流复制中：同步和异步自动切换 --PostgreSQL Hot Standby模式下

姜瑞海
jiangruihai@highgo.com
山东瀚高基础软件股份有限公司

内容简介

- 简要介绍PostgreSQL流复制的工作原理

- 介绍流复制中：同步流复制和异步流复制的自动切换的实现。该方案满足了一些客户的需要。

WAL:Write-Ahead Logging

- 数据的变化首先在 内存(shared buffer)发生，在后续的某个时刻，shared buffer里更改的数据被同步到数据文件中。
- 每一个数据的修改，都对应着至少一条WAL日志: WAL record。 WAL record被写入WAL文件中。目录$PGDATA/xlog/下产生很多WAL文件，每一个WAL文件叫做WAL segment。
- shared buffer里的数据更改被提交成功之前，以及同步到数据文件之前，其对应的WAL日志是先被写入WAL文件中。
- 当系统发生故障(例如掉电)，shared buffer中更改的数据，如果没有同步到数据文件中，会丢失。丢失的数据，能够从WAL日志文件中对应的WAL record恢复。

Data lost without WAL

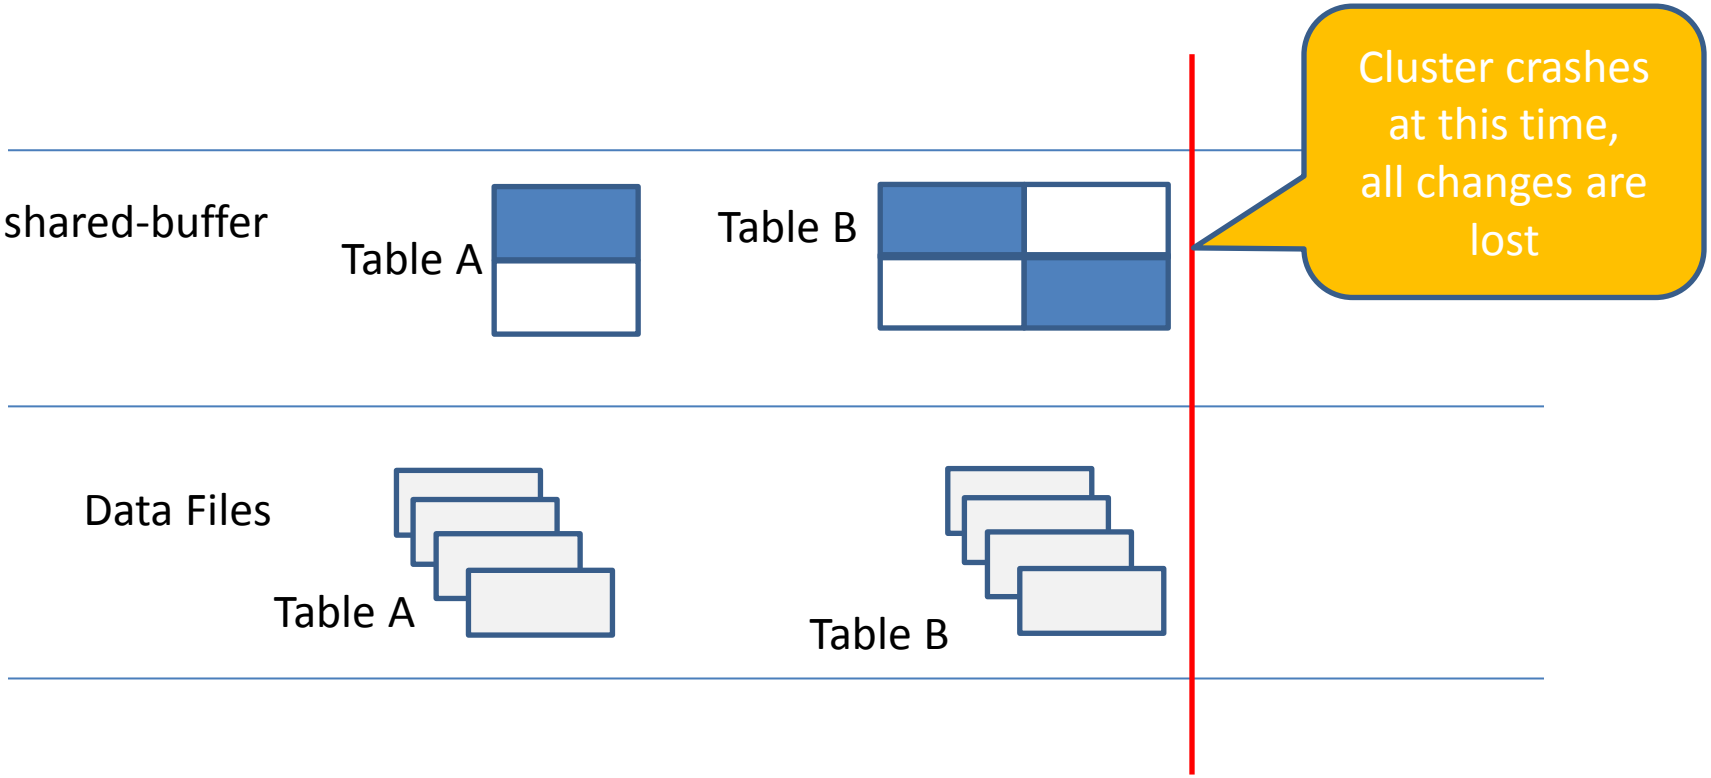

Data Recovery with WAL

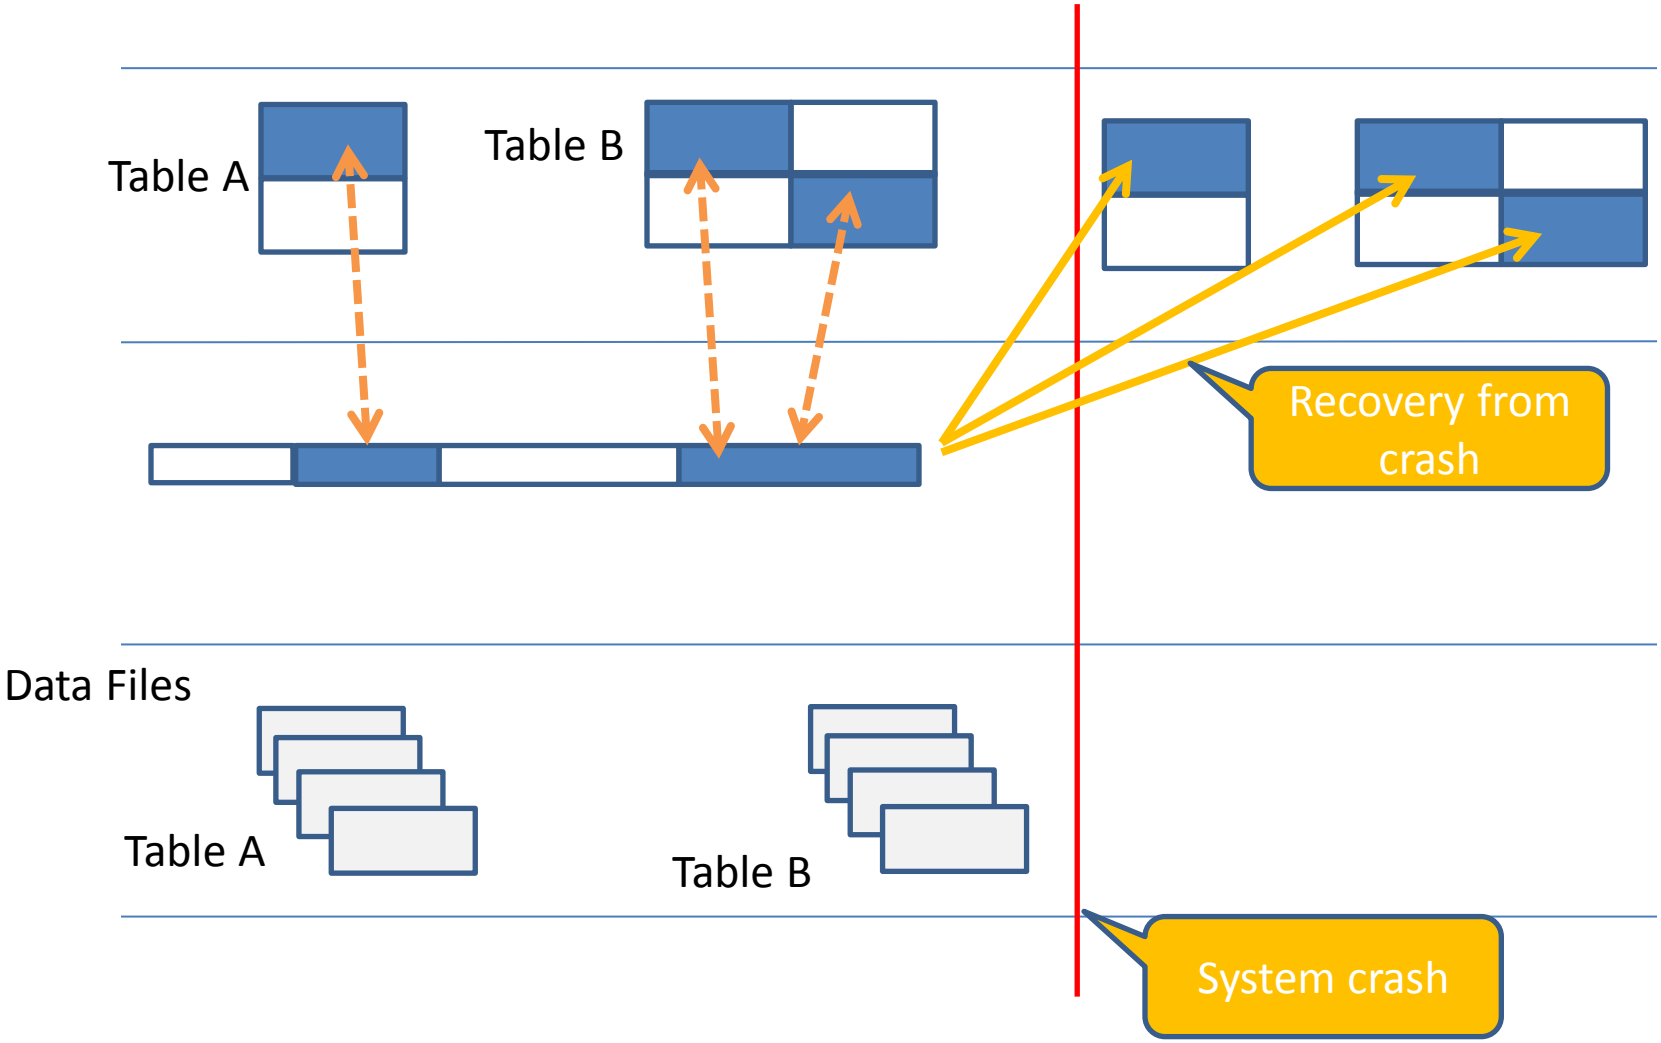

PostgreSQL Warm Standby

- Primary node supports both read and write.
- Standby node supports neither read nor write.

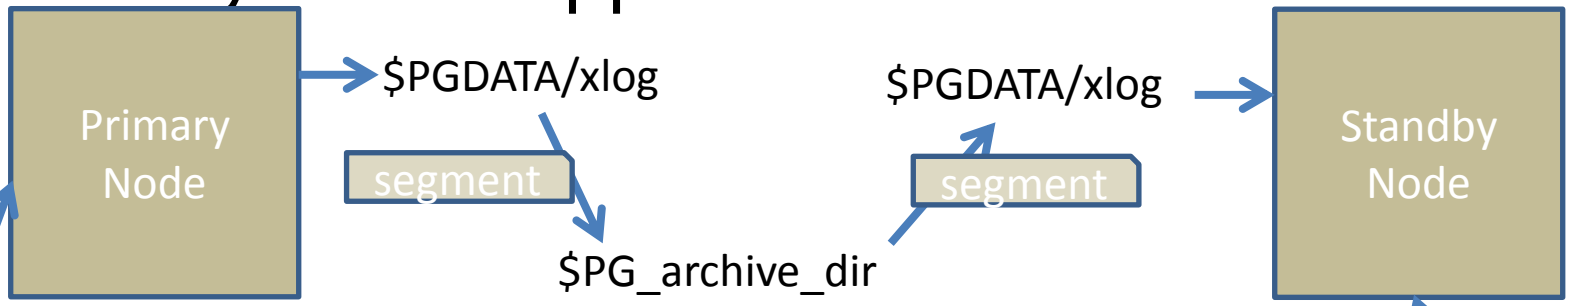

Primary node:postgresql.conf
==========
archive_mode = on
archive_command = 'cp -i %p /shared/psql_wal/%f'

Standby node: recovery.conf
==========
standby_mode = 'on'
restore_command = 'cp -f /var/lib/postgresql/data/archive/%f %p </dev/null'

PostgreSQL Hot Standby

- Primary node supports both read and write.
- Standby node supports read only.
- Use Stream replication to transfer WAL records.

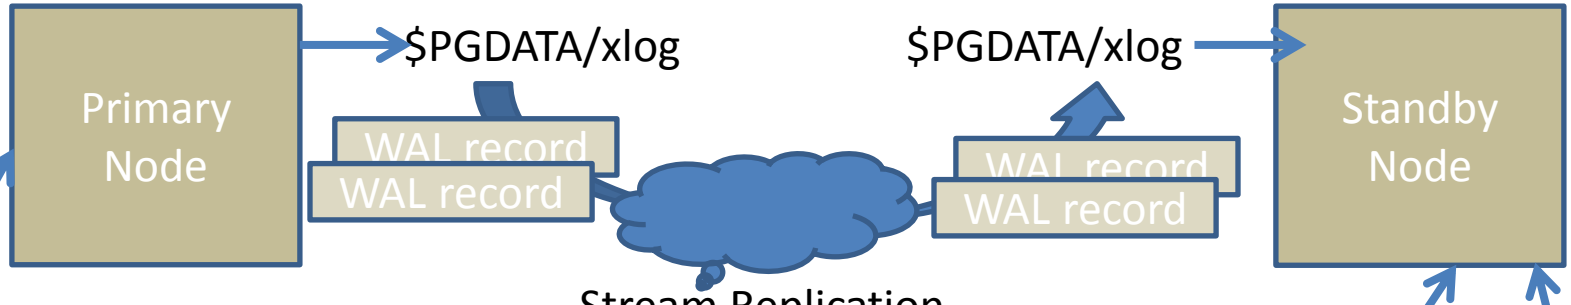

Primary node:postgresql.conf
==========
wal_level = hot_standby
max_wal_senders = 1

Standby node:postgresql.conf
==========
hot_standby = on

Standby node: recovery.conf
==========
primary_conninfo = 'host=192.168.0.1 port=5432 user=ruser password=password'
standby_mode = on

PostgreSQL Stream Replication

- Standby node: Recovery process notifies Postmaster to start the WAL receiver process.
- Standby node: Postmaster process starts the WAL receiver process.
- Standby node: WAL receiver process tries to connect to the Primary node.
- Primary Node: Postmaster accept the connection and spawn the WAL sender process.
- The WAL receiver and WAL sender begin to work.
- WAL receiver tells WAL sender the WAL location(LSN, Log Sequence Number) to start.
- WAL sender starts sending WAL records to WAL receiver.
- WAL sender and WAL receiver exit on communication timeout. WAL receiver will be started again and then WAL sender.

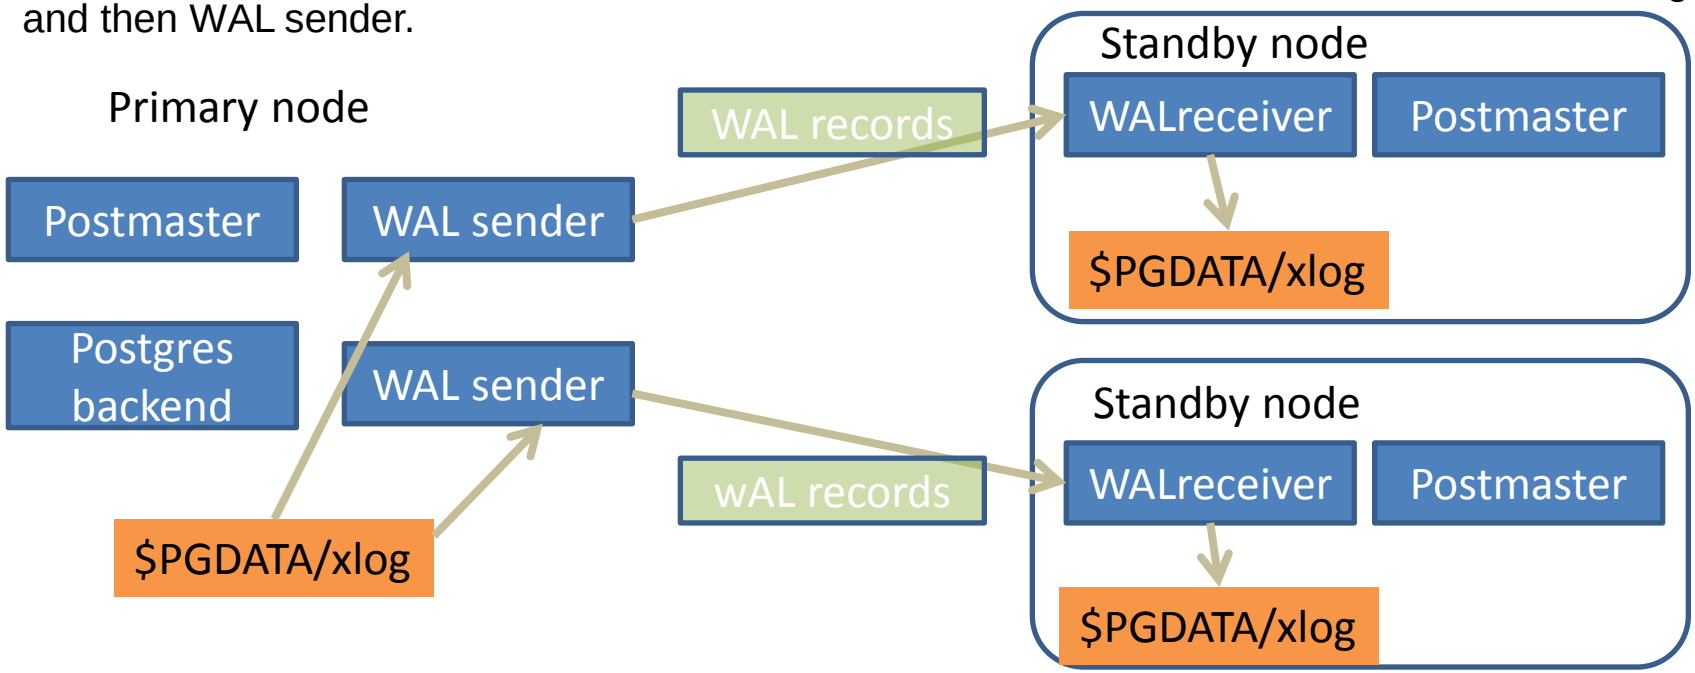

LSN(Log Sequence Number)示意

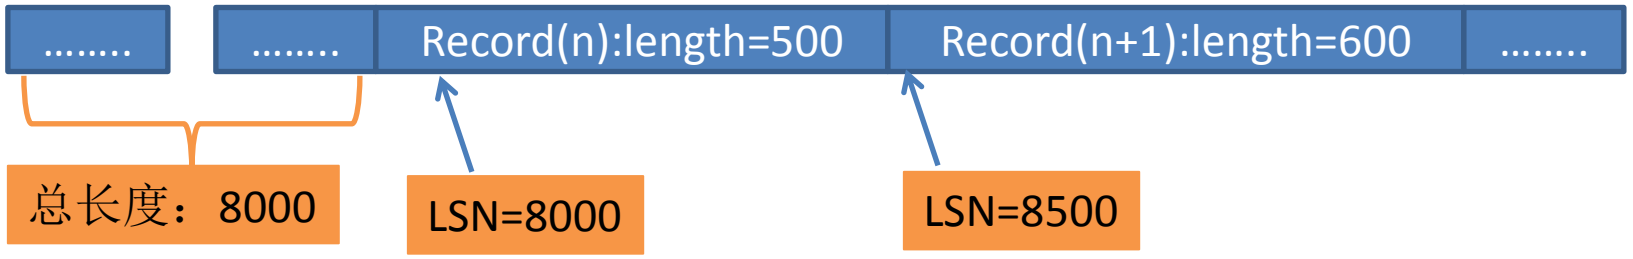

- LSN表示一个WAL record在WAL流中的偏移，如图所示。（实际的LSN计算比图示复杂）
- 每一个WAL record分配一个LSN。

同步流复制：Synchronous Replication

- 同步流复制意味着Primary节点上，Postgres backend等待当前事务的WAL records被Standby接收并写入WAL日志文件或者被应用以恢复数据(replay)。这个等待使得Postgres backend阻塞，直到相应的LSN 从standby应答。
- 当WAL sender收到standby应答的LSN, 例如：10000, 所有等待中的事务/backend, 其waitLSN小于等于应答LSN，例如：8000,9000，会被唤醒。

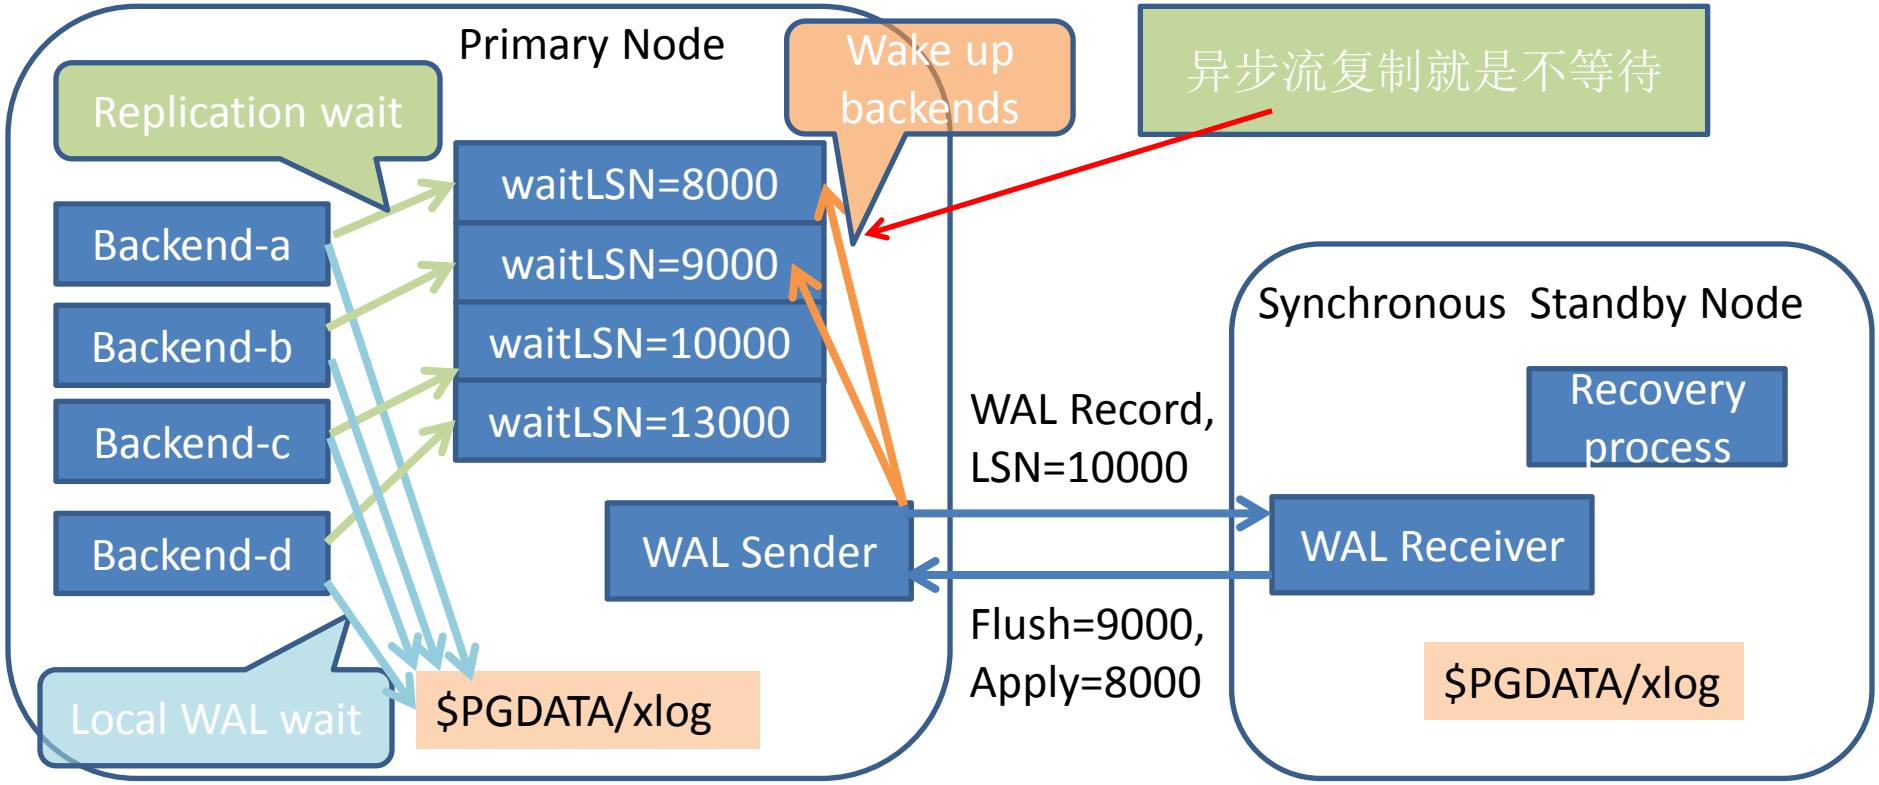

同步模式中：Standby 故障，导致 Primary 无法正常工作

- 当同步模式的standby崩溃，或者网络故障，导致WAL sender收不到任何来自WAL receiver的应答。
- 这会导致Primary端，没有任何Postgres backend会被唤醒，意味着进行中的事务被挂起，进而数据库客户端会超时，返回失败。
- 一些应用程序遇到这样的错误时，会不断放弃已有的数据库连接，而尝试新建连接。新建连接意味着新的Postgres backend进程不断产生，进而会耗尽系统资源。

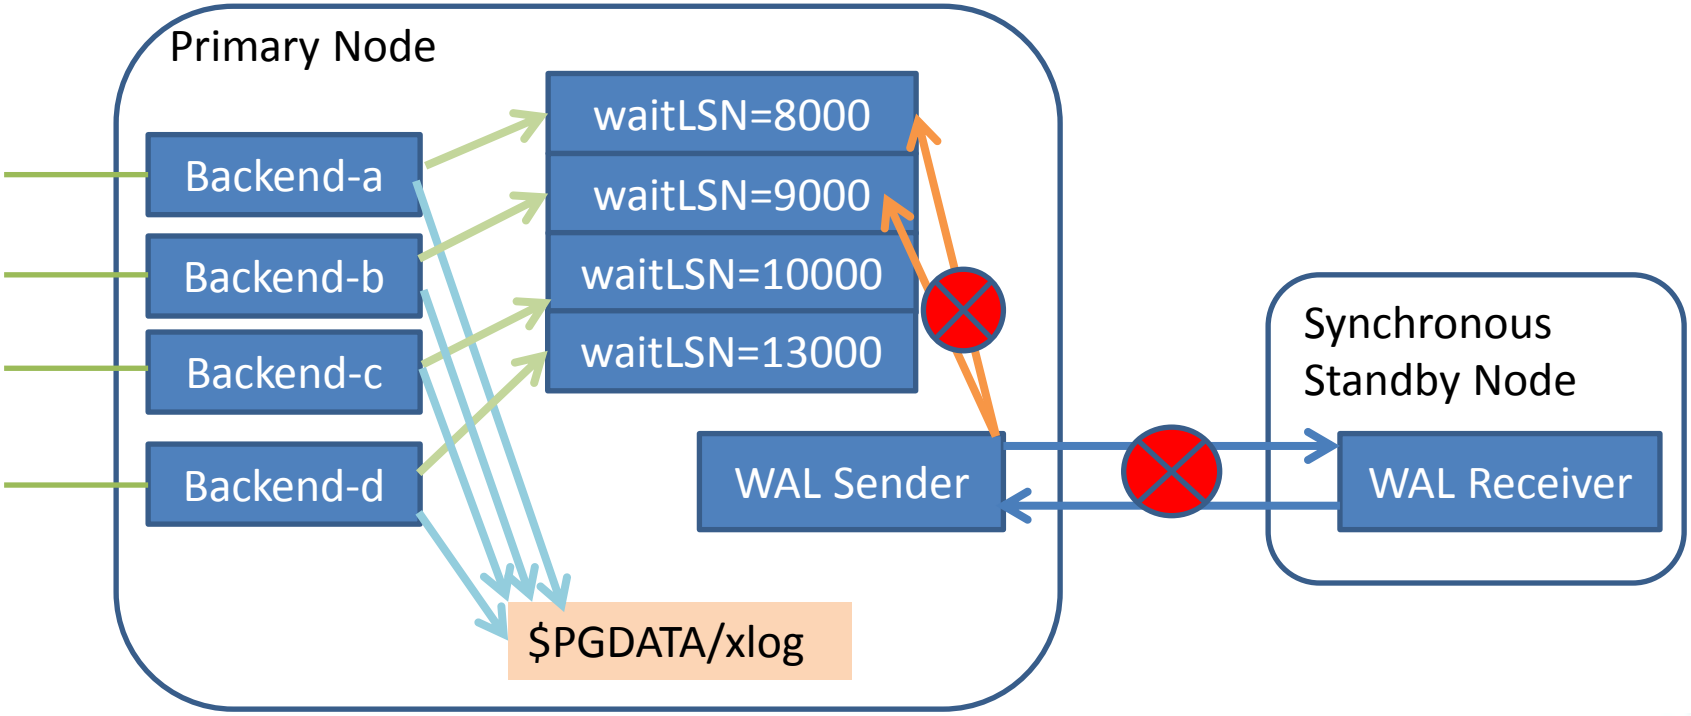

为什么需要同步/异步自动切换

- 基于流复制的hot standby配置中，如果同步的Standby节点故障，会导致Primary node也无法工作。
- 我们的很多客户不接受。他们希望：Standby节点出现故障后，Primary节点能继续工作，整个应用程序应该能继续工作。**通过自动切换实现**。
- 有些人说：这是可以接受的。因为同步流复制的目的是为了Primary和Standby保持数据高度一致。一个出故障了，另外一个就不应该继续更改数据了。

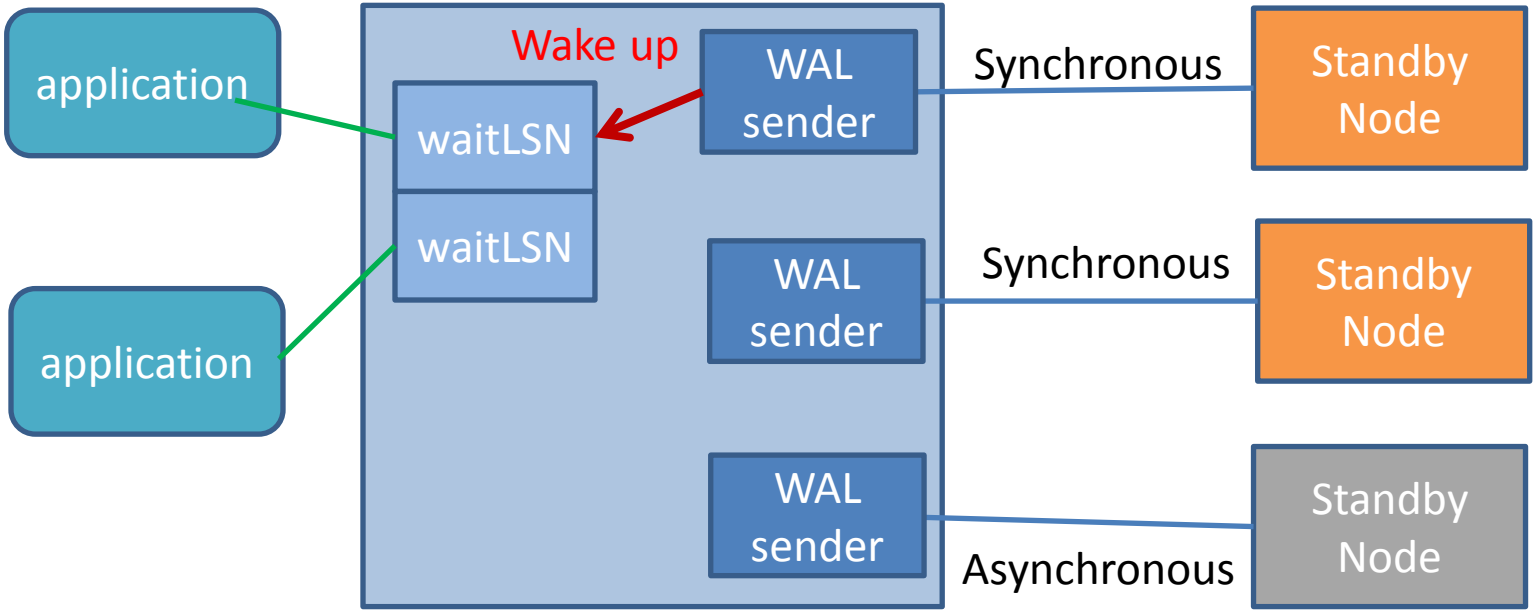

同步模式的工作流程

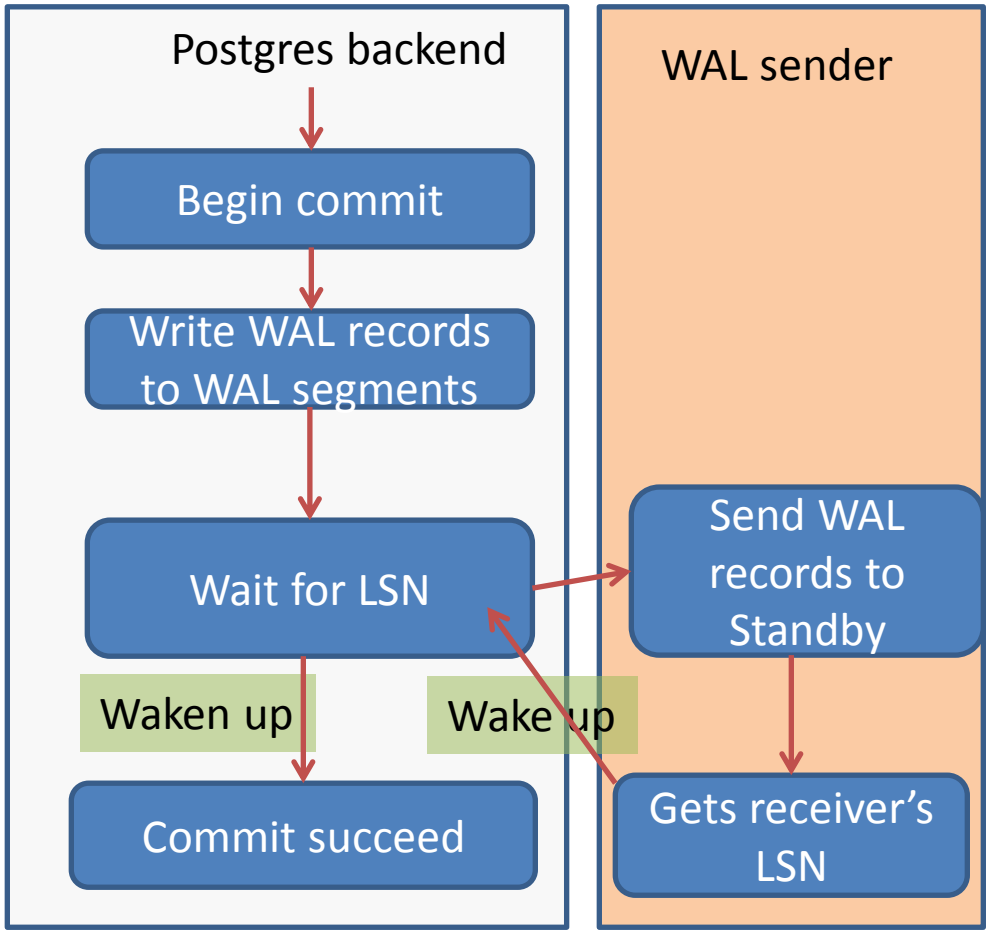
Postgres backend
WAL sender
Begin commit
Write WAL records to WAL segments
Wait for LSN
Send WAL records to Standby
Waken up
Wake up
Commit succeed
Gets receiver's LSN

Switching between synchronous mode and asynchronous mode

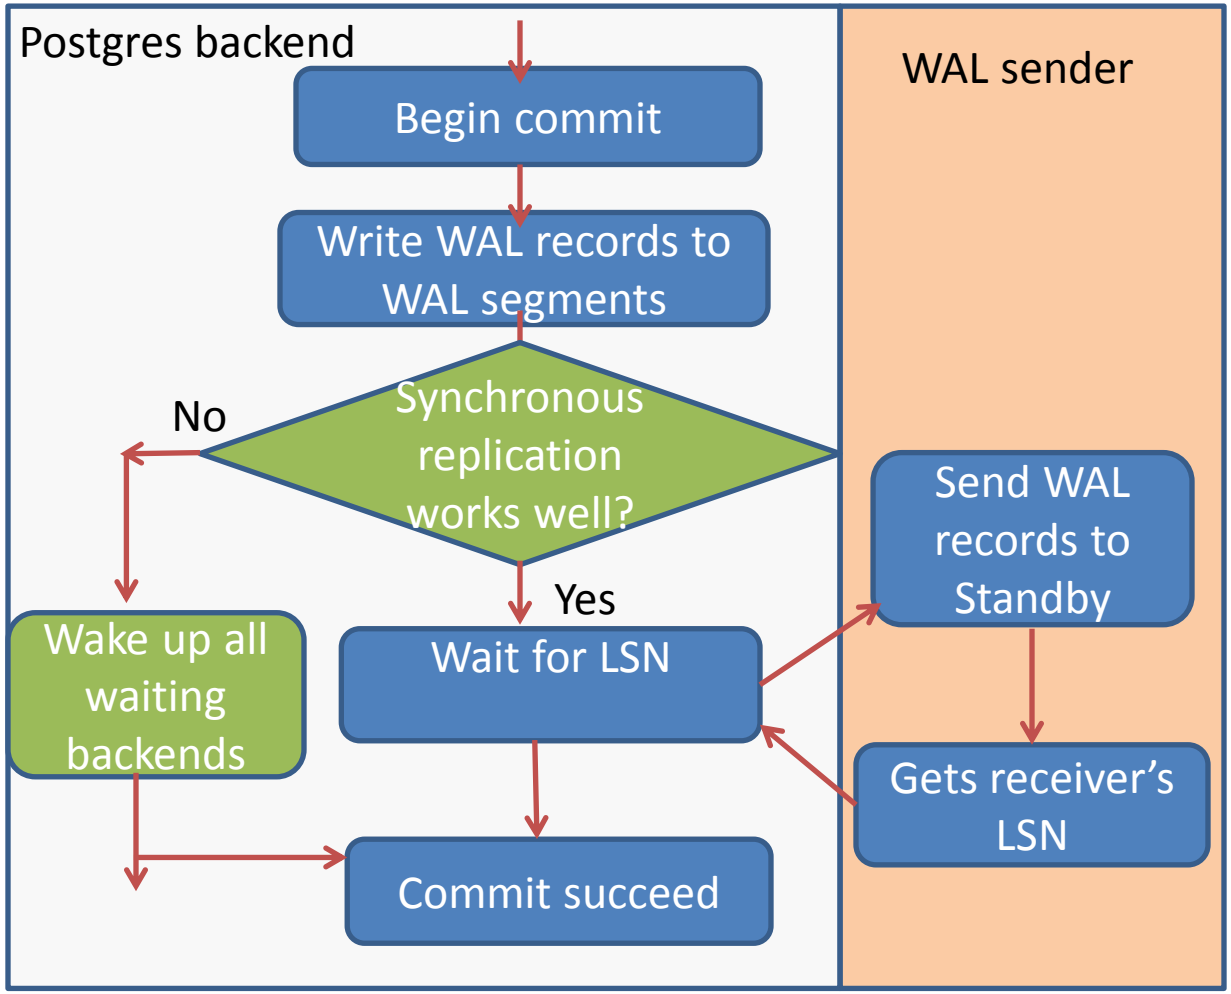

同步流复制状态检查

- 流复制会话建立时，即新的WAL sender产生，对应的WalSnd.pid 设置成WAL sender的PID，非0。
- WAL sender通信超时，退出，其WalSnd.pid设置为0。
- 当所有同步的WalSnd.pid都为0时，同步流复制变为不可用。

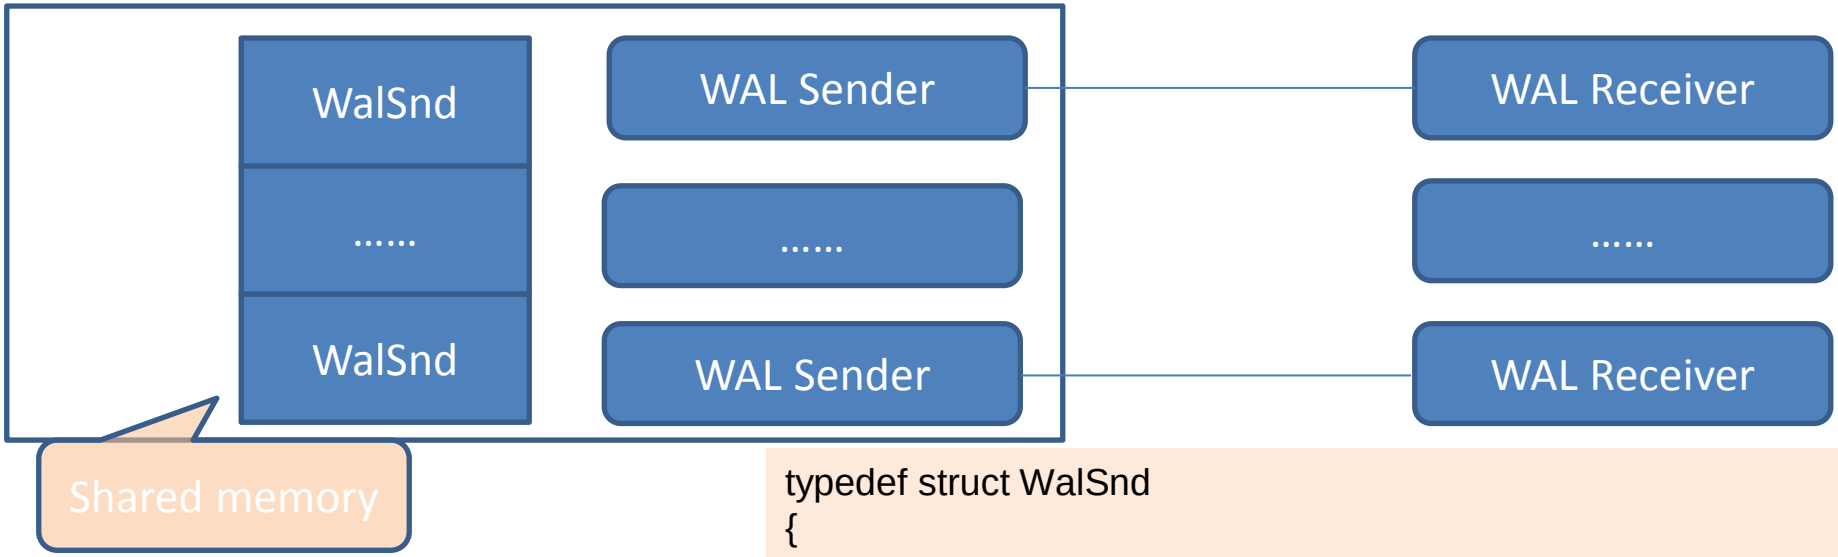


```
typedef struct WalSnd
{
    pid_t       pid;            /* this walsender's process id, or 0 */
    WalSndState state;          /* this walsender's state */
    XLogRecPtr  sentPtr;        /* WAL has been sent up to this
point */
} WalSnd;
```

Synchronous to Asynchronous

- 条件检查和动作：如果WalSnd[…]中，所有同步模式的pid都是0，则唤醒所有等待中的事务，进入异步模式。

- 每次提交事务，做上述检查。
- 每当流复制通信超时，关闭该会话，WAL sender退出，做上述检查。

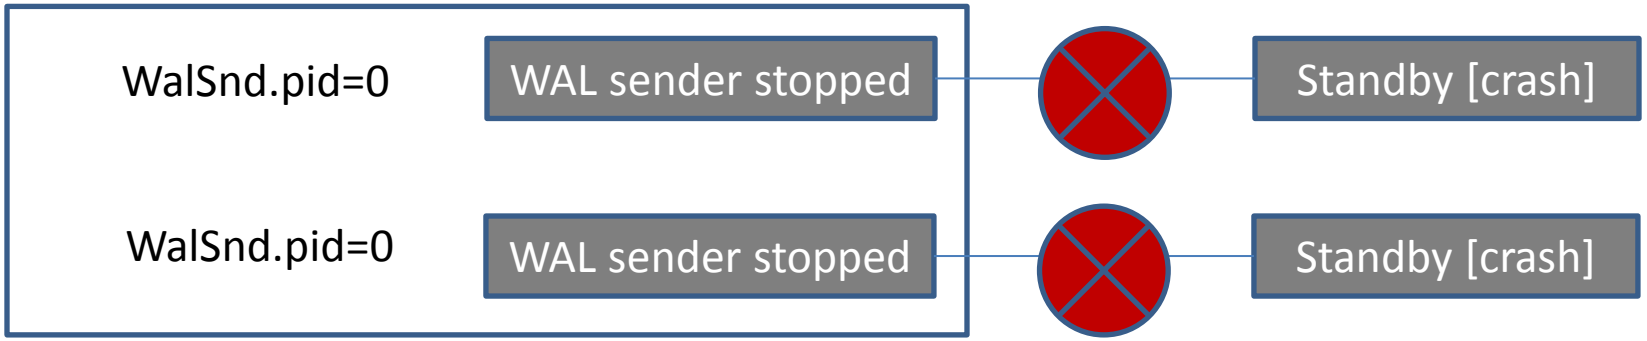

所有同步模式的standby都出故障了

Asynchronous to Synchronous

- 条件检查和动作：当至少一个同步的Standby连接上来。即：当一个WAL receiver发送请求，建立连接，对应的WAL sender进程产生，其对应的WalSnd.pid变为有效值（非0）。
- 如果刚刚连接上来的standby落后的WAL日志如果太多，还不能变为同步模式，必须等待该Standby通过流复制，追平Primary WAL日志。WAL sender和对应的WAL reciever之间的LSN差小于配置参数: adaptive_sync_repli_lsn_catchup=8192。

- 每次提交事务，做上述检查。
- 每当一个新的WAL sender运行，做上述检查。
- 每当一个同步的WAL sender收到WAL receiver的应答。

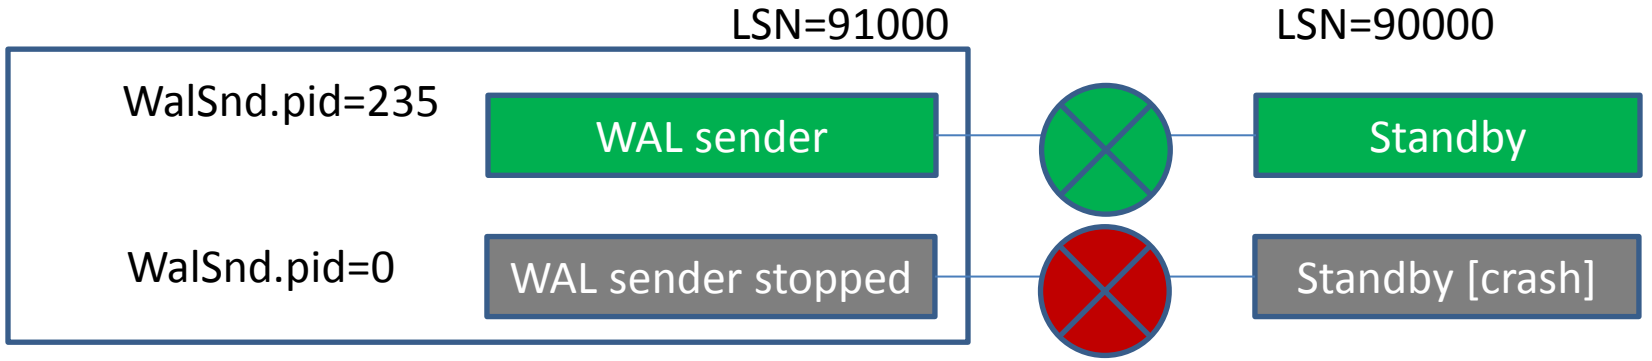

至少一个同步Standby恢复了，并且LSN追上来了

实现细节:1

postgresql.conf
==========
adaptive_sync_repli_flag=on/off #这个开关控制一切功能，只有这个开关#打开，新增功能才工作，否则，所有新增代码都不运行。

adaptive_sync_repli_lsn_catchup=8192 #有异步切换到同步时，standby落后的LSN要小于这个值

共享内存中的变量
==========
Bool adaptive_sync_repli_flag=true/false #对应配置参数adaptive_sync_repli_flag。
Int adaptive_sync_repli_lsn_catchup=8192 #对应配置参数adaptive_sync_lsn_catchup。
Int adaptive_sync_repli_status=(adaptive_sync, adaptive_async, disabled)
WalSnd {
  XLogRecPtr standbyLSN; //WAL receiver收到的最新新的LSN，WAL sender就能知道Standby落后了多少LSN.
}

实现细节:2

SyncRepWaitForLSN()进入等待前的检查

```
SyncRepWaitForLSN(XLogRecPtr XactCommitLSN){

    如果adaptive_sync_repli_flag=true
    {
        检查所有的同步WAL sender， WalSnd[]
        如果存在至少有一个同步WAL sender,WalSnd.pid非0
        {
            if(adaptive_sync_repli_status==adaptive_sync/*自适应同步模式*/) {
             //本来就是同步模式，不做什么， SyncRepWaitForLSN()将执行旧的逻辑
             } else if(adaptive_sync_repli_status==adaptive_async/*自适应异步模式*/) {
                 if( ( myLSN-WalSnd.standbyLSN )<adaptive_sync_repli_lsn_catchup ) {
                     adaptive_sync_repli_status==adaptive_sync; //异步到同步，
                                 //SyncRepWaitForLSN()将执行旧的逻辑
                 } else {
                     //仍然处于自适应异步模式
                    wakeup_all_transactions(); //唤醒所有等待中的backend进程
                    return; //不执行SyncRepWaitForLSN()将执行旧的逻辑
                 }
             }
        }
        否则，如果没有同步WAL sender存在
        {
             if(adaptive_sync_repli_status==adaptive_sync/*当前是自适应同步模式*/)
             {    //同步变异步
                  wakeup_all_transactions(); //唤醒所有等待中的backend进程
                  adaptive_sync_repli_status==adaptive_async
             }
             return;//不执行SyncRepWaitForLSN()将执行旧的逻辑即不等待。
        }
    }

    //SyncRepWaitForLSN后续正常处理
    ....
    ....
    ....
}
```

实现细节:3

WAL sender进程产生，并开始工作时，做检查。
异步切换到同步。

```
如果adaptive_sync_repli_flag=true
{
    检查所有的同步WAL sender
    如果没有其它同步WAL sender存在
    {
        if(adaptive_sync_repli_status==adaptive_async/*自适应异步模式*/) {
            //如果当前是异步模式，则有可能切换到异步模式
          if( ( myLSN-WalSnd.standbyLSN )<adaptive_sync_repli_lsn_catchup ) {
              adaptive_sync_repli_status==adaptive_sync; //异步到同步，
          }
        }
    }
}
```

实现细节:4

WAL sender进程退出之前，做检查。
同步切换到异步。

```
如果adaptive_sync_repli_flag=true
{
    检查所有的同步WAL sender
    如果没有其它同步WAL sender存在
    {
        if(adaptive_sync_repli_status==adaptive_sync/*自适应同步模式*/) {
            //如果当前时同步模式，则切换到异步模式
            adaptive_sync_repli_status=adaptive_async;
            唤醒所有等待中的backend进程
            wakeup_all_transactions();
        }
    }
}
```

Thanks!

Q & A

山东瀚高基础软件股份有限公司