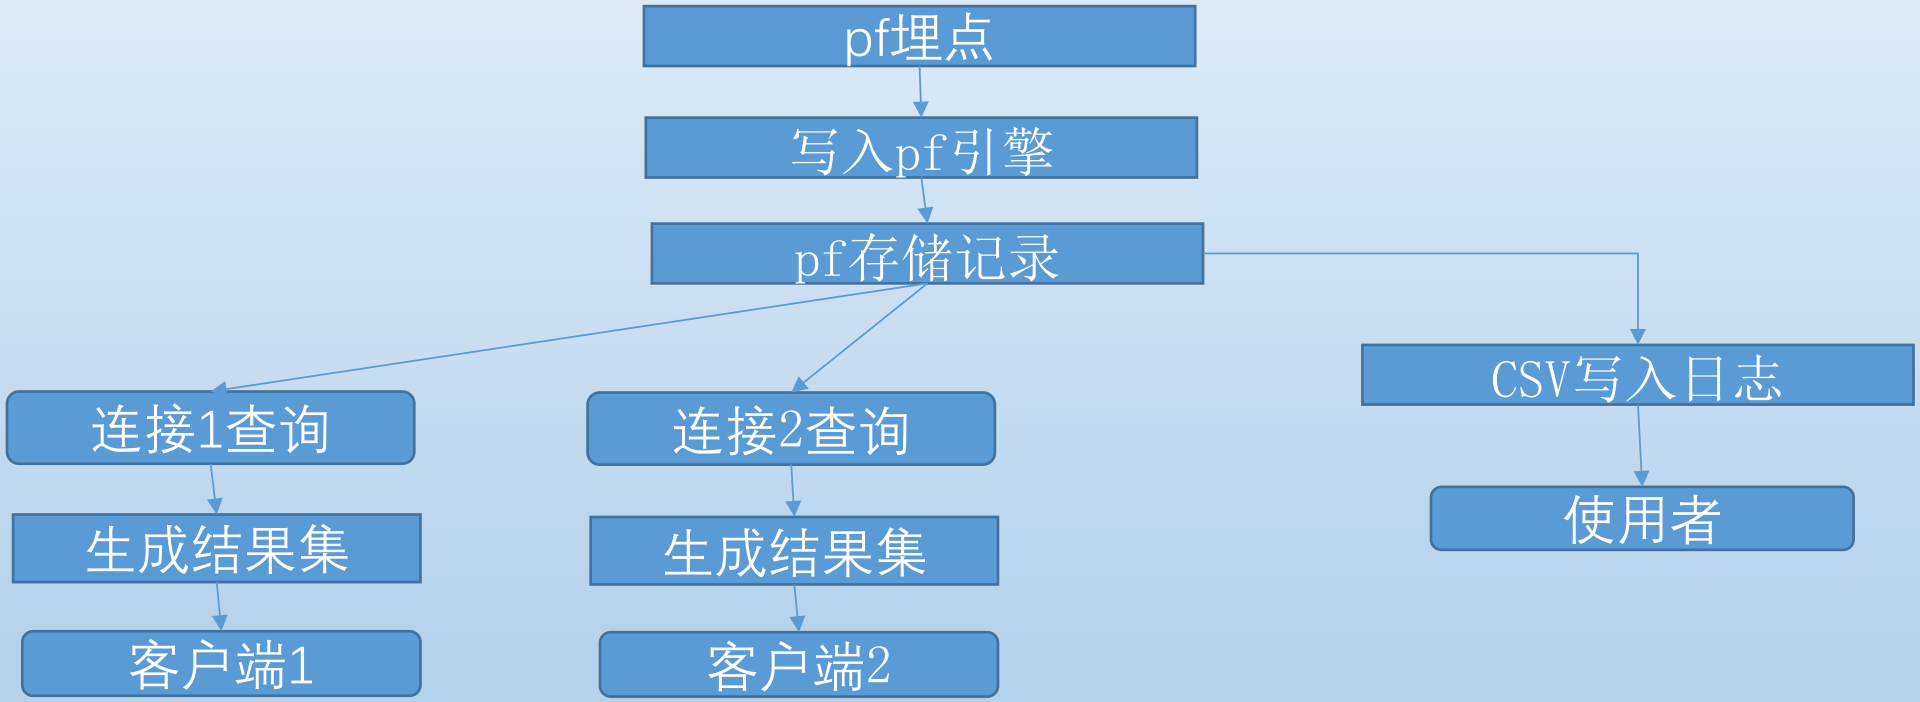

线程池

- 开发原因
  - 业务连接数据惊人而且并发量大
  - percona线程池存在诸如内存泄漏等问题
  - 探索MySQL连接实现
- 设计
  - 通过网络事件触发
  - 监听线程进行网络事件管理
  - 工作线程进行客户端请求处理，并返回给客户端
- 限制
  - 仅限Linux下可用

线程池实现

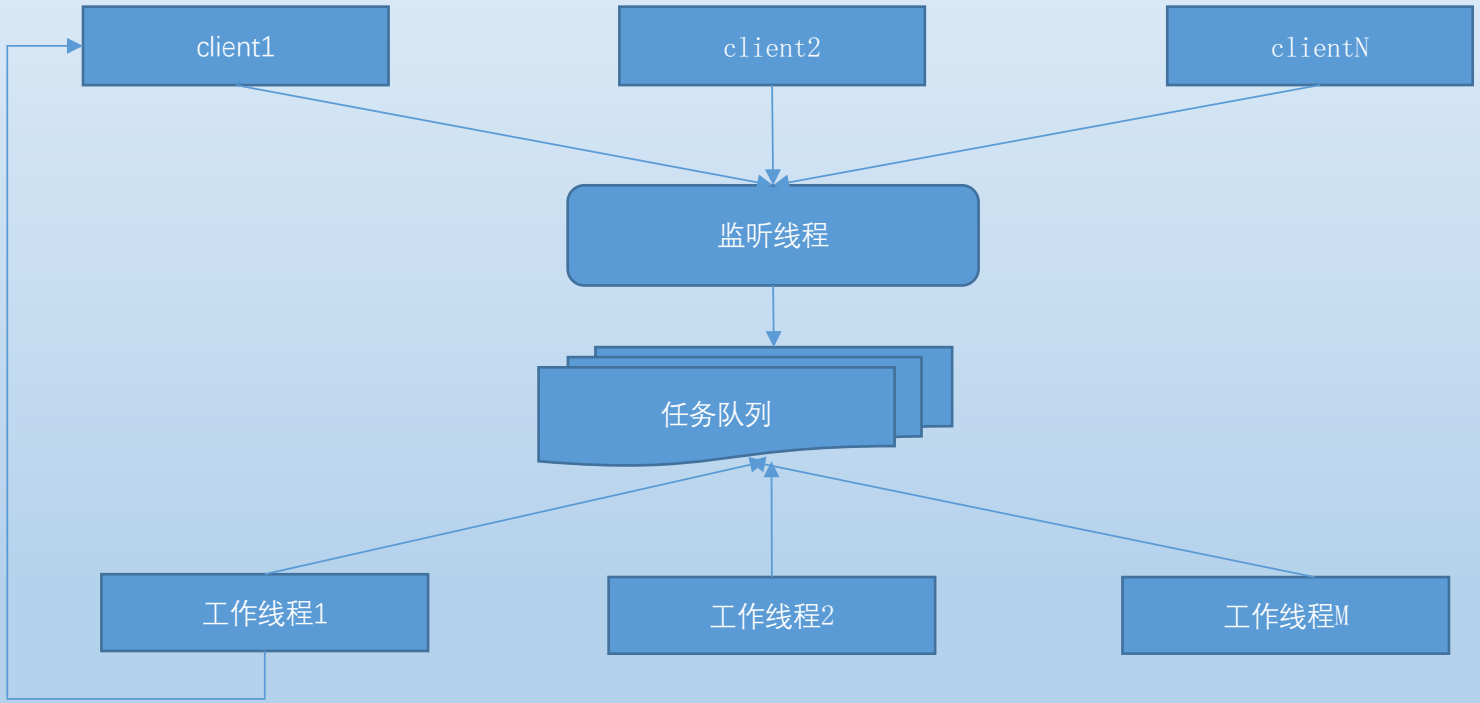

RPM打包开发

- 问题
  - 5.7.17无法按照5.6的操作进行打包
- 解决
  - 仿照5.6.X的打包方式重新编写mysql.spec.sh
- 特色
  - 增加了携程定制的打包内容，如mysqlfbtool以及名字等

总结

- 版本
  - 5.6.12/5.6.21/5.7.17
- 功能点
  - 11个线上运行功能
  - 1个探索性开发

源码改造经验

- 太深的源码改造将影响版本升级。在享受新版本和自定制中存在一个平衡。由此，总结下来一些原则减少版本升级中的问题
  - 1、尽可能的利用MySQL原有的函数
  - 2、尽可能通过插件来完成功能
  - 3、如果不可避免要进行代码修改，则尽可能通过新增函数/源文件方式
  - 4、尽可能不要尝试去解析并修改数据内容
  - 5、尽可能不要触动MySQL的运行机制

异步复制的移植失败

- 遇到问题
  - 5.6.12代码移植到5.6.21后，MySQL服务器出现宕机
- 无法定位问题
  - 由于错误出现位置的随机性，而且出现问题的间隔较长，无法准确重现问题，最终只能放弃这个功能
- 分析
  - 该修改改变了复制分发的运行机制，当代码出现变化后，在原理层面就无法
- 教训
  - 尽可能避免触动MySQL的运行机制

flashback的两次移植的差异

- UPDATE回滚的两个思路
  - 在内存中互换行数据
  - 在输出文本中交换set和where的位置
- 5.6.X上的移植
  - 代码相近，写入文件的binlog事件完全一致，patch工作相对简单
- 5.7.17上的移植
  - 新增数据类型增加，需要继续升级
- 得失
  - 前者尽可能还原数据为binlog模式，其结果可直接由mysql使用进行还原工作，但在升级过程中需要更多的修改MySQL代码
  - 后者减少对MySQL代码的修改，但只能处理-v参数所生成的文本结果，失去原有的便利性
- 总结
  - 尽可能少改动MySQL源码，把更多工作留给外部的工具

5.6.X

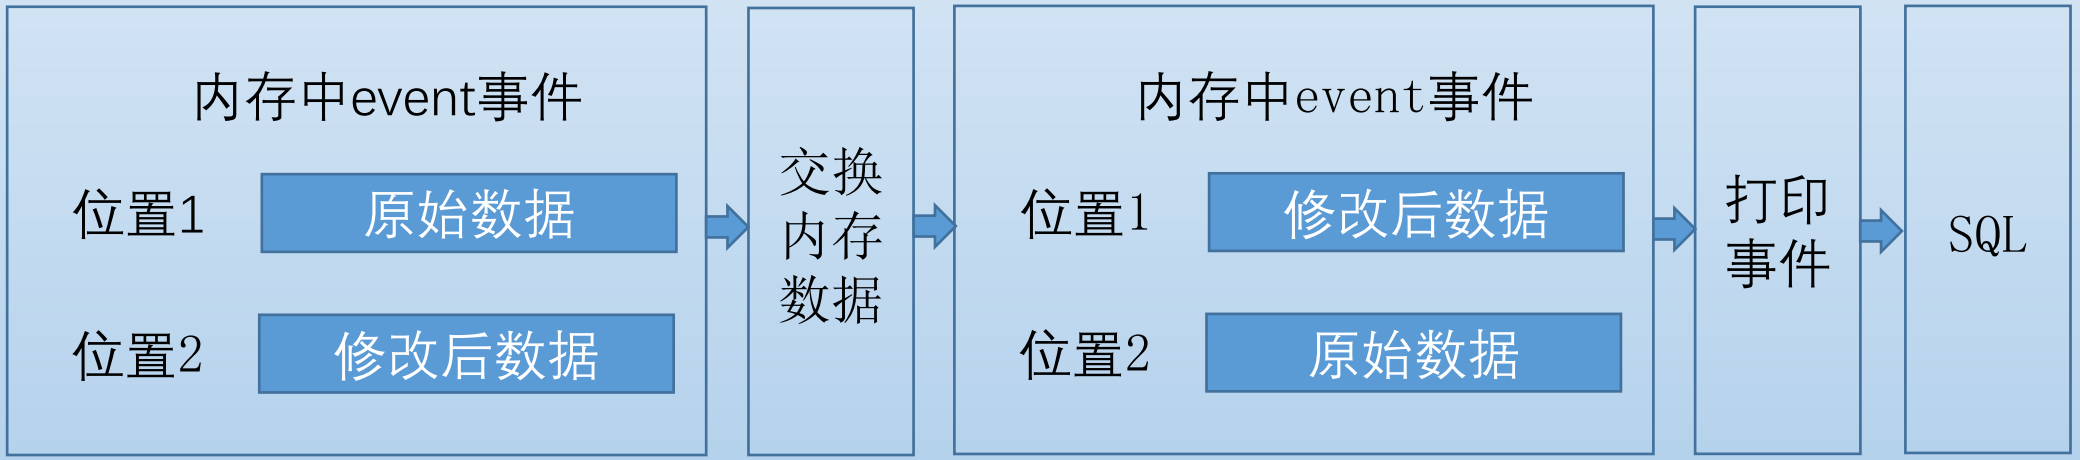
内存中event事件
位置1
原始数据
位置2
修改后数据
交换内存数据
内存中event事件
位置1
修改后数据
位置2
原始数据
打印事件
SQL

5.7.X

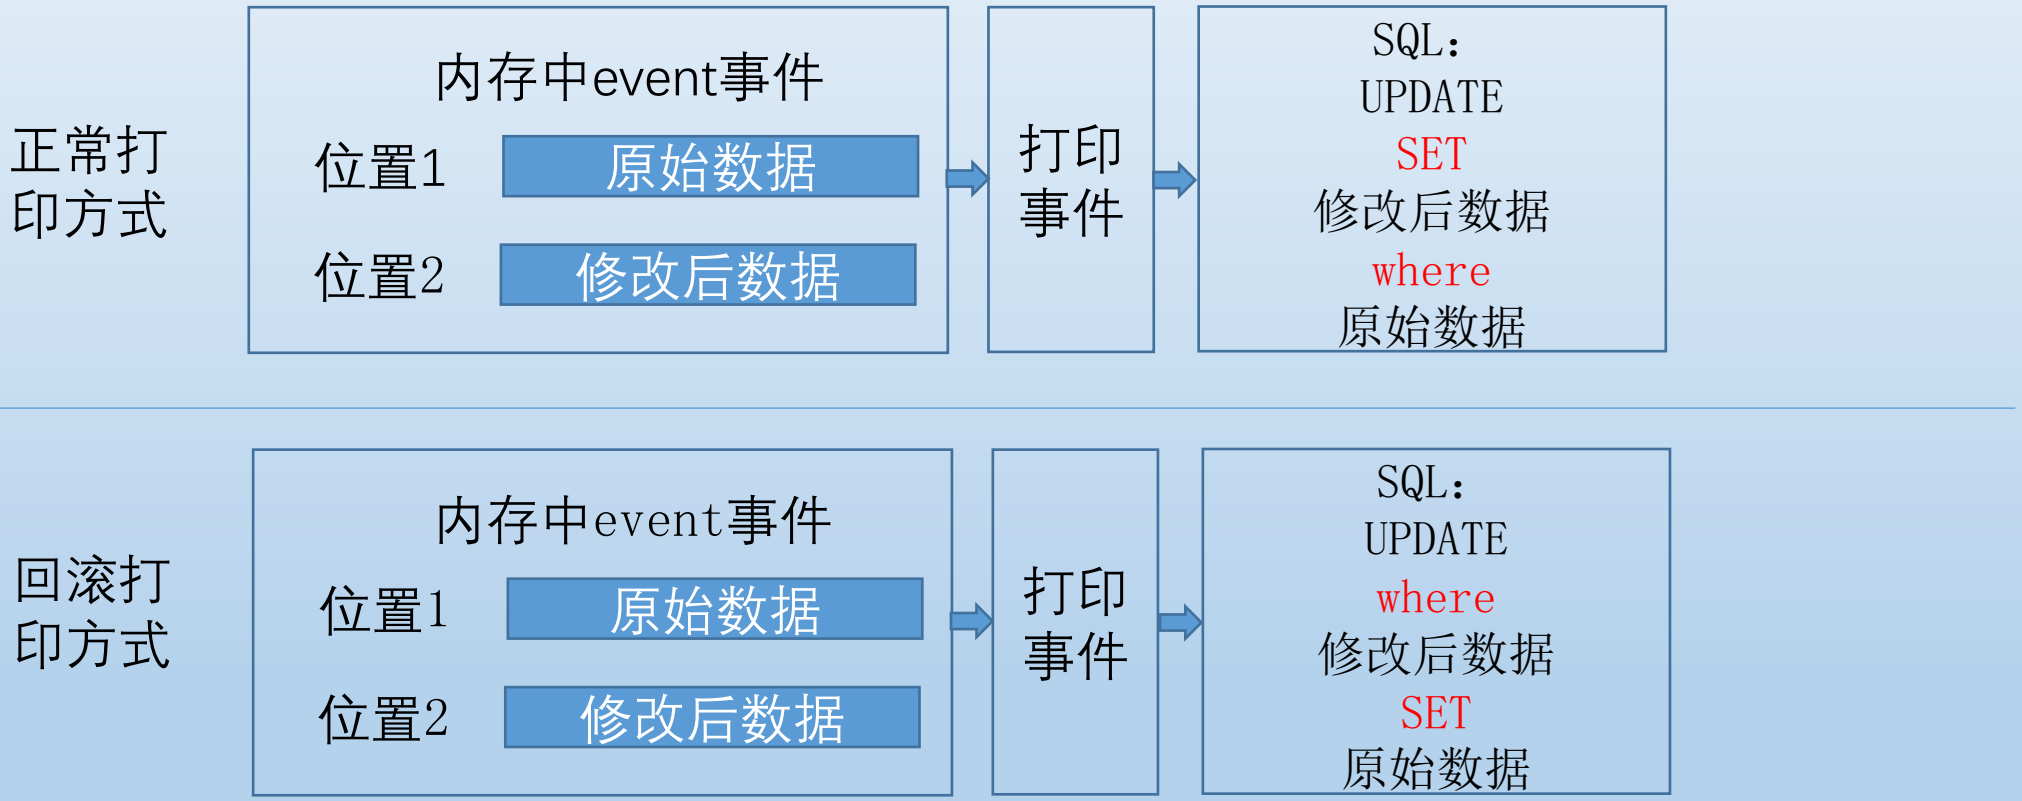
正常打印方式
内存中event事件
位置1
原始数据
位置2
修改后数据
打印事件
SQL：
UPDATE
SET
修改后数据
where
原始数据
回滚打印方式
内存中event事件
位置1
原始数据
位置2
修改后数据
打印事件
SQL：
UPDATE
where
修改后数据
SET
原始数据

路在远方

源码地址

- 5.6.12
  - https://github.com/ctripopsdba/mysql-5.6.12
- 5.6.21
  - https://github.com/ctripopsdba/mysql-5.6.21
- 5.7.17
  - https://github.com/ctripopsdba/mysql-5.7.17

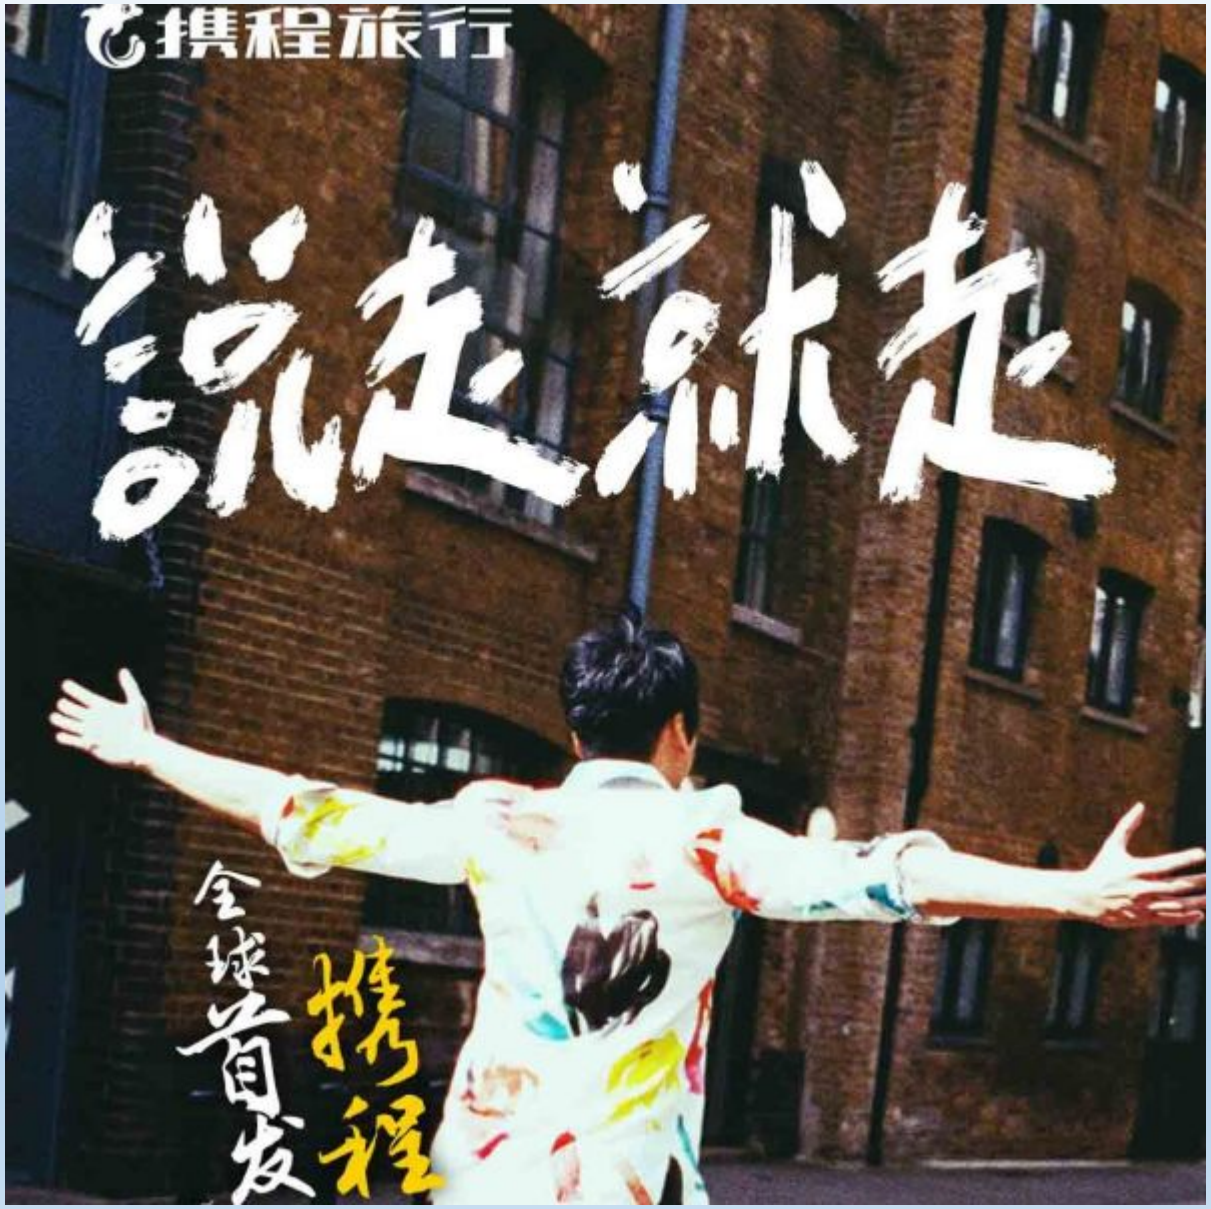
携程旅行
說走就走
全球首发
携程