OpenResty构建
一站式应用网关实践分享

聂永 王辉 @新浪微博

目录

一、网关概述

概述

- 一站式应用网关服务
- 上行请求
  - 代理
  - 聚合
- 下行推送
- TCP/TLS/HTTP/HTTPS/QUIC

背景

- 网络链路优化，实践见真知
- 新业务，需求、改动频繁
- 人员少，任务重

选择

- Erlang招人难、学习成本高
- Go、Java，当前业务开发效率问题

为什么是OpenResty？

- Nginx+Lua，速度快性能强
- 学习成本低，快速开发，应用广泛
- 支持TCP & HTTP
- 降低运维成本

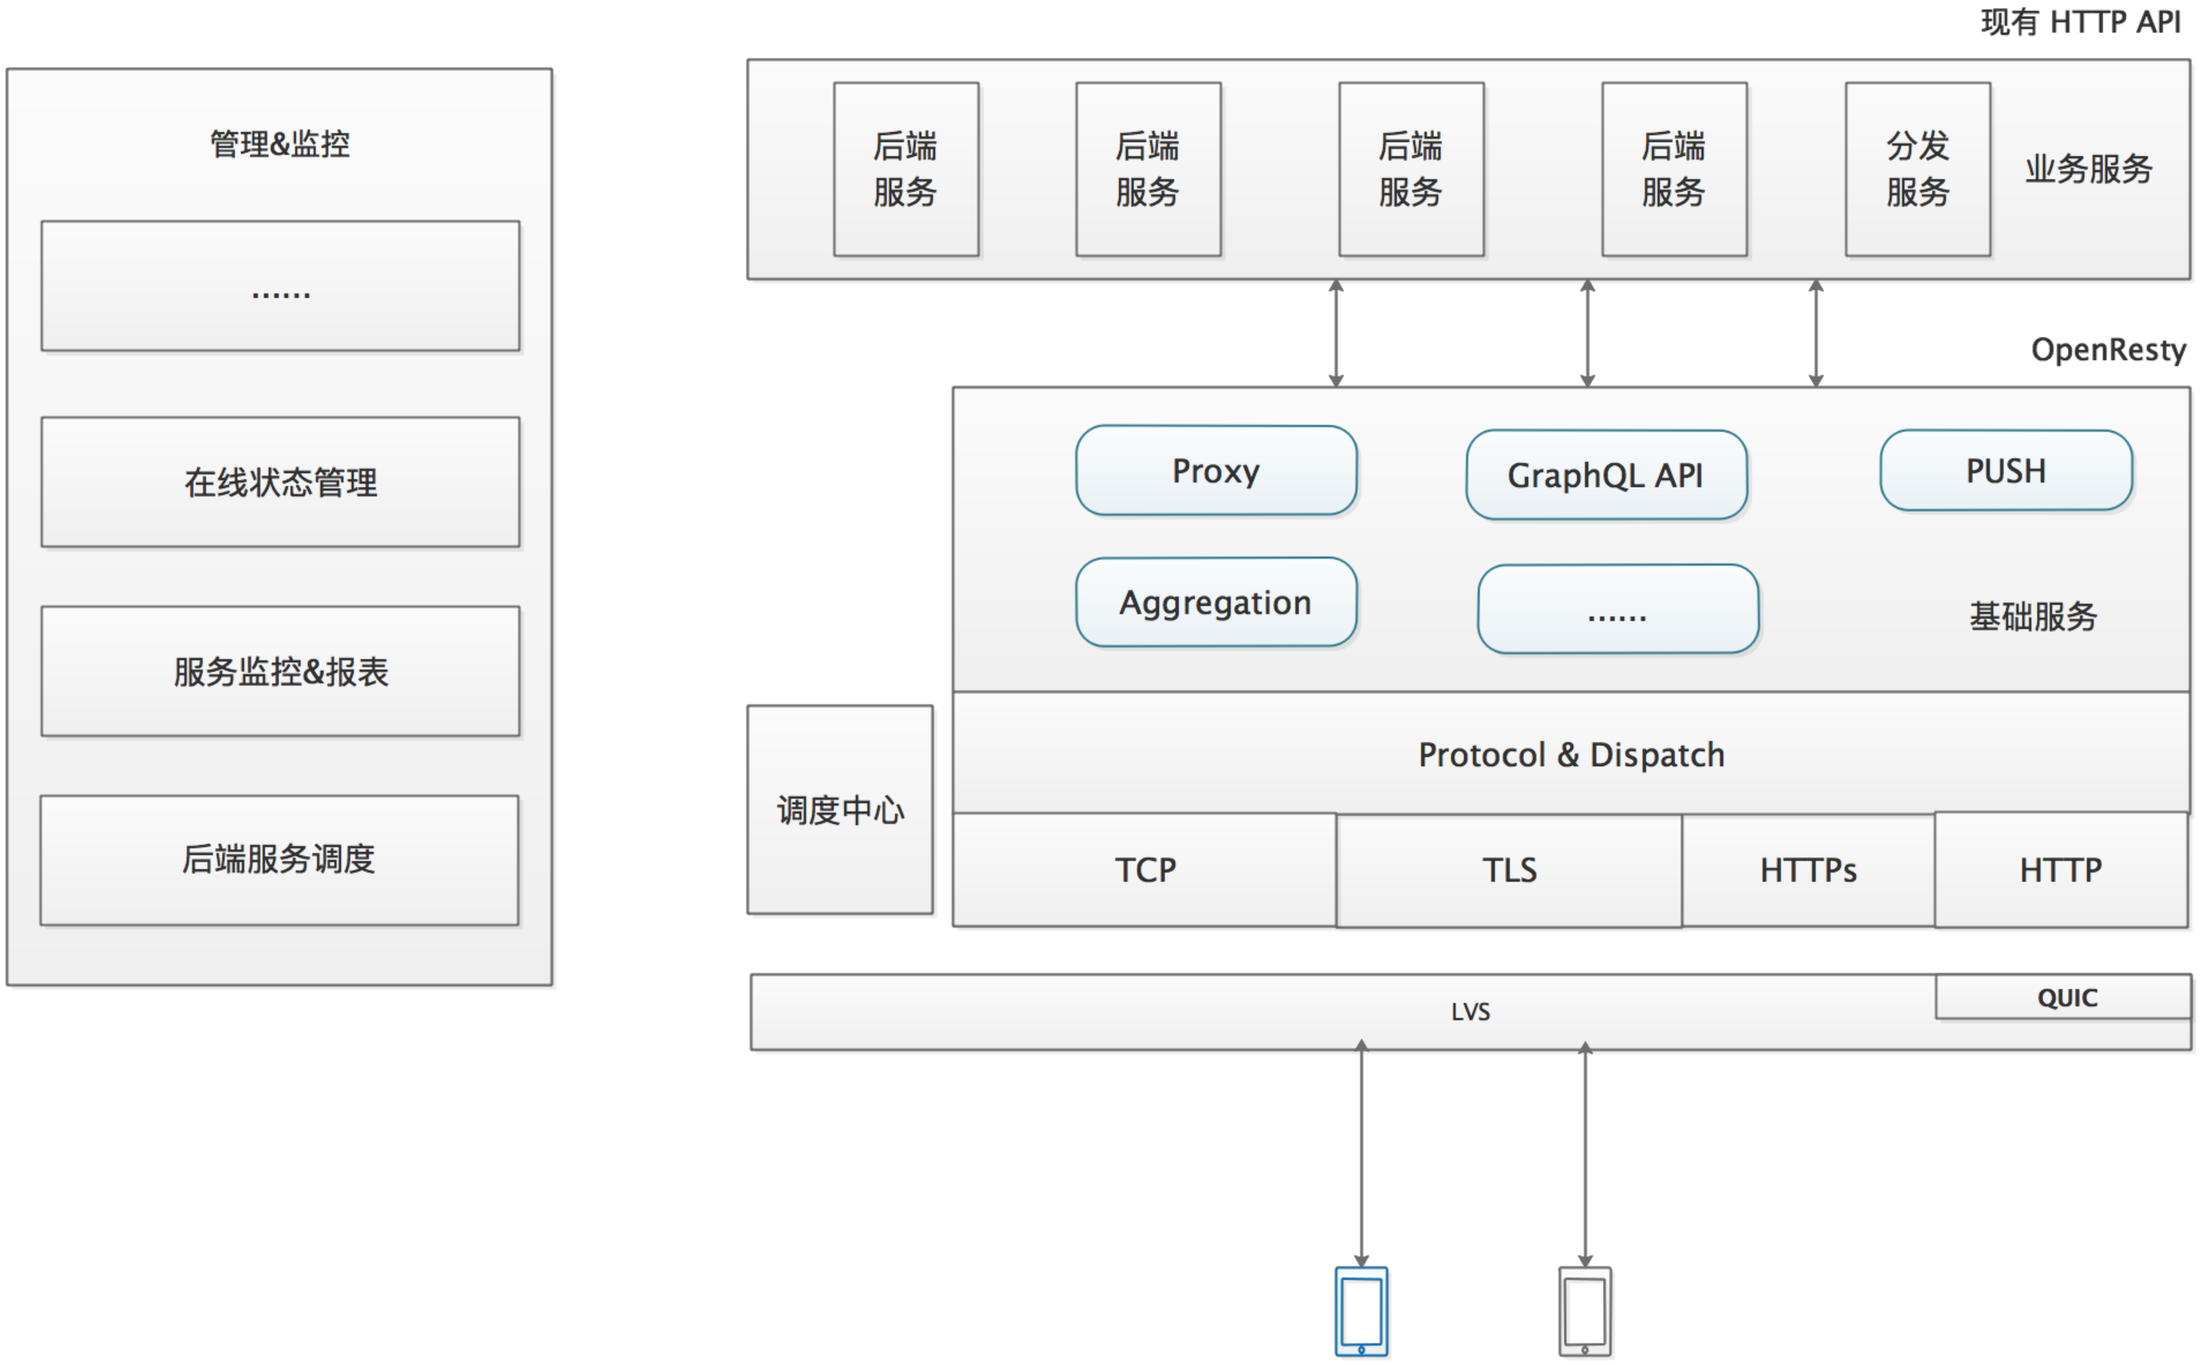
现有 HTTP API
后端服务
后端服务
后端服务
后端服务
分发服务
业务服务
OpenResty
Proxy
GraphQL API
PUSH
Aggregation
.....
基础服务
Protocol & Dispatch
调度中心
TCP
TLS
HTTPs
HTTP
LVS
QUIC
管理&监控
.....
在线状态管理
服务监控&报表
后端服务调度

业务流程

- 所有通道，统一协议
- 代理部分，请求&转发
- 聚合功能，后端多业务聚合，统一输出

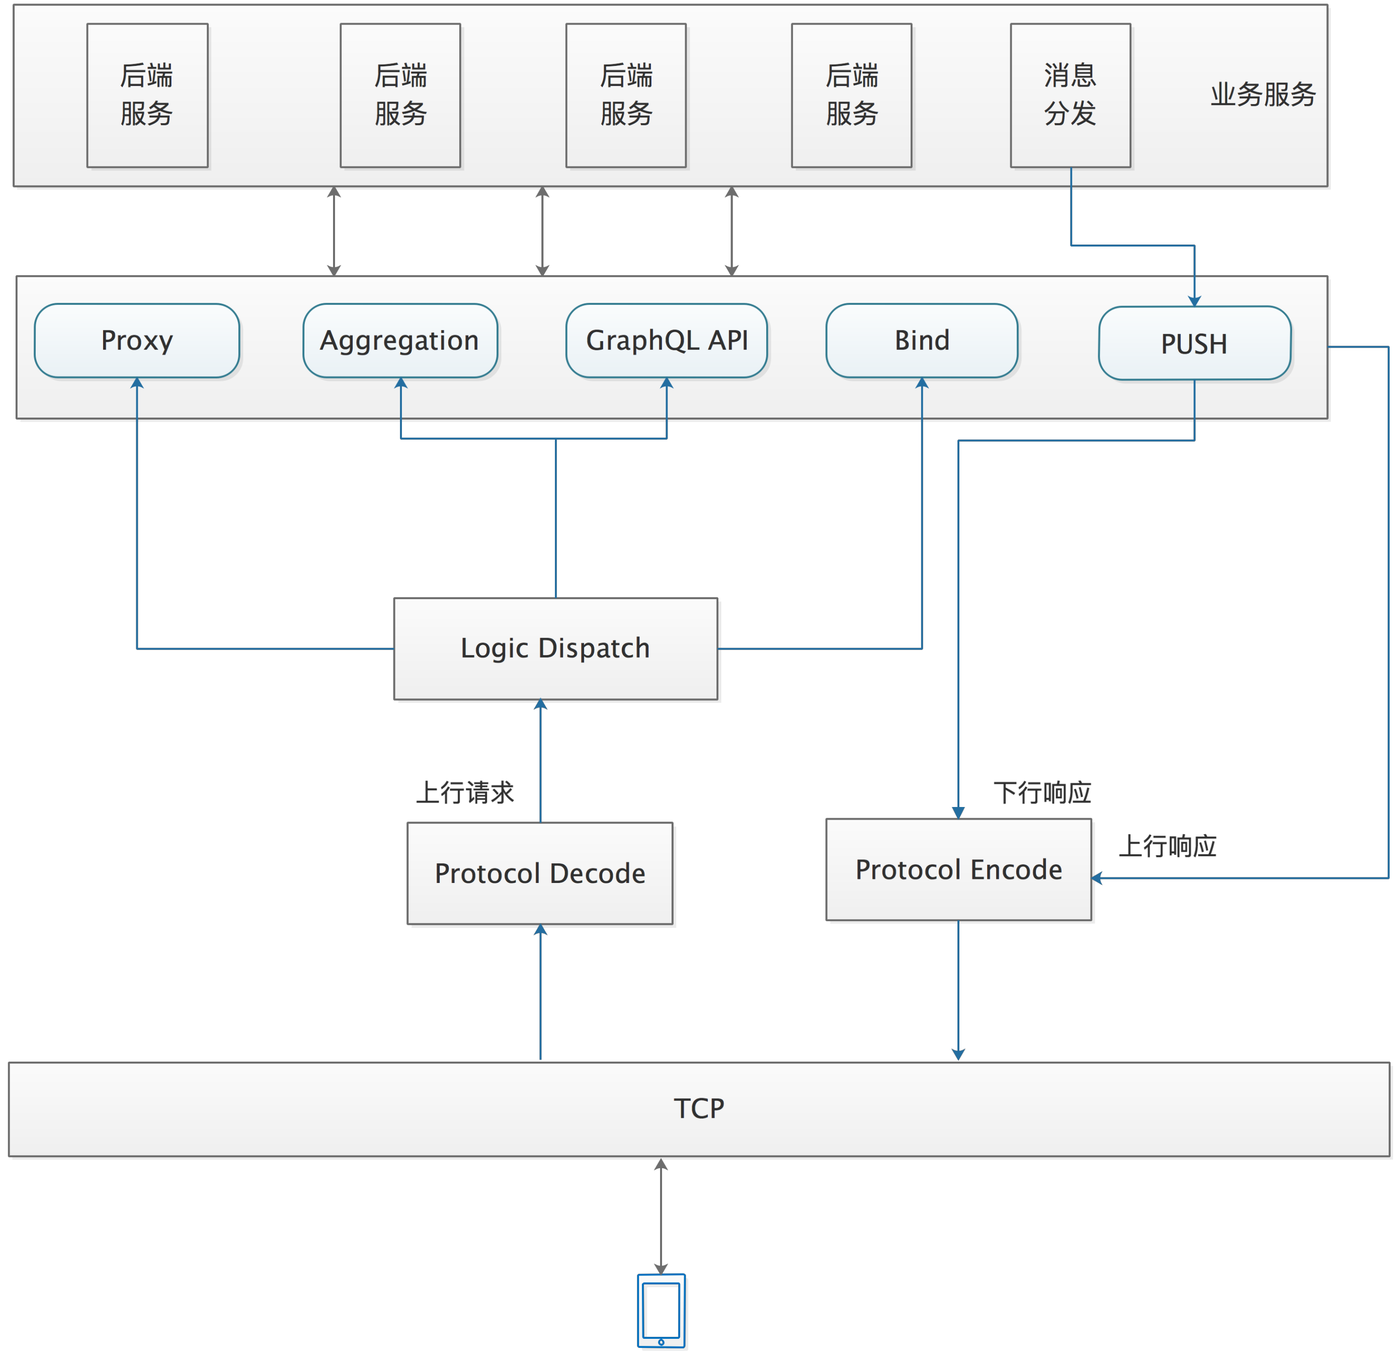

二、问题 & 解决

1. TCP不支持Lua Semaphore API

- 目前仅提供HTTP版本
- 长连接下推需要使用到
- 解决方式
  - https://github.com/openresty/lua-resty-core/issues/94

2. CJSON-大数

- 使用CJSON进行json的编解码

- API中有64位整数型，会自动被修正为科学计数法

```
Lua 5.1.5  Copyright (C) 1994-2012 Lua.org, PUC-Rio
> num = 232565634353635
> print(num)
2.3256563435364e+14
>
```

- 增加大数支持：https://github.com/yongboy/lua-cjson

  - cjson.decode_big_numbers_as_strings(true|false)

CJSON-数组和对象

- Lua，数组和对象使用table表示
- table转换JSON
- 数组 **[ ]**？结构**{ }**？同时存在？

```lua
local cjson = require "cjson"
local ori = {name = "array & object", array = {}, object = {}}

-- 1. 指定某个key为空数组，推荐
setmetatable(ori.array, cjson.empty_array_mt)
ngx.say(cjson.encode(ori))
-- output: {"array":[],"object":{},"name":"array & object"}

-- 2. 统一全局设置需要编码成数组
cjson.encode_empty_table_as_object(false)
ngx.say(cjson.encode(ori))
-- output: {"array":[],"object":[],"name":"array & object"}

-- 3. 下面情况，全局设置默认覆盖局部设置
setmetatable(ori.object, cjson.object)
ngx.say(cjson.encode(ori))
-- output: "array":[],"object":[],"name":"array & object"}
```

CJSON Decode性能

- 一定压力下，已暴露 decode 占用CPU过高问题
- 已着手使用 lua-resty-json 替换

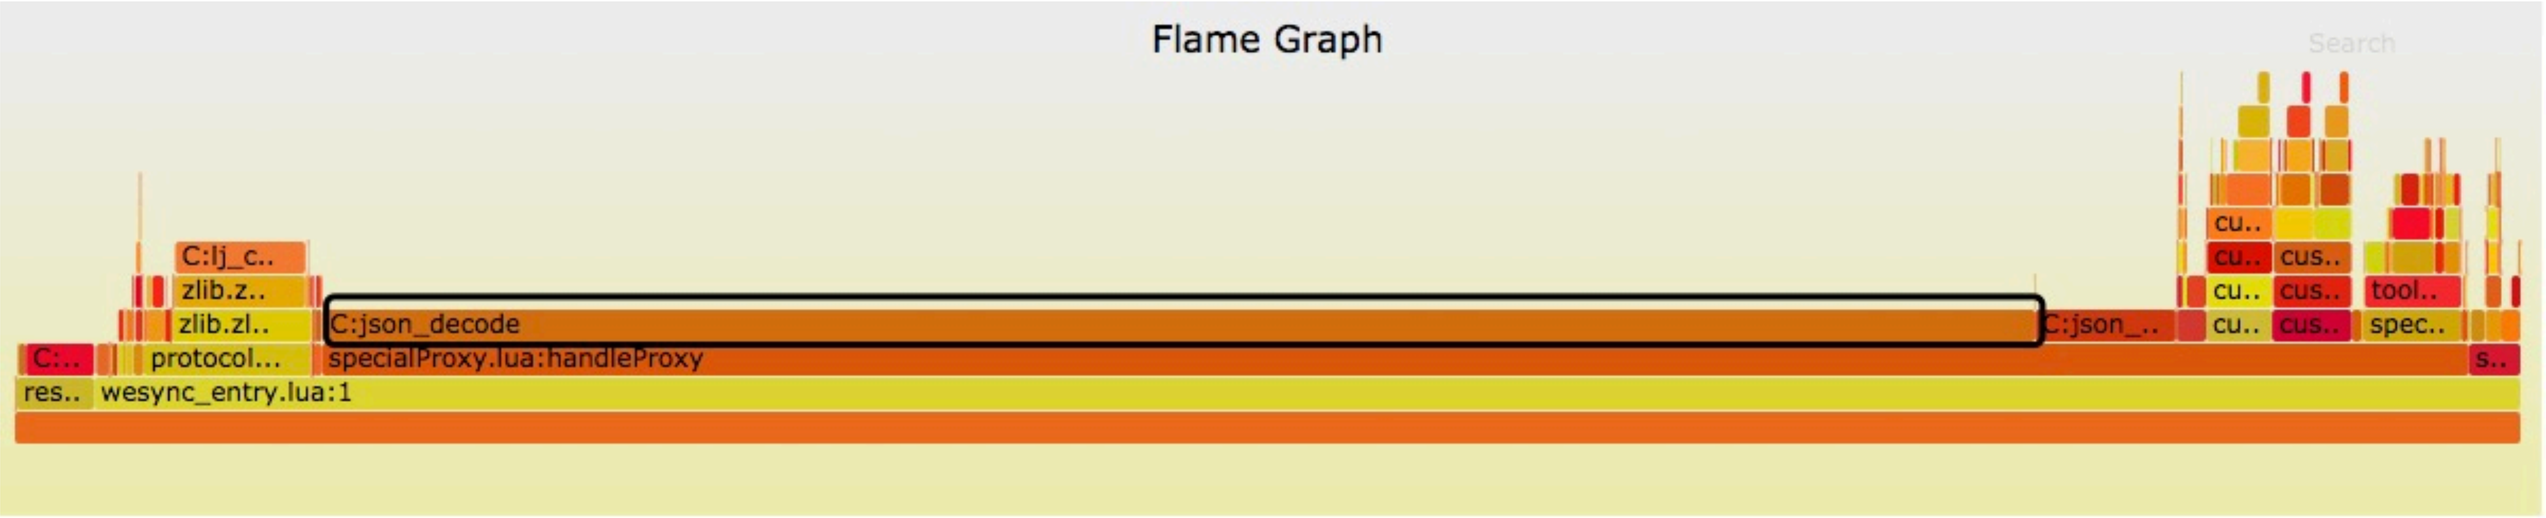

3. 日志传输

- https://github.com/cloudflare/lua-resty-logger-socket
- UDP传输消息的上限
  - 警告：**send() failed (90: Message too long)**
  - 单个UDP数据包不能大于65507字节长度！
  - 消息裁剪！
  - cat /proc/sys/net/core/wmem_max
- 自动刷新
  - 警告：**logger buffer is full, this log message will be dropped**
  - periodic_flush
- newline换行符号

```lua
local logger = require "resty.logger.socket"
local ngx_log = ngx.log

local function do_log(msg)
    if not logger.initted() then
        ngx_log(ngx.INFO, "init logger")
        local ok, err = logger.init{
            host = '10.10.10.10',
            port = 5143,
            flush_limit = 1024,
            -- UDP包最大负荷长度: 2^16 - 1 - 20 - 8 = 65507字节
            drop_limit = 65507,
            -- 每秒钟刷新频率，适用于日志产生频繁环境
            periodic_flush = 0.001,
            sock_type = 'udp'
        }
        if not ok then
            ngx_log(ngx.ERR, "failer to initialize the logger: ", err)
        end
    end

    if #msg >= 65507 then
        msg = string.sub(msg, 1, 65506)
    end

    msg = msg .. "\n"

    local _, err = logger.log(msg)
    if err then
        ngx_log(ngx.ERR, "failed to log message: ", err)
    end
end
```

日志产生过快

- 压力大，UDP忙不过来了
  - failed to log message: too many pending timers
- 处理方法
  - 回退到磁盘日志模式，极可能的保证不丢失

```
error_log syslog:server=10.10.10.10:3514 notice;
error_log logs/error.log error;
```

  - 提高日志等级，减少输出量
  - 合并日志，减少输出次数

4. TCP Server glibc内存不释放问题

- 老问题：https://moonbingbing.gitbooks.io/openresty-best-practices/something/2016_10_1.html
- glibc malloc & free & malloc_trim
- 最偷巧方式
    1. 增加HTTP节点
    2. 配置 lua_malloc_trim 1;
    3. 经常周期性访问HTTP接口

Demo

TCP通道压测后

```
  PID USER      PR  NI    VIRT    RES    SHR S  %CPU  %MEM     TIME+ COMMAND
10983 nobody    20   0  987m 382m 2300 S   0.0   2.4   2:36.23 nginx: worker process
```

调用HTTP API接口后

```
  PID USER      PR  NI    VIRT    RES    SHR S  %CPU  %MEM     TIME+ COMMAND
10983 nobody    20   0  987m 164m 2472 S   0.3   1.0   2:36.24 nginx: worker process
```

还可以定时释放

- 请求不均匀，效果不理想
- 基于FFI的glibc.malloc_trim(1)
- Code: lua_malloc_trim.lua
- 每worker定时触发
- init_worker_by_lua_file *.lua

```lua
local ffi = require "ffi"
local glibc = ffi.load("c")

if ffi.os == "Windows" then
    ngx.log(ngx.ALERT, "DOES NOT SUPPORT windows")
    return
elseif ffi.os == "OSX" then
    ngx.log(ngx.ALERT, "DOES NOT SUPPORT MAC OS X")
    return
end

ffi.cdef[[
    int malloc_trim(size_t pad);
]]

-- eg: glibc.malloc_trim(1)
```

5. GraphQL API

- HTTP API接口兼容版本以及各种特殊业务需求，变得越来越重
- 使用GraphQL API一般可为客户端节省至少50%网络下行流量
- 已经服务于某微博版本

5.1 易用性定制

- 增加GraphQL API Client兼容性，方便调试
- 修复需要时得不到InputObject参数的BUG
- 修复指令和参数不协作的BUG
- https://github.com/yongboy/graphql-lua

6. CPU过高问题

- 业务处理低效性能出现问题
  - 请求高，CPU占用100
- 发现瓶颈
  - 横向宽度大平顶
  - 纵向调用层级深度

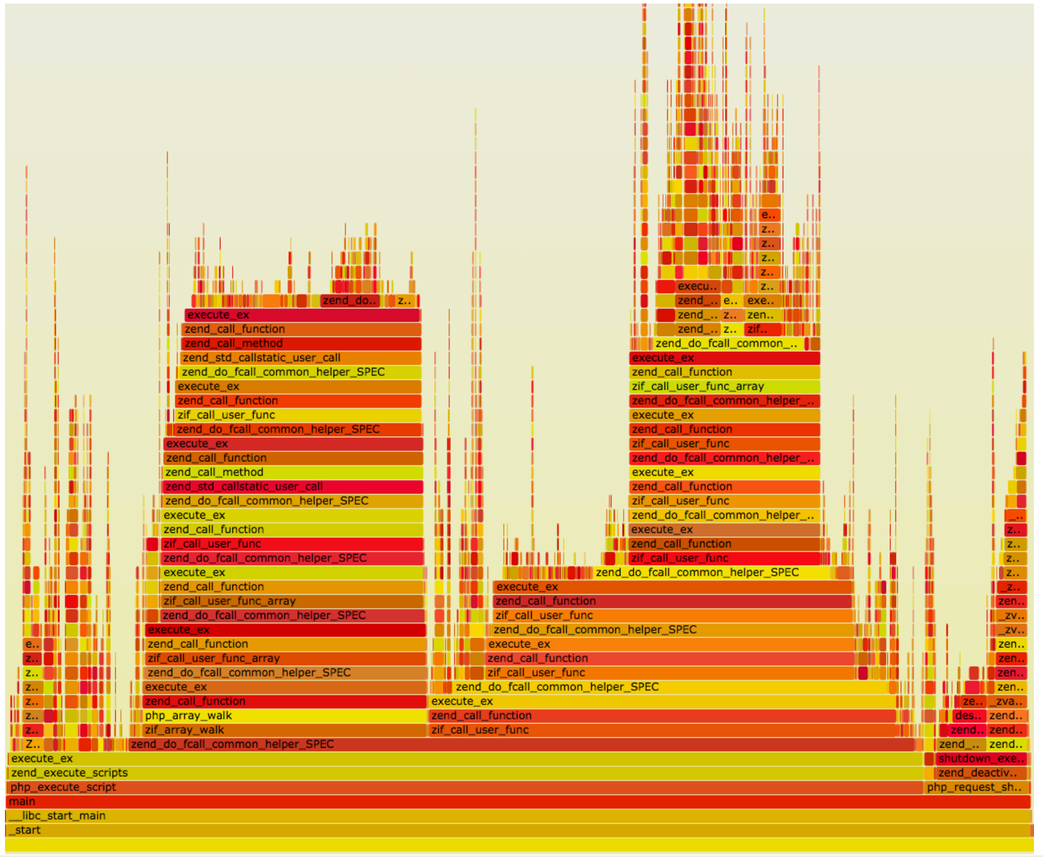

7. 内存火焰图

- 多次采样对比
  - eg：一次300秒，一次500秒
  - 小心对比，寻找增加宽度的可疑点
- 大处着眼，小处着手，谨慎寻找异样的输出

Demo

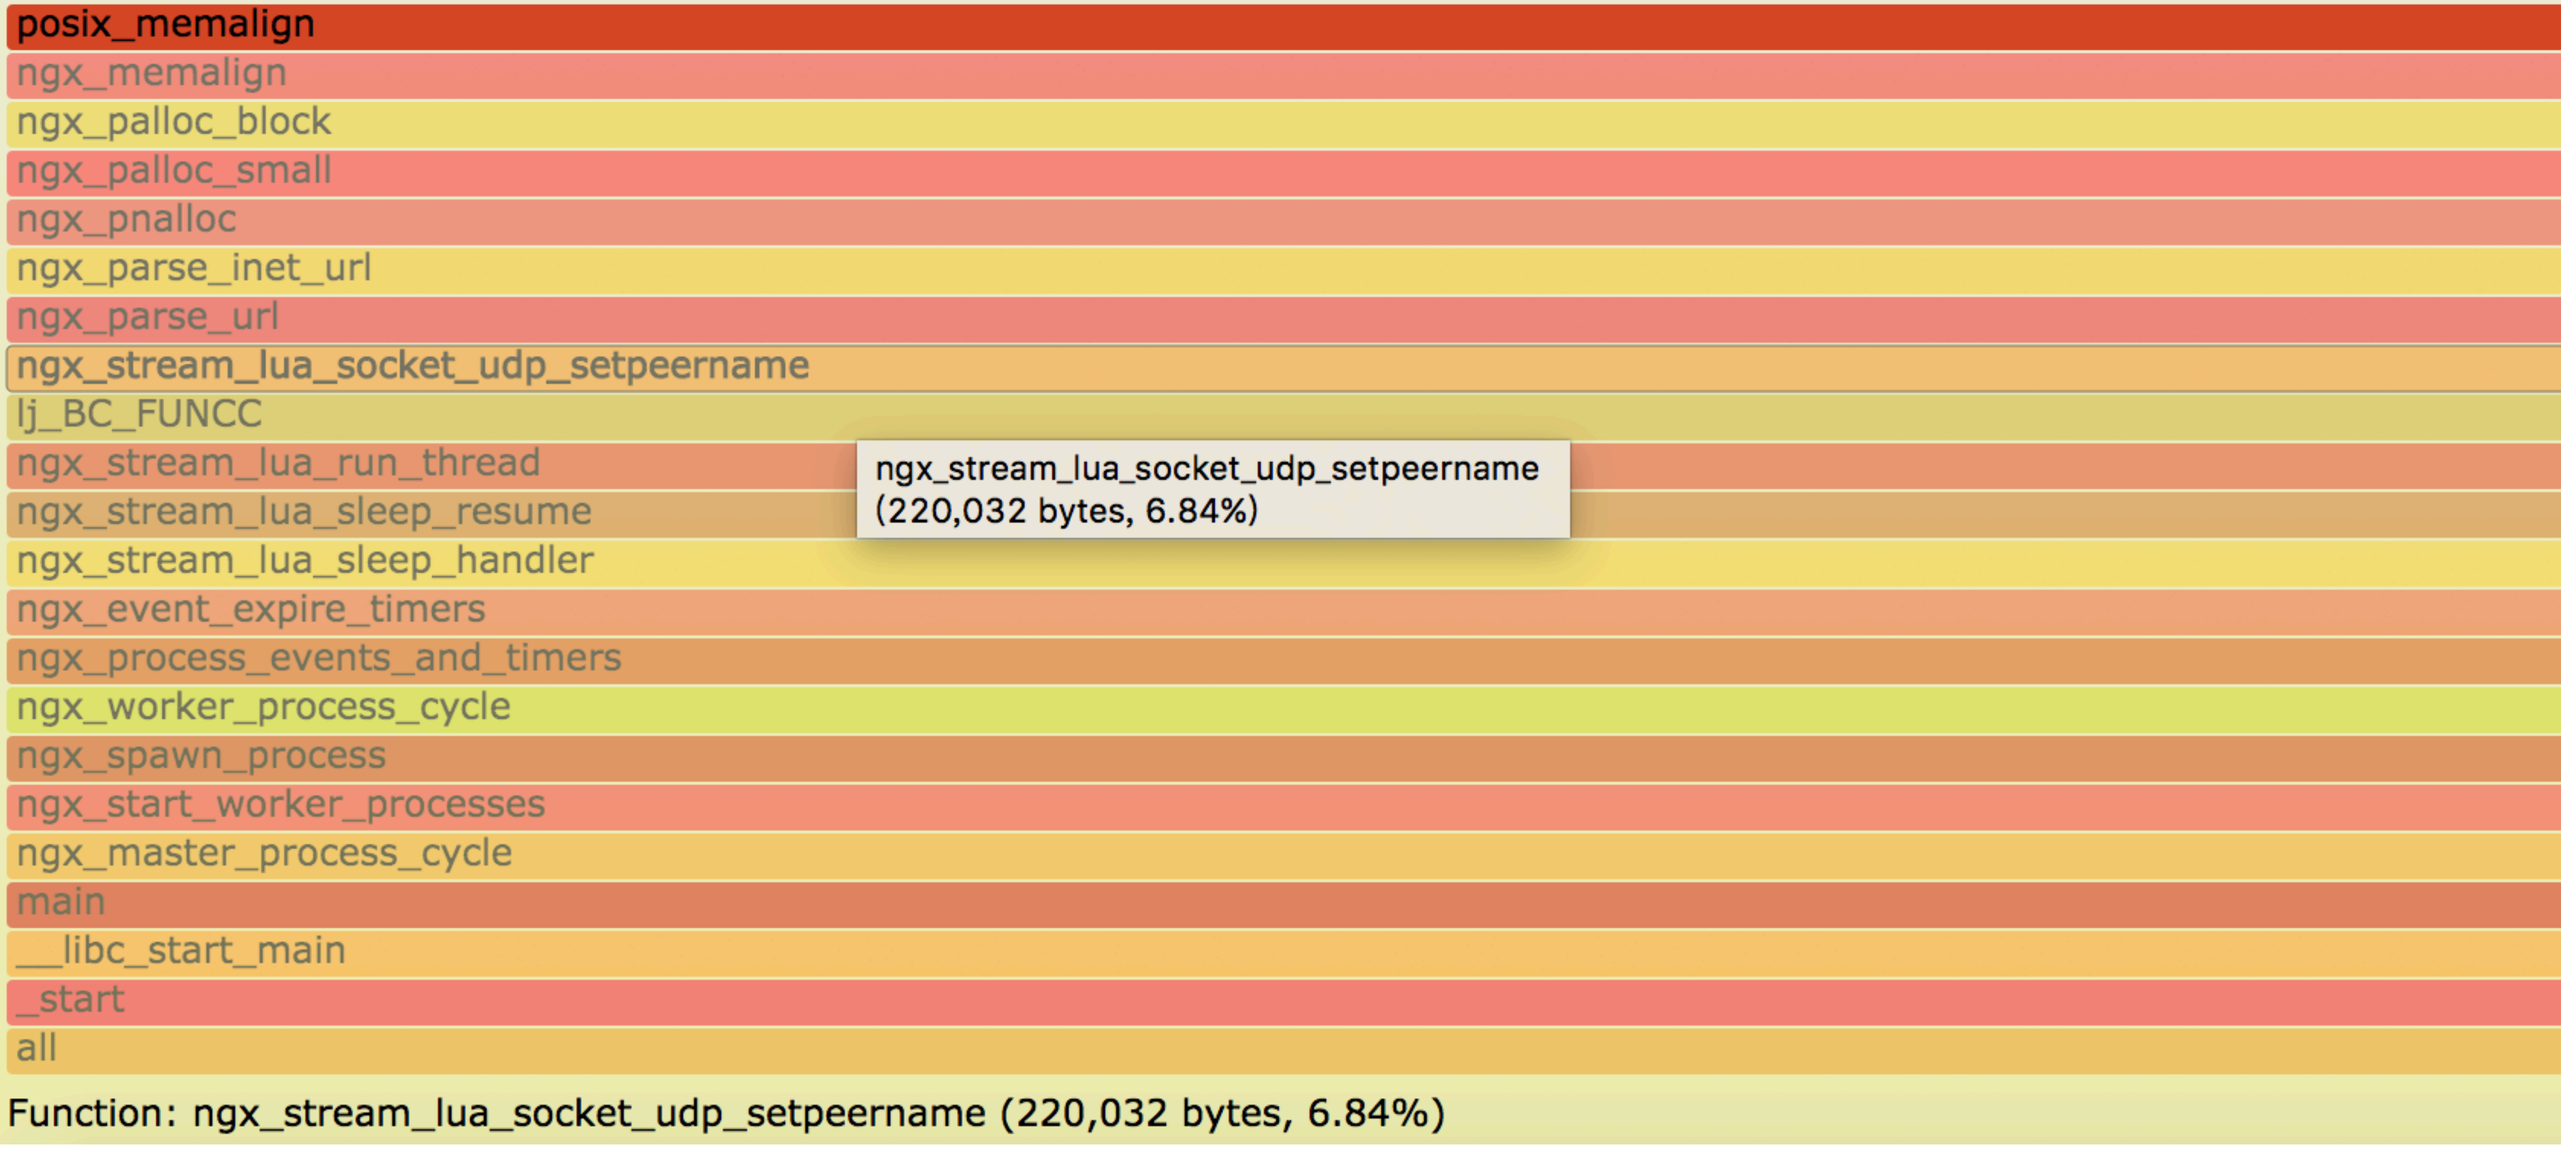
posix_memalign
ngx_memalign
ngx_palloc_block
ngx_palloc_small
ngx_pnalloc
ngx_parse_inet_url
ngx_parse_url
ngx_stream_lua_socket_udp_setpeername
lj_BC_FUNCC
ngx_stream_lua_run_thread
ngx_stream_lua_sleep_resume
ngx_stream_lua_sleep_handler
ngx_event_expire_timers
ngx_process_events_and_timers
ngx_worker_process_cycle
ngx_spawn_process
ngx_start_worker_processes
ngx_master_process_cycle
main
__libc_start_main
_start
all
ngx_stream_lua_socket_udp_setpeername
(220,032 bytes, 6.84%)
Function: ngx_stream_lua_socket_udp_setpeername (220,032 bytes, 6.84%)

8. 调试依赖

- yum install yum-utils
- yum install kernel-devel
- debuginfo-install kernel

- SystemTap 2.6
- GDB 7.11
- Valgrind 3.13.0
- GCC 4.8 ASAN
- stapx
- openresty-gdb-utils
- openresty-systemtap-toolkit

简化调试

- 目标：降低跟踪调试成本，轻松参与其中
- 一个脚本初始化调试环境
- 一个脚本搞定CPU、内存等资源占用跟踪调试
  - 自动输出调试报告并提供火焰图访问地址
- 仓库地址：https://github.com/yongboy/openresty-debug-tools

9. 压力测试辅助

- HTTP的压力测试选择很多
  - ab、wrk、WebBench、…
- TCP可以选择Tsung
  - 可以模拟线上复杂业务
  - 压力灵活、可持续

三、总结 & 反思

总结

- 接口请求耗时可减少33.6%
- 接口成功率可提升0.6%
- 极速版采样一分钟内可降低用户72.34%流量
- ……

反思

- TCP支持没有HTTP完善
- 针对UDP协议支持还不够充分
  - QUIC，暂时还看不到希望
- 内存管理方面，受限于GLIBC内存不及时释放问题
- socket句柄无法在多个轻量级线程中共享
- Timer数量受限，不要滥用
- 后期学习难度较大

Thank You :))