深入理解BFE

×

章淼

百度智能云
架构师

什么是BFE?

- 百度统一的七层流量转发平台
  - HTTP, HTTPS, HTTP/2, QUIC
- 2012年开始建设
- 每日转发请求约1万亿，日峰值超过1KW QPS
- 2019年，核心转发引擎对外开源
  - BFE => **Beyond Front End**
  - https://github.com/bfenetworks/bfe
- 2020年6月，成为CNCF Sandbox Project
- 2021年5月，《深入理解BFE》对外发布
  - https://github.com/baidu/bfe-book
  - 2021年Q3将由电子工业出版社正式出版

BFE开源项目公众号

GopherChina 2021

目 录

为什么需要BFE？

- 没有统一七层接入的问题
  - 功能重复开发
  - 运维成本高
  - 流量统一控制能力低
- 引入BFE后
  - 功能统一开发
  - 运维统一管理
  - 流量控制能力增强
- BFE平台的主要功能
  - 接入和转发，流量调度，安全防攻击，数据分析

BFE部署前

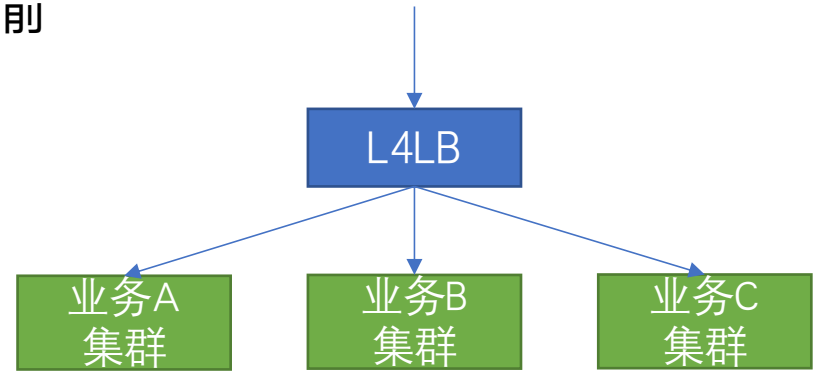

BFE部署后

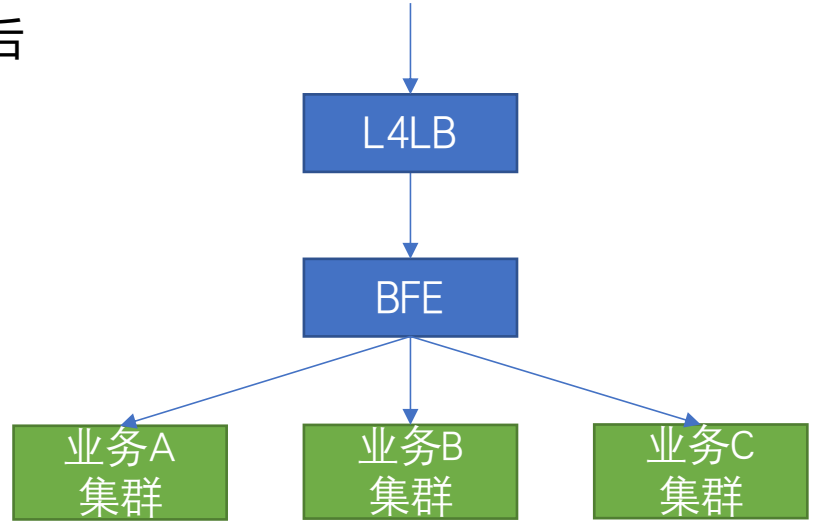

BFE平台架构

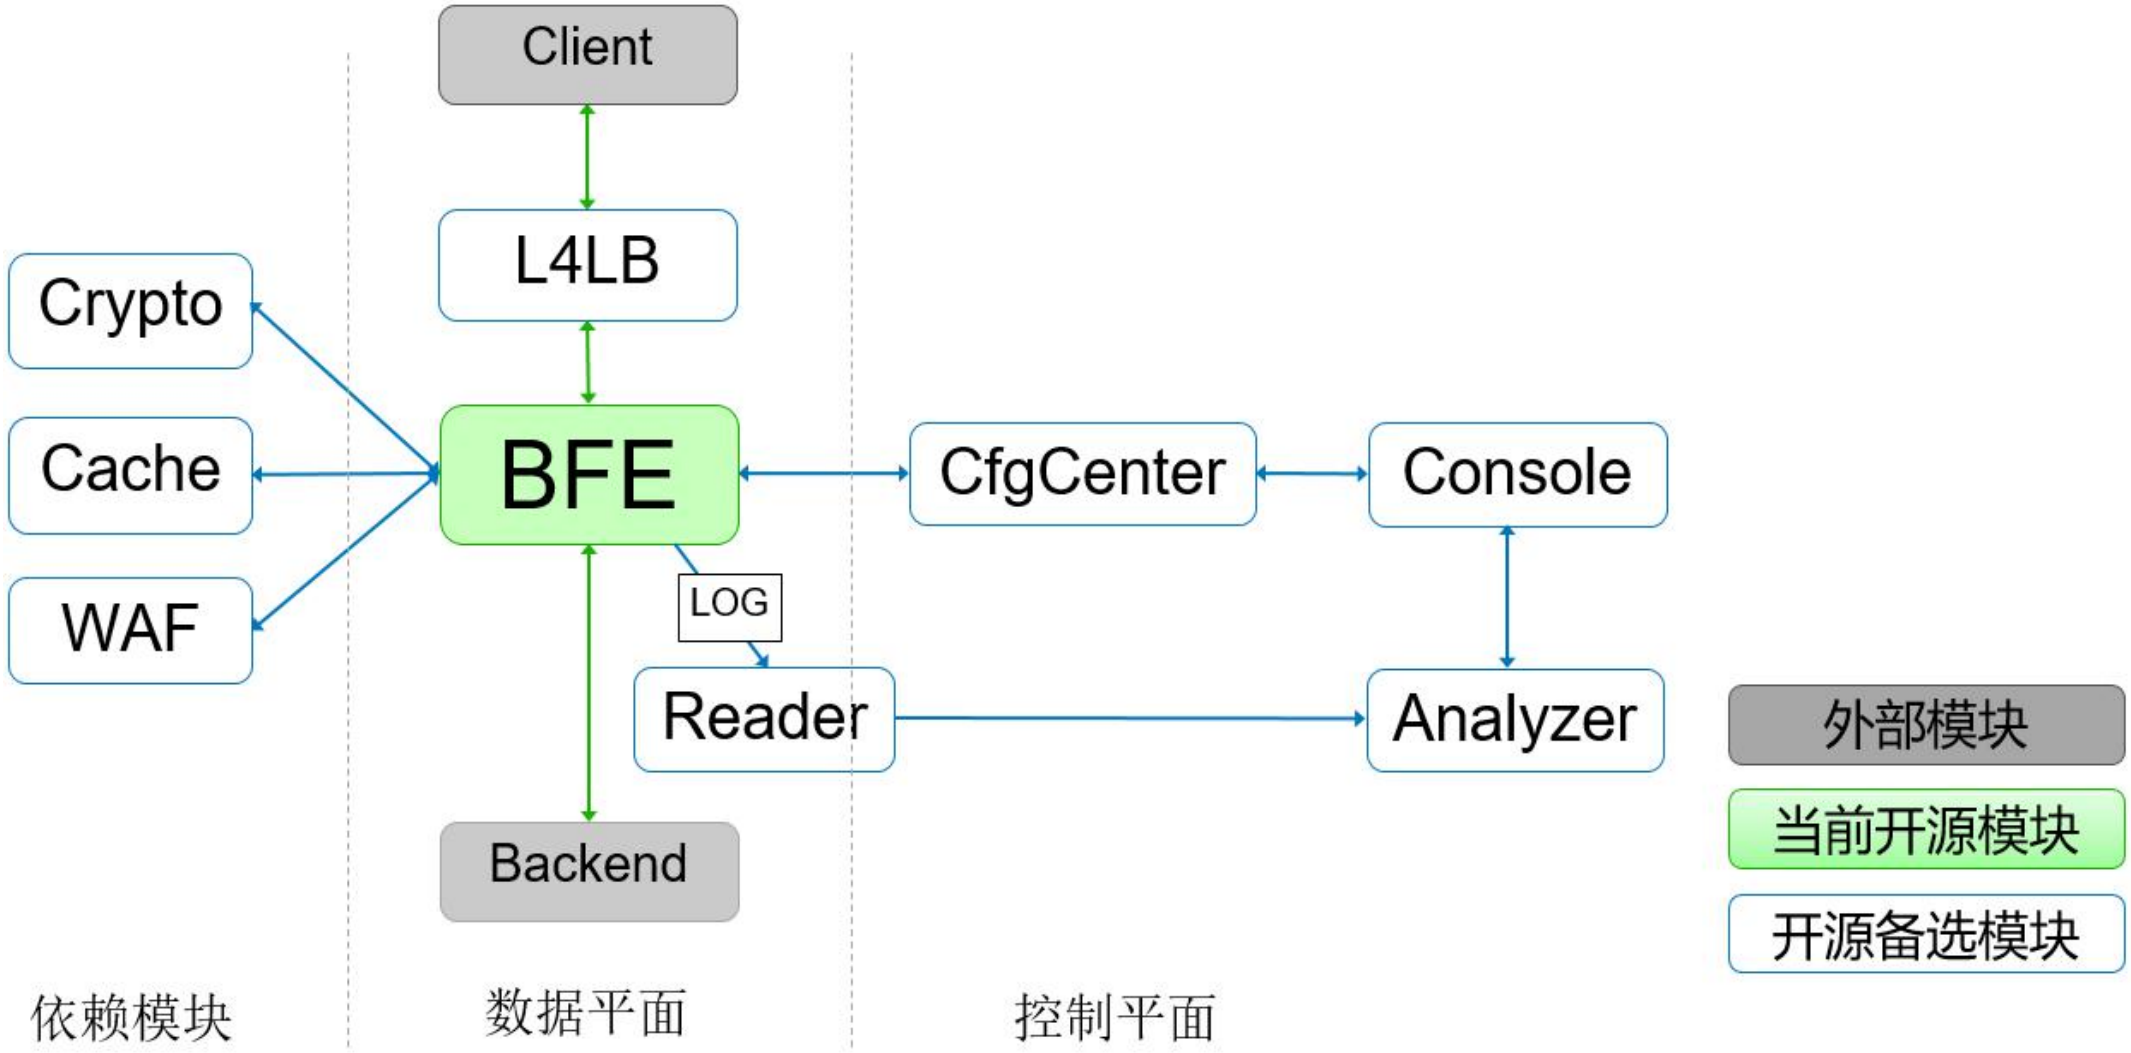
Client
L4LB
Crypto
Cache
WAF
BFE
CfgCenter
Console
LOG
Reader
Analyzer
Backend
外部模块
当前开源模块
开源备选模块
依赖模块
数据平面
控制平面

负载均衡器 vs 名字服务

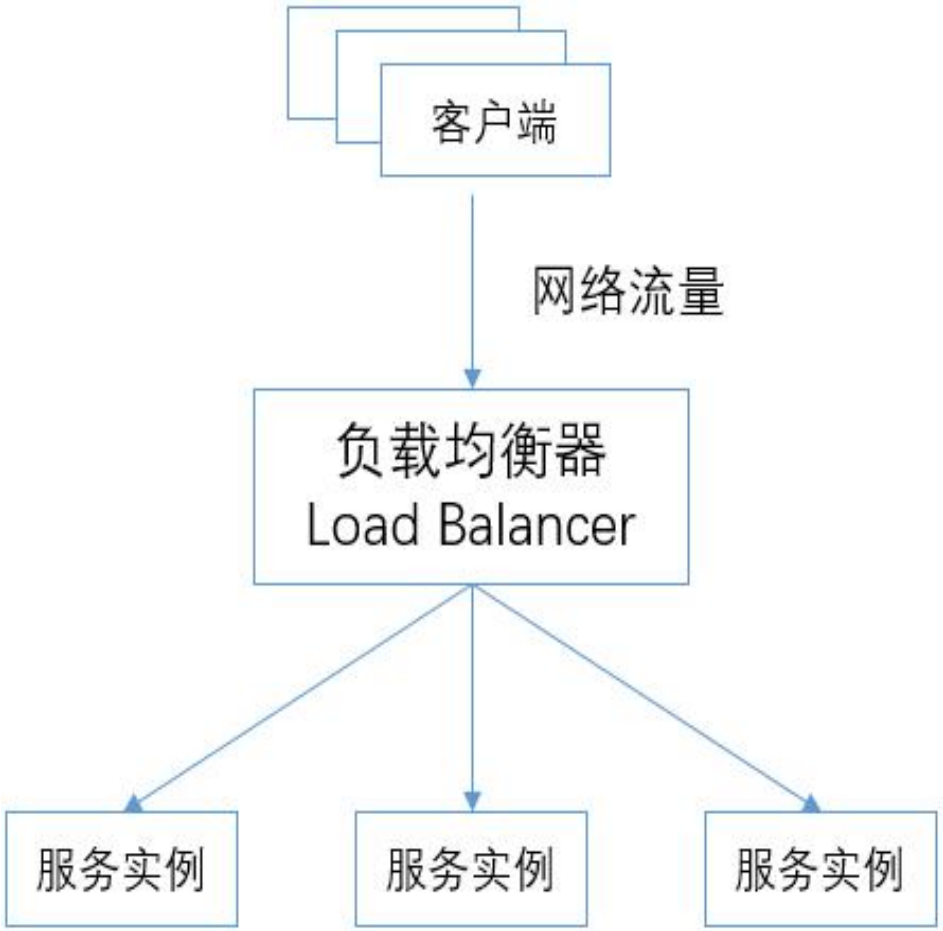

基于负载均衡器

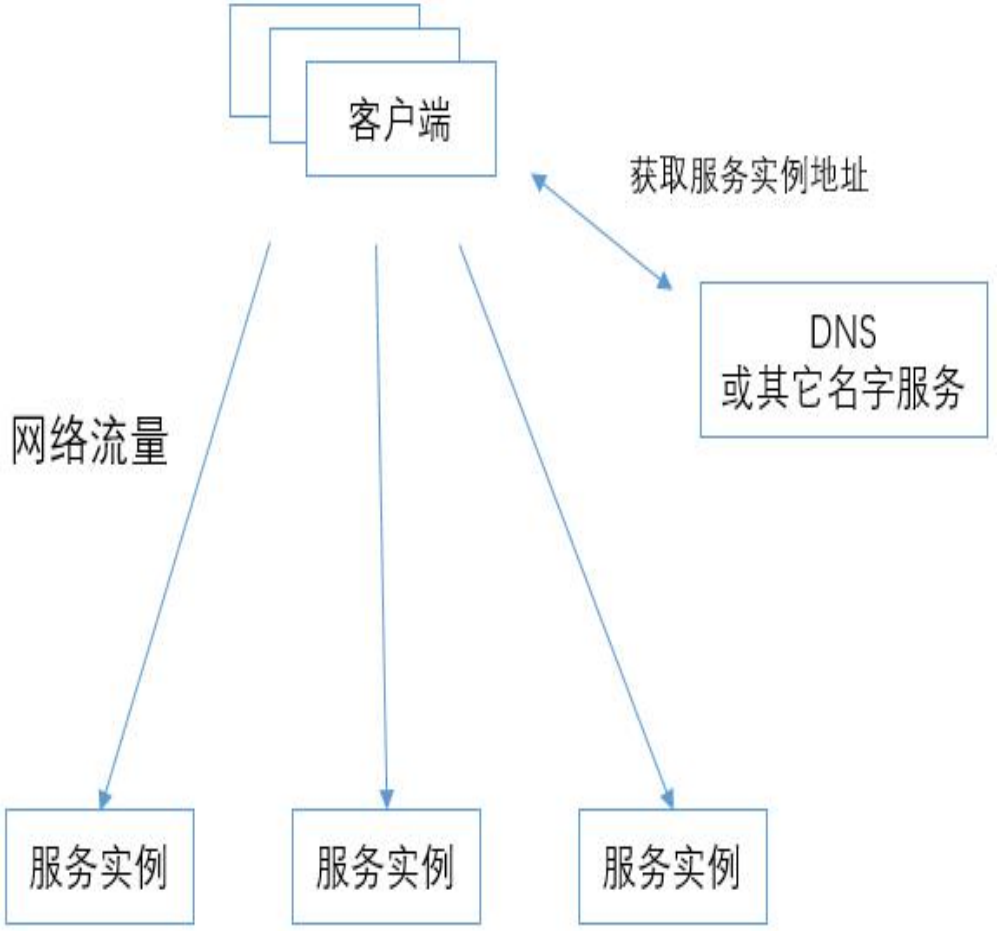

基于名字服务

方案对比

方案	对流量的控制力	资源消耗	对客户端的要求	适用场景
基于负载均衡器	强。可以达到单个连接 / 请求的粒度。	高。负载均衡器引入了额外的资源消耗。	低。客户端基本不需要实现策略。	总体流量规模不大（从负载均衡器资源消耗的角度）；应用场景对流量控制要求高。
基于名字服务 + 客户端策略	弱。客户端直接访问服务，没有可靠的卡控点，无法实现精细的流量控制测量。	低。不需要额外的资源投入。	高。客户端需要支持比较复杂的策略，且涉及升级的问题。	总体流量规模较大；应用场景对流量控制要求低；无法使用负载均衡器的场景。

负载均衡器

- 负载均衡的趋势
  - 硬件 => 软件
  - 四层和七层负载均衡器分离
- 四层负载均衡
  - LVS，DPVS，…
- 七层负载均衡
  - HAProxy，Nginx，Envoy，Traefik，BFE，…

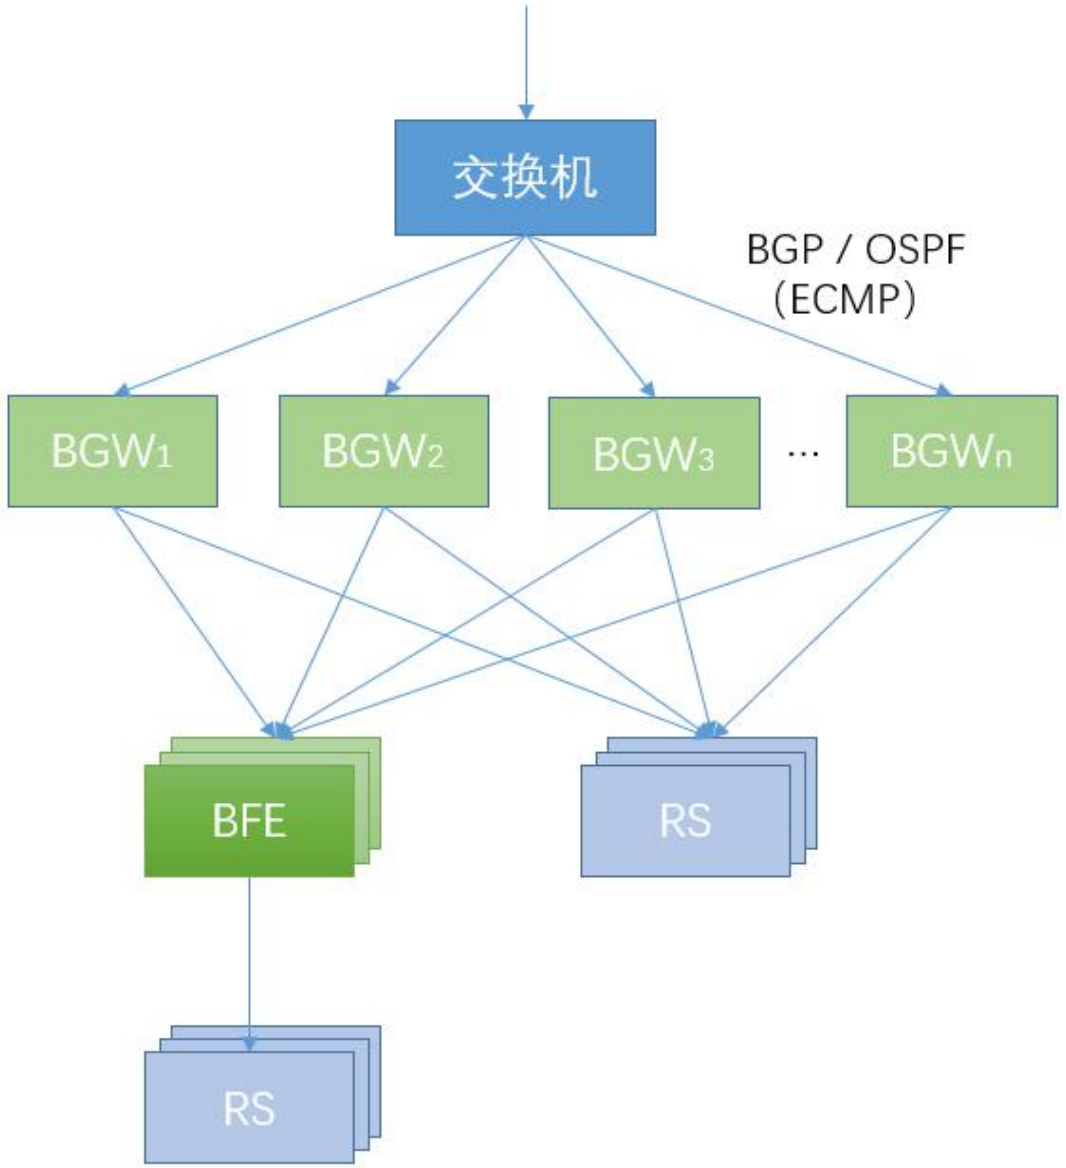

BFE为什么基于Go语言

- 研发效率
  - 远高于C语言
- 稳定性
  - 内存方面错误降低
  - 可以捕捉异常
- 安全性
  - 缓存区溢出风险降低
- 代码可维护性
  - 可读性好
  - 易于编写高并发逻辑
- 网络协议栈支持

BFE的短板

- 没有在内存拷贝上做极致优化
  - 使用Go系统协议栈
- 无法利用CPU亲和性（CPU Affinity）
  - 无法控制底层线程

七层负载均衡的生态选择

Nginx / OpenResty 生态	Envoy 生态	Go 生态
• 利用Nginx积累的大量功能 • 利用Lua的快速开发能力 • 代表：Nginx，APISIX	• 最早用于Service Mesh • 也可用于网关 • 代表：Envoy	• 基于Go语言的生态积累 • 更好的稳定性和安全性 • 易于开发扩展功能 • 代表：BFE，Traefik

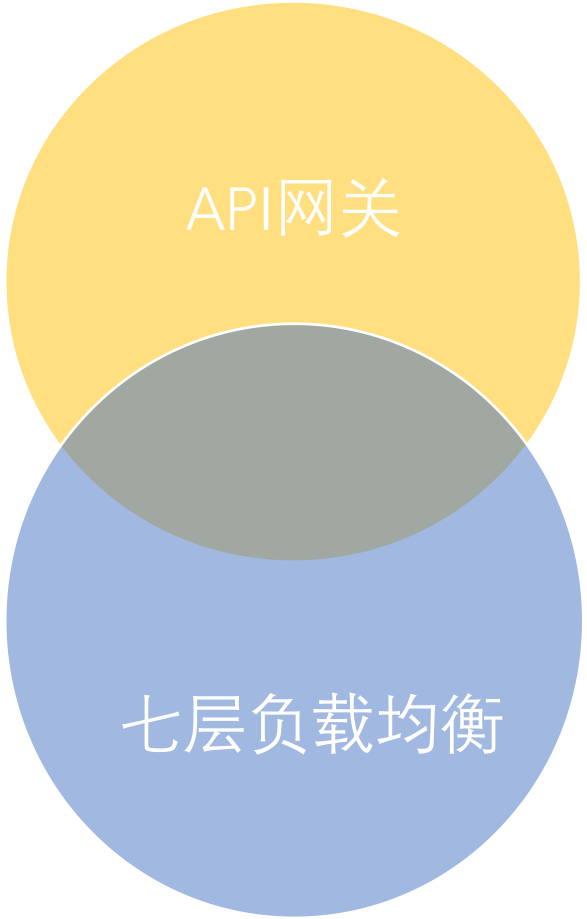

BFE主要设计思想

- 转发模型优化
  - 支持多租户
  - 引入条件表达式，减少正则表达式使用
- 降低动态配置加载的难度
  - 区分“常规配置”和“动态配置”
- 增强服务状态监控能力
  - 向外展现大量内部的执行状态
- 将大存储功能转移到外部
  - 加快启动速度

正则表达式 方案的问题

- **配置难以维护**：正则表达式存在严重的可读性问题
- **性能存在隐患**：有可能因编写不当引起严重的性能退化

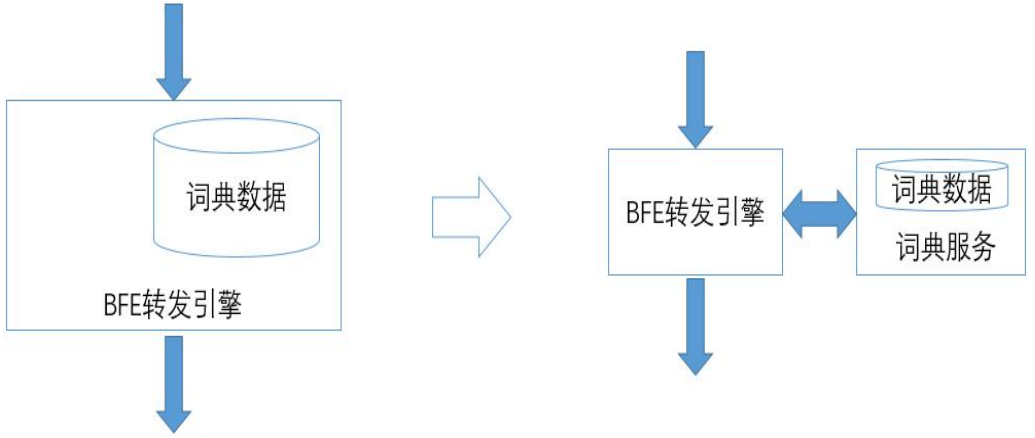

BFE转发的主要概念

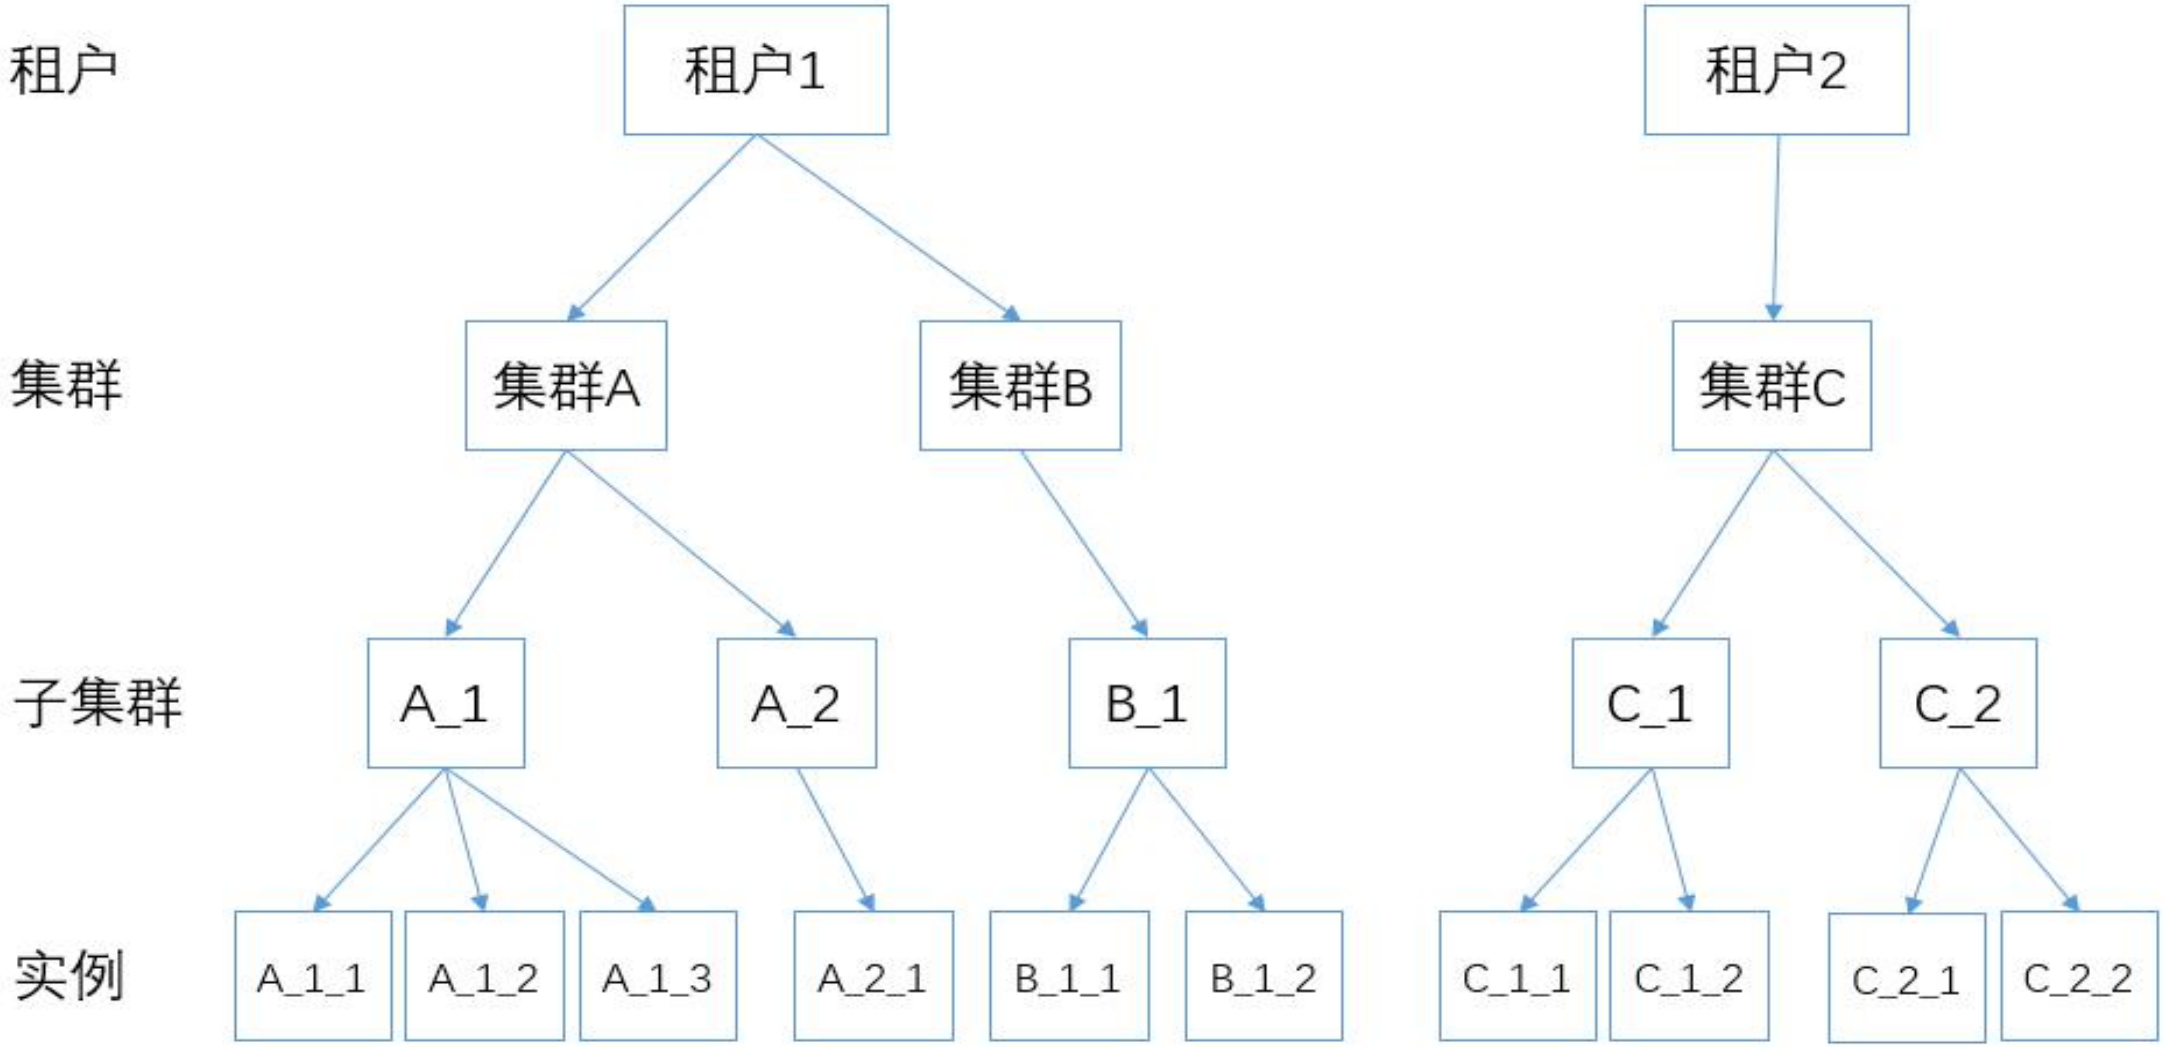
租户
集群
子集群
实例
租户1
租户2
集群A
集群B
集群C
A_1
A_2
B_1
C_1
C_2
A_1_1
A_1_2
A_1_3
A_2_1
B_1_1
B_1_2
C_1_1
C_1_2
C_2_1
C_2_2

BFE的转发过程

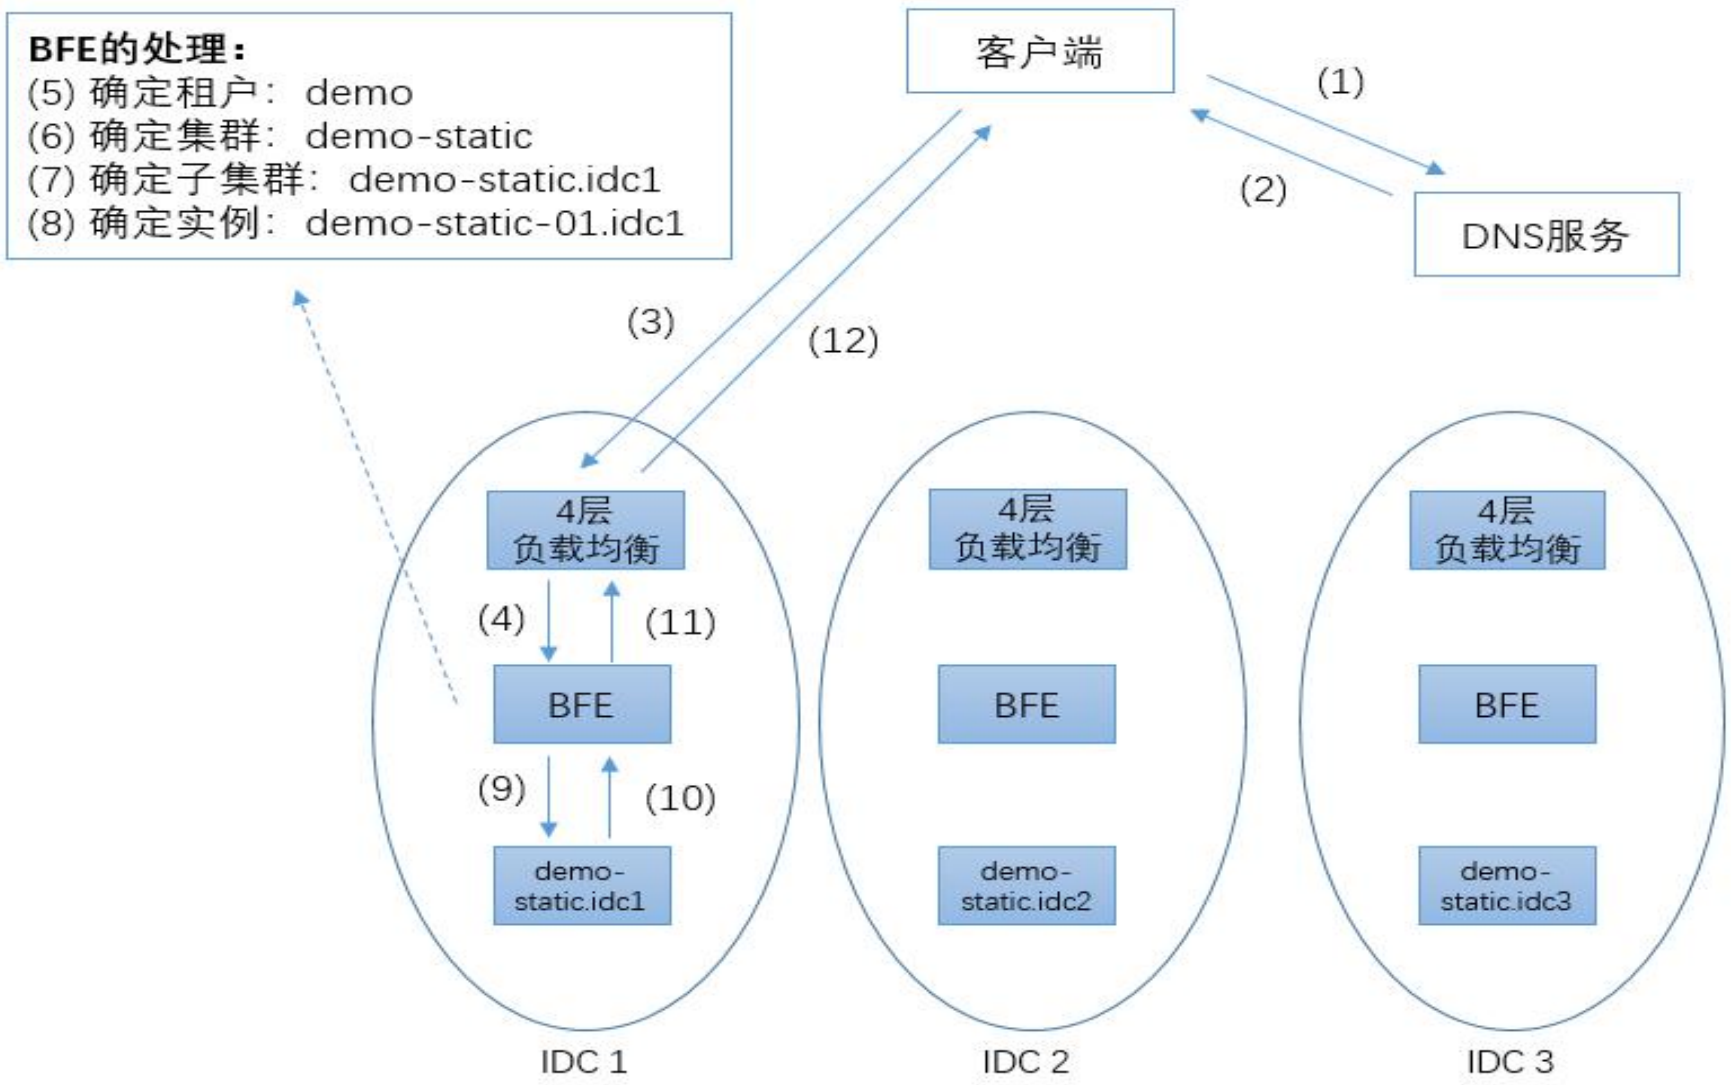
BFE的处理：
(5) 确定租户：demo
(6) 确定集群：demo-static
(7) 确定子集群：demo-static.idc1
(8) 确定实例：demo-static-01.idc1
客户端
(1)
(2)
DNS服务
(3)
(12)
4层
负载均衡
(4)
(11)
BFE
(9)
(10)
demo-
static.idc1
4层
负载均衡
BFE
demo-
static.idc2
4层
负载均衡
BFE
demo-
static.idc3
IDC 1
IDC 2
IDC 3

BFE的路由转发

基础转发表

匹配条件	目标集群
www.a.com/a/*	Demo-A
www.a.com/a/b	Demo-B
*.a.com/	Demo-C
www.c.com	ADVANCED_MODE

高级转发表

匹配条件	目标集群
req_host_in("www.c.com") && req_cookie_value_prefix_in("deviceid", "x", false)	Demo-D1
req_host_in("www.c.com")	Demo-D

默认集群 Demo-E

内网流量调度

- 使用场景
  - 多数据中心 ／　多容器云集群
  - 内部服务故障
  - 内部服务压力不均

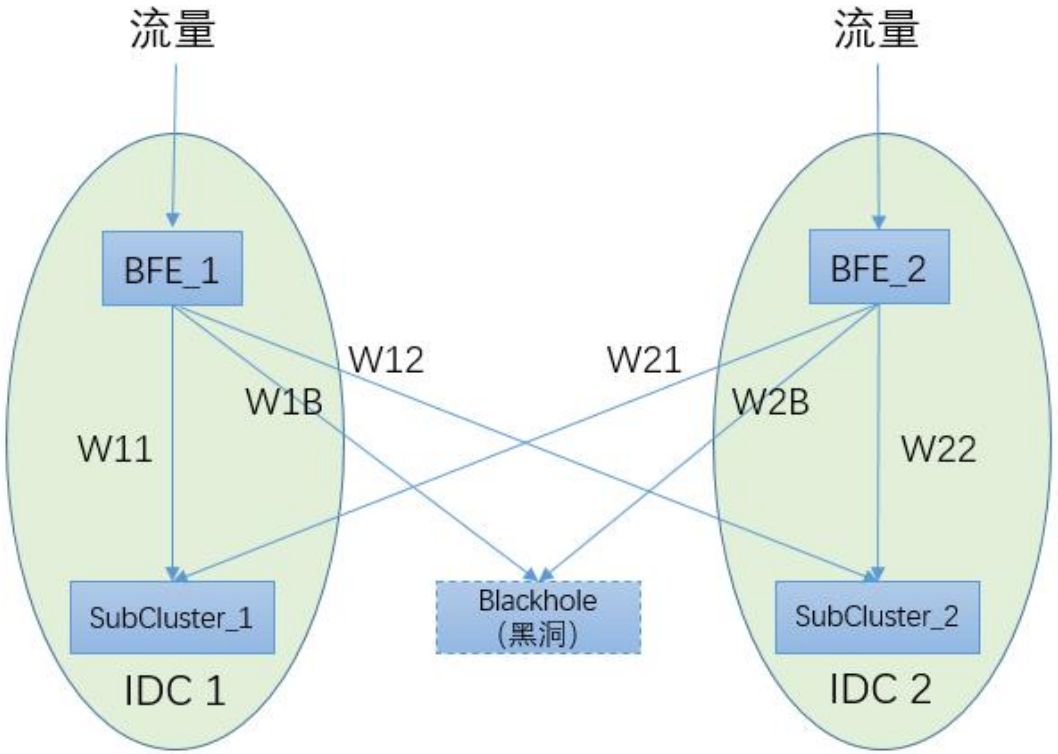

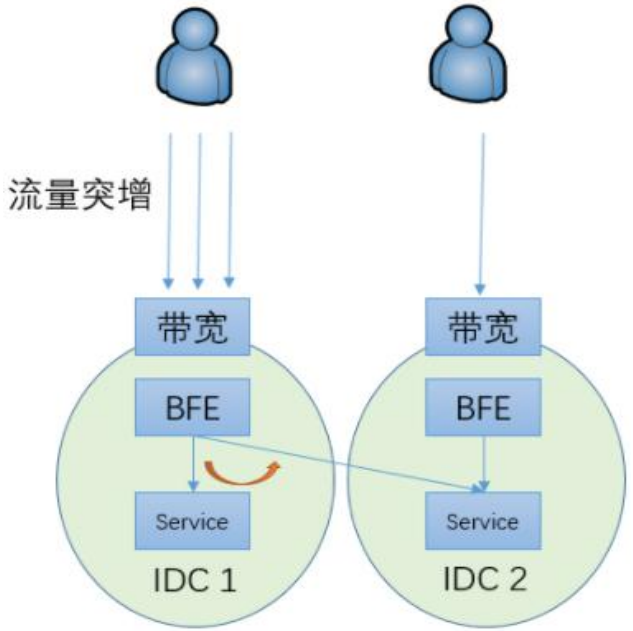

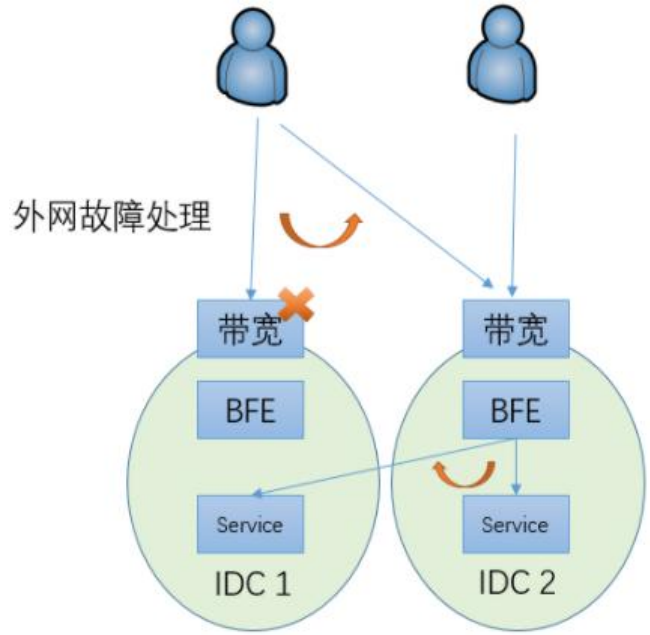

健康检查

- 主动健康检查
  - 负载均衡系统**持续**向RS发送探测请求
  - 问题：在响应速度和发送压力间存在权衡
  - 在分布式场景下问题更加明显
- 被动健康检查
  - 利用正常业务请求来发现失败
  - 失败后启动主动健康检查
  - 问题：业务请求频度低时无法及时发现失败
- 主动和被动的结合
  - 汇总两种检查的结果
  - 可降低主动检查的频度(如30—60s)

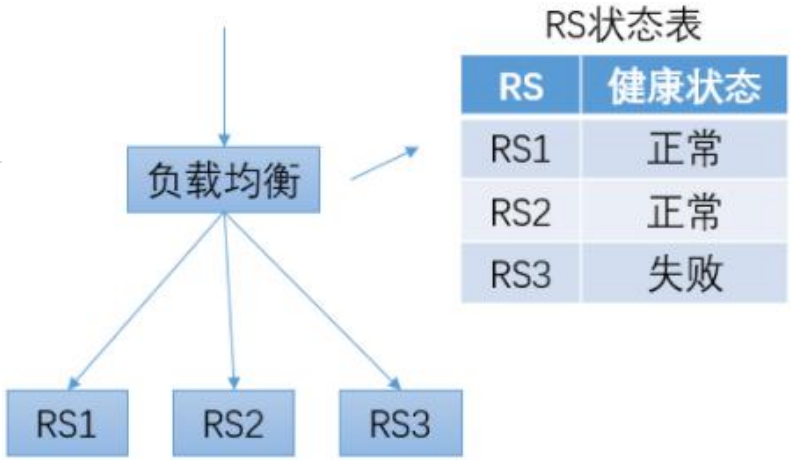

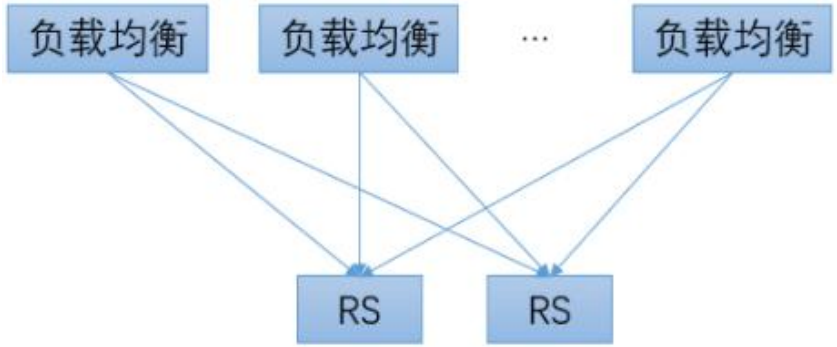

RS	被动检查	主动检查	汇总结果
RS1	正常	失败	失败
RS2	正常	正常	正常
RS3	失败	正常	失败

信息透传

- 客户端IP地址透传
  - X-Forwarded-For：容易被伪造
- mod_header
  - 默认增加：X-Real-Ip，X-Real-Port
  - 可以[illegible]多的信息

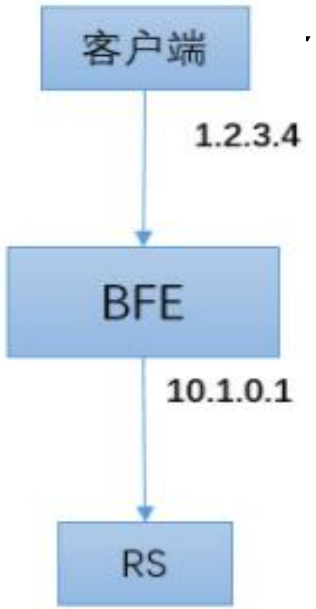


```
{
    "Version": "20190101000000",
    "Config": {
        "example_product": [
            {
                "cond": "req_path_prefix_in(\"/header\",
false)",
                "actions": [
                    {
                        "cmd": "REQ_HEADER_SET",
                        "params": [
                            "X-Bfe-Log-Id",
                            "%bfe_log_id"
                        ]
                    },
                    {
                        "cmd": "RSP_HEADER_SET",
                        "params": [
                            "X-Proxied-By",
                            "bfe"
                        ]
                    }
                ],
                "last": true
            }
        ]
    }
}
```

限流机制

- 问题：
  - 分布式场景下是否可以均分阈值？
- 要精确限流，需使用集中计数

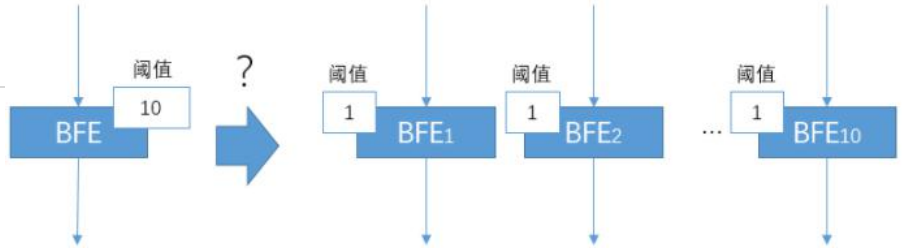

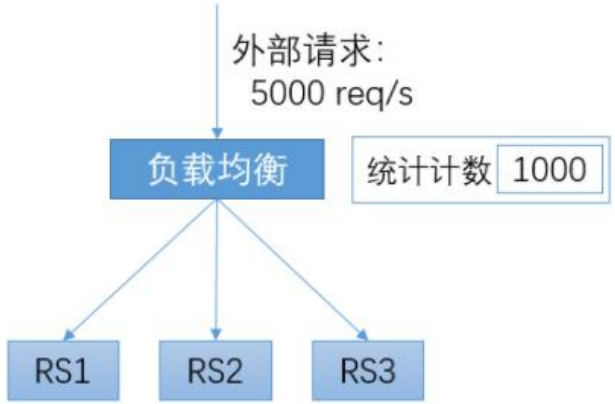

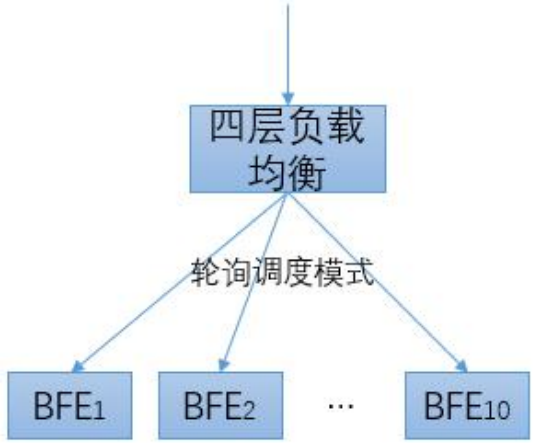

统计特征	统计周期	阈值	动作
www.demo.com	1秒	1200	关闭连接
api.baidu.com/api	1秒	200	返回静态结果

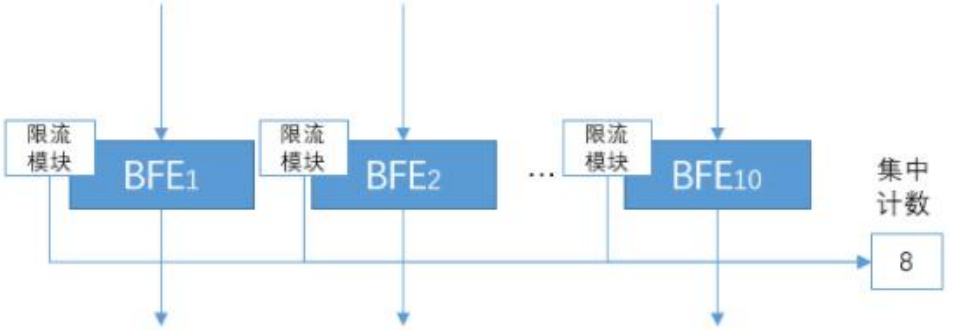

监控机制

- 基于日志监控的问题
  - 被监控系统的资源消耗较高
  - 监控系统的资源消耗较高
  - 很多状态信息并不适合打印输出
- BFE的内部状态输出
  - 通过内嵌web server向外暴露
  - 状态信息的汇聚和读取成本低
- 可以将状态和日志配合使用
- Web Monitor框架
  - https://github.com/baidu/go-lib
  - 支持状态、差值、延迟统计等

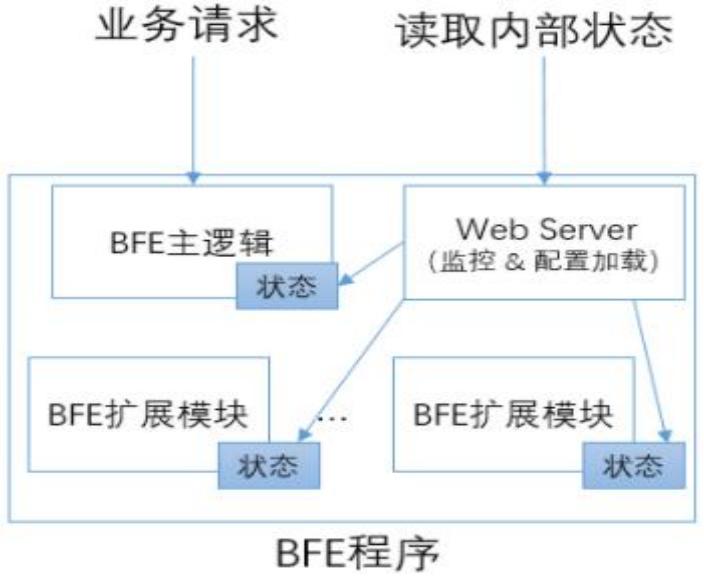

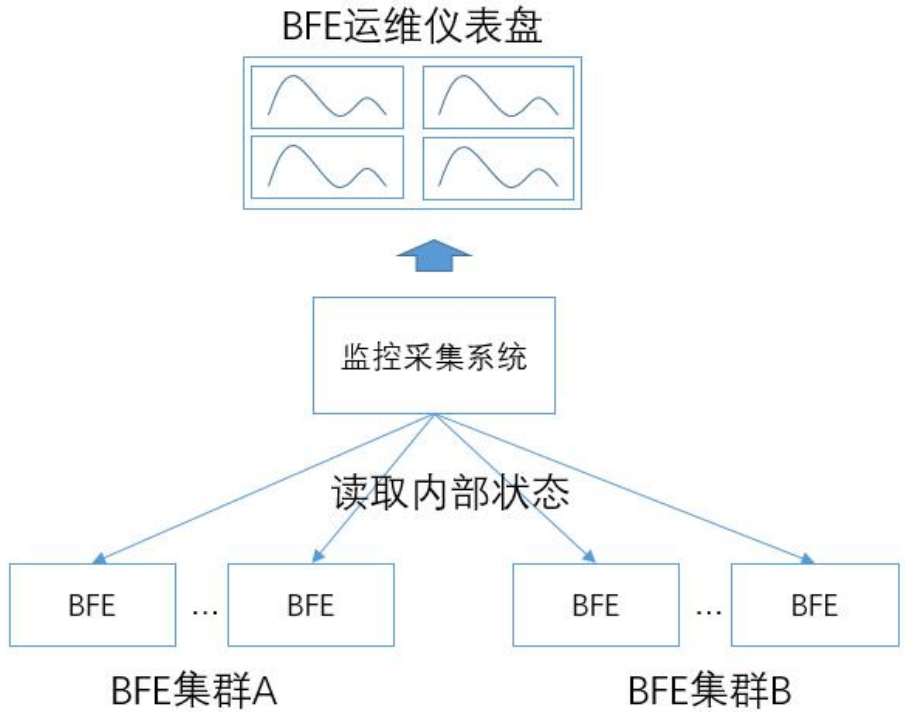

配置管理

- BFE配置的分类
  - 常规配置： .conf
  - 动态配置： .data
- 配置动态加载
  - 外部触发，细粒度加载

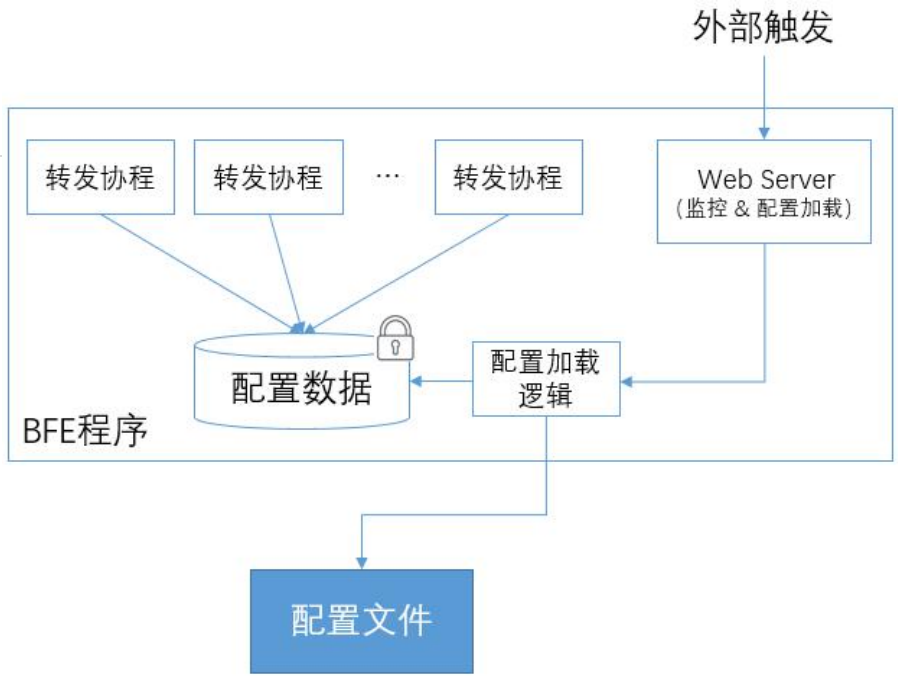

写配置

```
func (t *ProductRuleTable) Update(conf
productRuleConf) {
        t.lock.Lock()
        t.version = conf.Version
        t.productRules = conf.Config
        t.lock.Unlock()
}
```

读配置

```
func (t *ProductRuleTable) Search(product string)
(*blockRuleList, bool) {
        t.lock.RLock()
        productRules := t.productRules
        t.lock.RUnlock()

        rules, ok := productRules[product]
        return rules, ok
}
```

BFE的代码组织

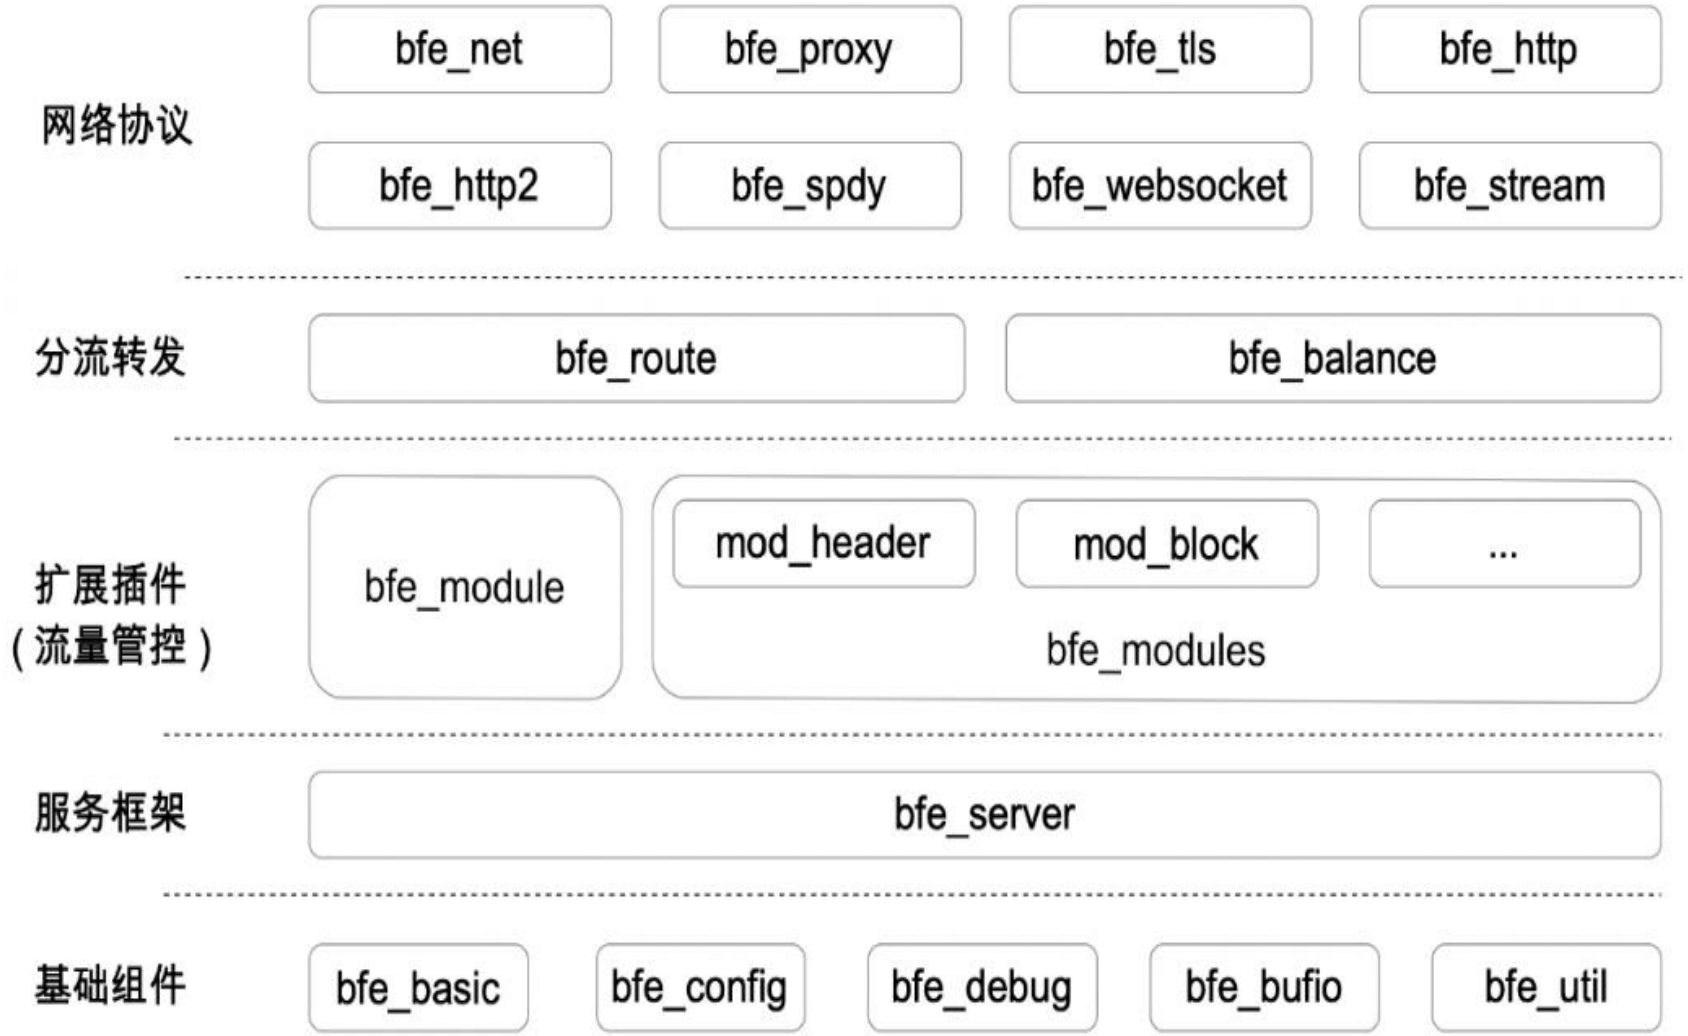
网络协议
bfe_net
bfe_proxy
bfe_tls
bfe_http
bfe_http2
bfe_spdy
bfe_websocket
bfe_stream
分流转发
bfe_route
bfe_balance
扩展插件
（流量管控）
bfe_module
mod_header
mod_block
...
bfe_modules
服务框架
bfe_server
基础组件
bfe_basic
bfe_config
bfe_debug
bfe_bufio
bfe_util

BFE的协程使用

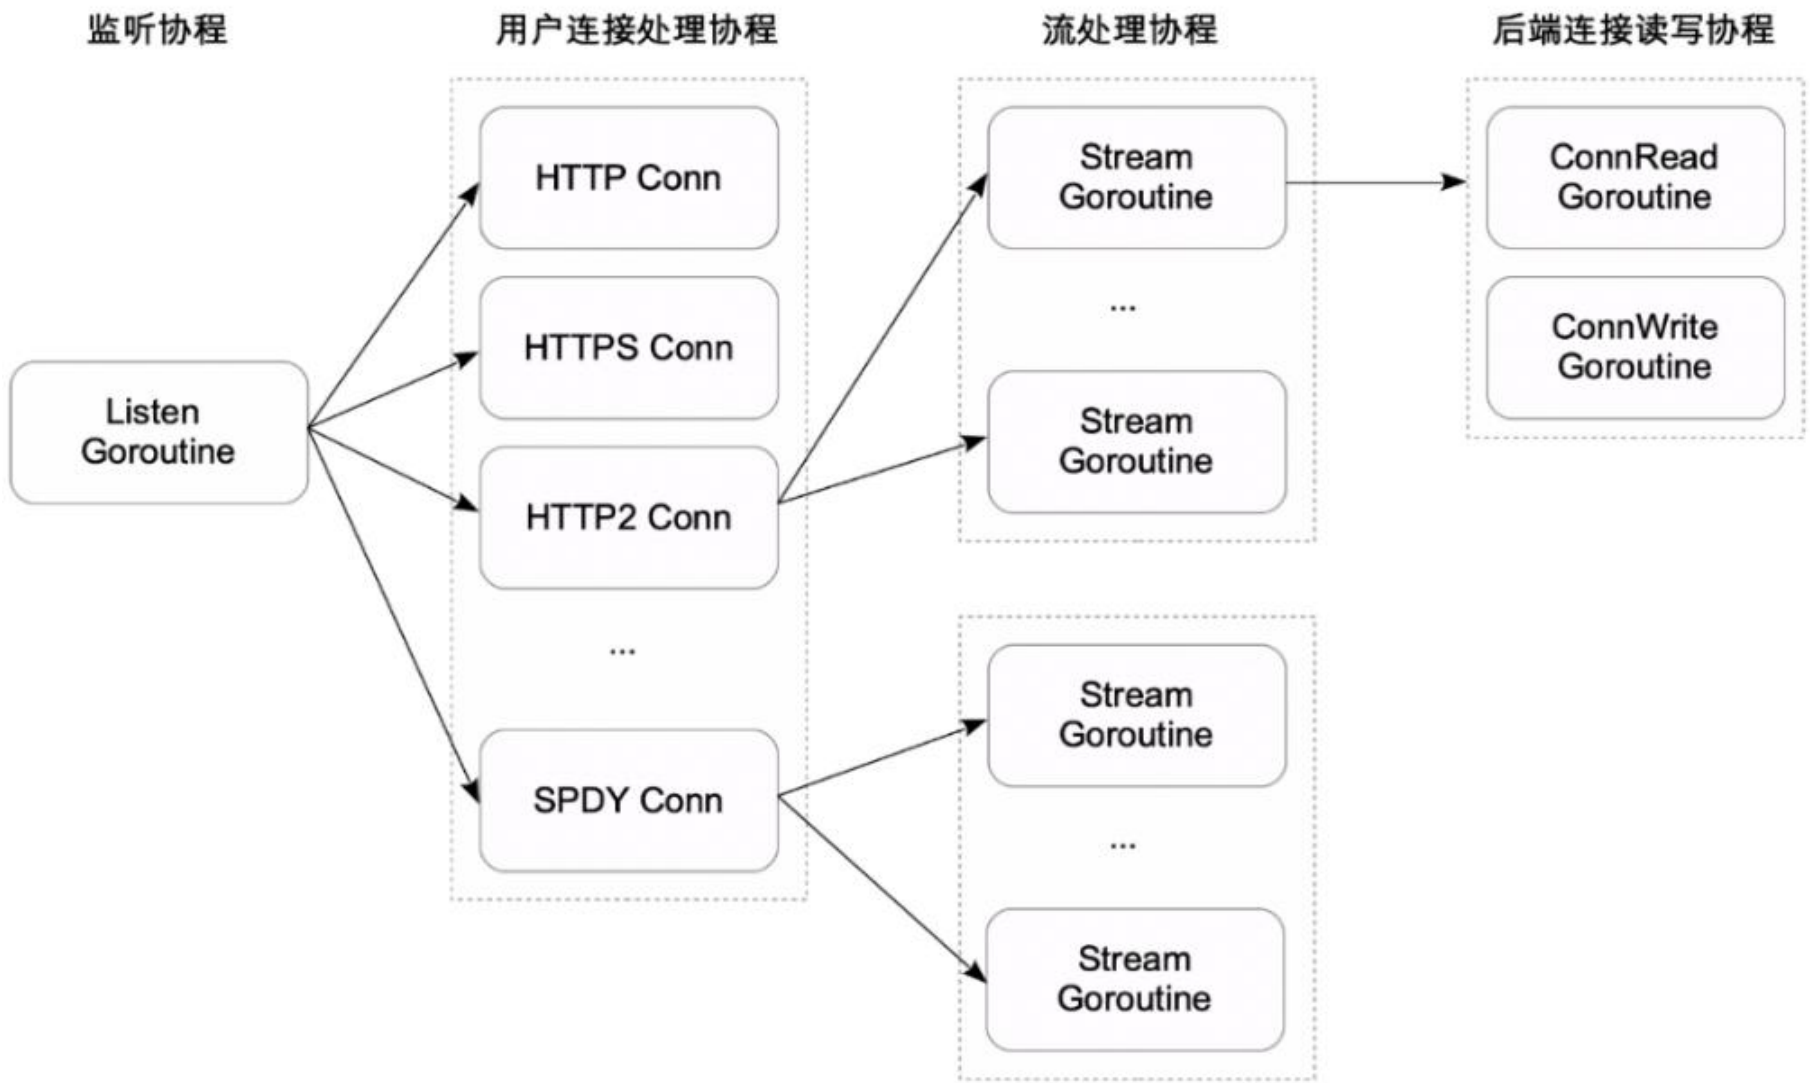
监听协程
用户连接处理协程
流处理协程
后端连接读写协程
Listen Goroutine
HTTP Conn
HTTPS Conn
HTTP2 Conn
...
SPDY Conn
Stream Goroutine
...
Stream Goroutine
Stream Goroutine
...
Stream Goroutine
ConnRead Goroutine
ConnWrite Goroutine

BFE的回调点设置

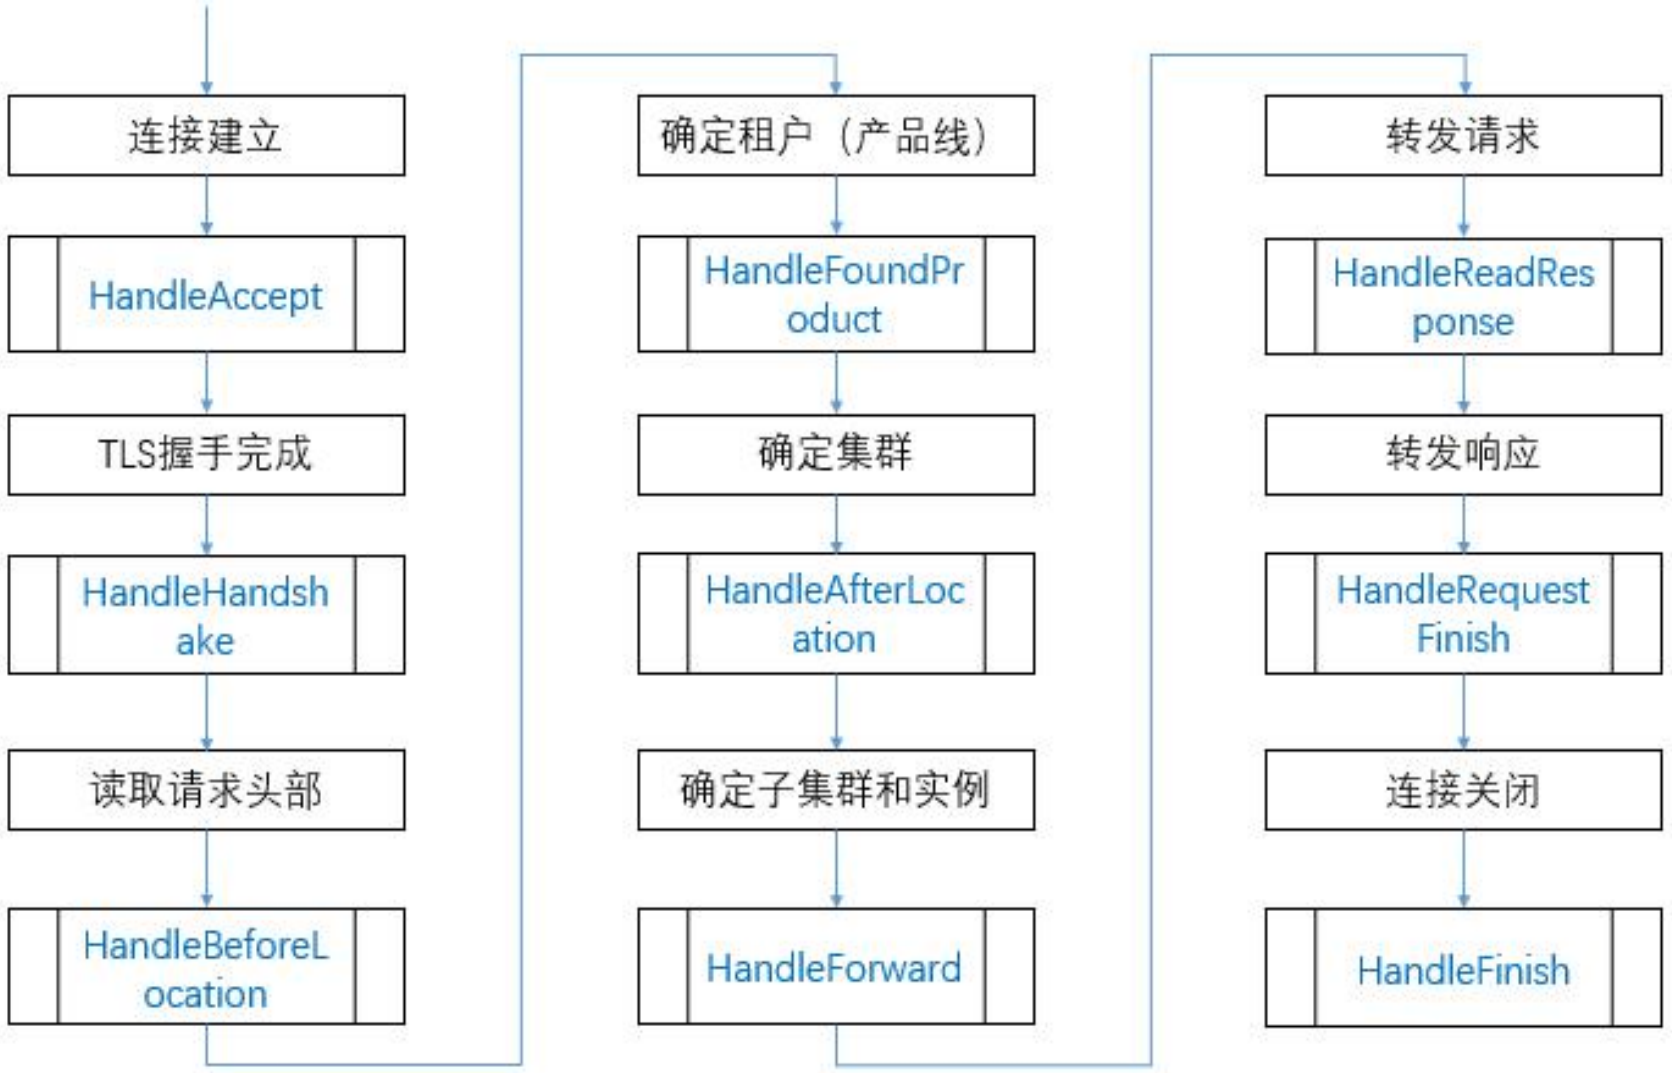
连接建立
HandleAccept
TLS握手完成
HandleHandshake
读取请求头部
HandleBeforeLocation
确定租户（产品线）
HandleFoundProduct
确定集群
HandleAfterLocation
确定子集群和实例
HandleForward
转发请求
HandleReadResponse
转发响应
HandleRequestFinish
连接关闭
HandleFinish

BFE扩展模块的编写

- 配置加载
  - 静态：mod_block.conf
  - 动态：block_rules.data，
    ip_blocklist.data
- 回调函数编写和注册
- 定义状态变量

```
type ModuleBlock struct {
    ...
    state    ModuleBlockState // module state
    metrics metrics.Metrics
}

func NewModuleBlock() *ModuleBlock {
    m := new(ModuleBlock)
    m.metrics.Init(&m.state, ModBlock, 0)
    ...
}
```

```
// register web handler for reload
err = whs.RegisterHandler(web_monitor.WebHandleReload,
m.name, m.loadConfData)
if err != nil {
...
}
```

```
func (m *ModuleBlock) productBlockHandler(request
*bfe_basic.Request) (int, *bfe_http.Response) {
    ...
}

func (m *ModuleBlock) Init(cbs *bfe_module.BfeCallbacks, whs
*web_monitor.WebHandlers, cr string) error {
    // register handler
    err = cbs.AddFilter(bfe_module.HandleFoundProduct,
m.productBlockHandler)
    ...
}
```

未来计划

- BFE管理控制台对外开源
- BFE ingress controller对外开源

欢迎广大Gopher使用或参与共建！

BFE开源项目公众号

谢谢