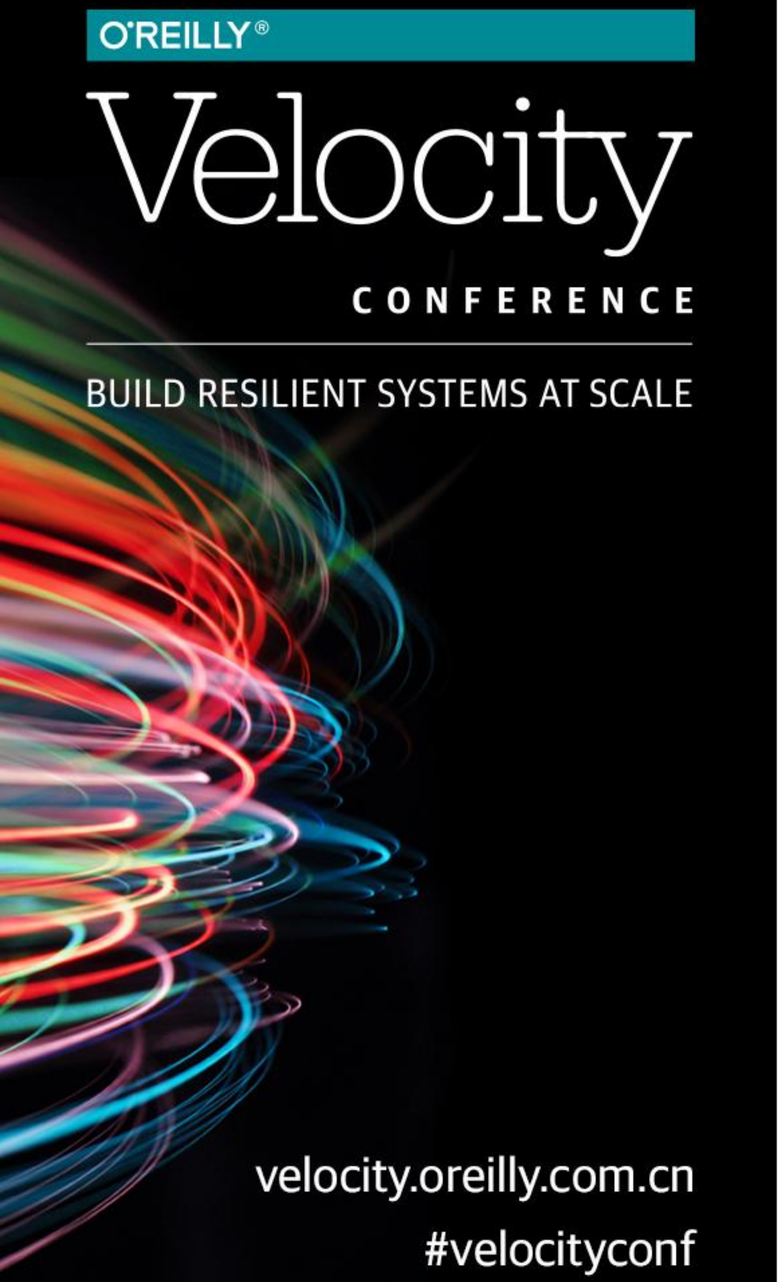

智能运维在监控中的探索

Baidu Intelligent Operation

曲显平
quxianping@baidu.com

Baidu 百度

背景：服务器爆发式增长


百度服务器数量变化趋势
5年增长约20倍！
2006
2007
2008
2009
2010
2011
2012
2013
2014

监控和问题诊断很复杂

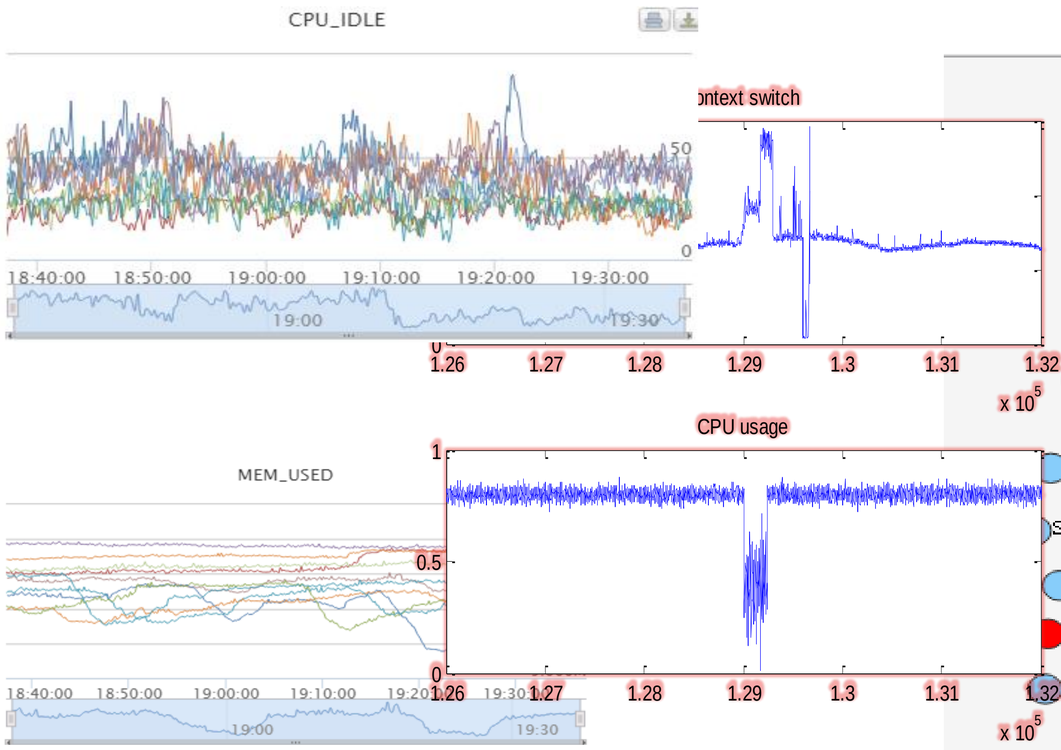


```
I0513 11:33:26.879593 12250 task_manager.cpp:504] insert task to be executed 5.nsps-imbs-999.IM.all
MBS_FLOW_cnt      60    600   10    5      3.5    DAY
I0513 11:33:27.678639 12234 detect_task.cpp:890] build threshold success 10.nsps-imbs-999.IM.all:IMBS_FL
W0513 11:33:27.690470 12234 task_manager.cpp:338] abnormal detected: [10.nsps-imbs-999.IM.all:IMBS_FLOW_
D, real_value:1.         expect/upper/lower/977.472/1466.21/293.242
I0513 11:33:27.709404 12234 task_manager.cpp:51] execute task success: 10.nsps-imbs-999.IM.all, IMBS_FLO
I0513 11:33:27.709450 12234 task_manager.cpp:298] create ClientPacket for 10.208.40.22:19050
I0513 11:33:27.709470 12234 task_manager.cpp:306] execute query[5.nsps-imbs-999.IM.all:IMBS_FLOW_cnt_avg
W0513 11:33:27.802666 12234 task_manager.cpp:338] abnormal detected: [5.nsps-imbs-999.IM.all:IMBS_FLOW_c
 real_value:1. expect/upper/lower/979.234/1468.85/293.77
I0513 11:33:27.802733 12234 task_manager.cpp:51] execute task success: 5.nsps-imbs-999.IM.all, IMBS_FLOW
I0513 11:33:28.900647 12250 task_manager.cpp:504] insert task to be executed 10.nsps-imbs-999.IM.all
MBS_FLOW_cnt      60    600   10    5      3.5    DAY
I0513 11:33:29.125764 12214 redis_manager.cpp:46] Redis pipeline thread exited
```

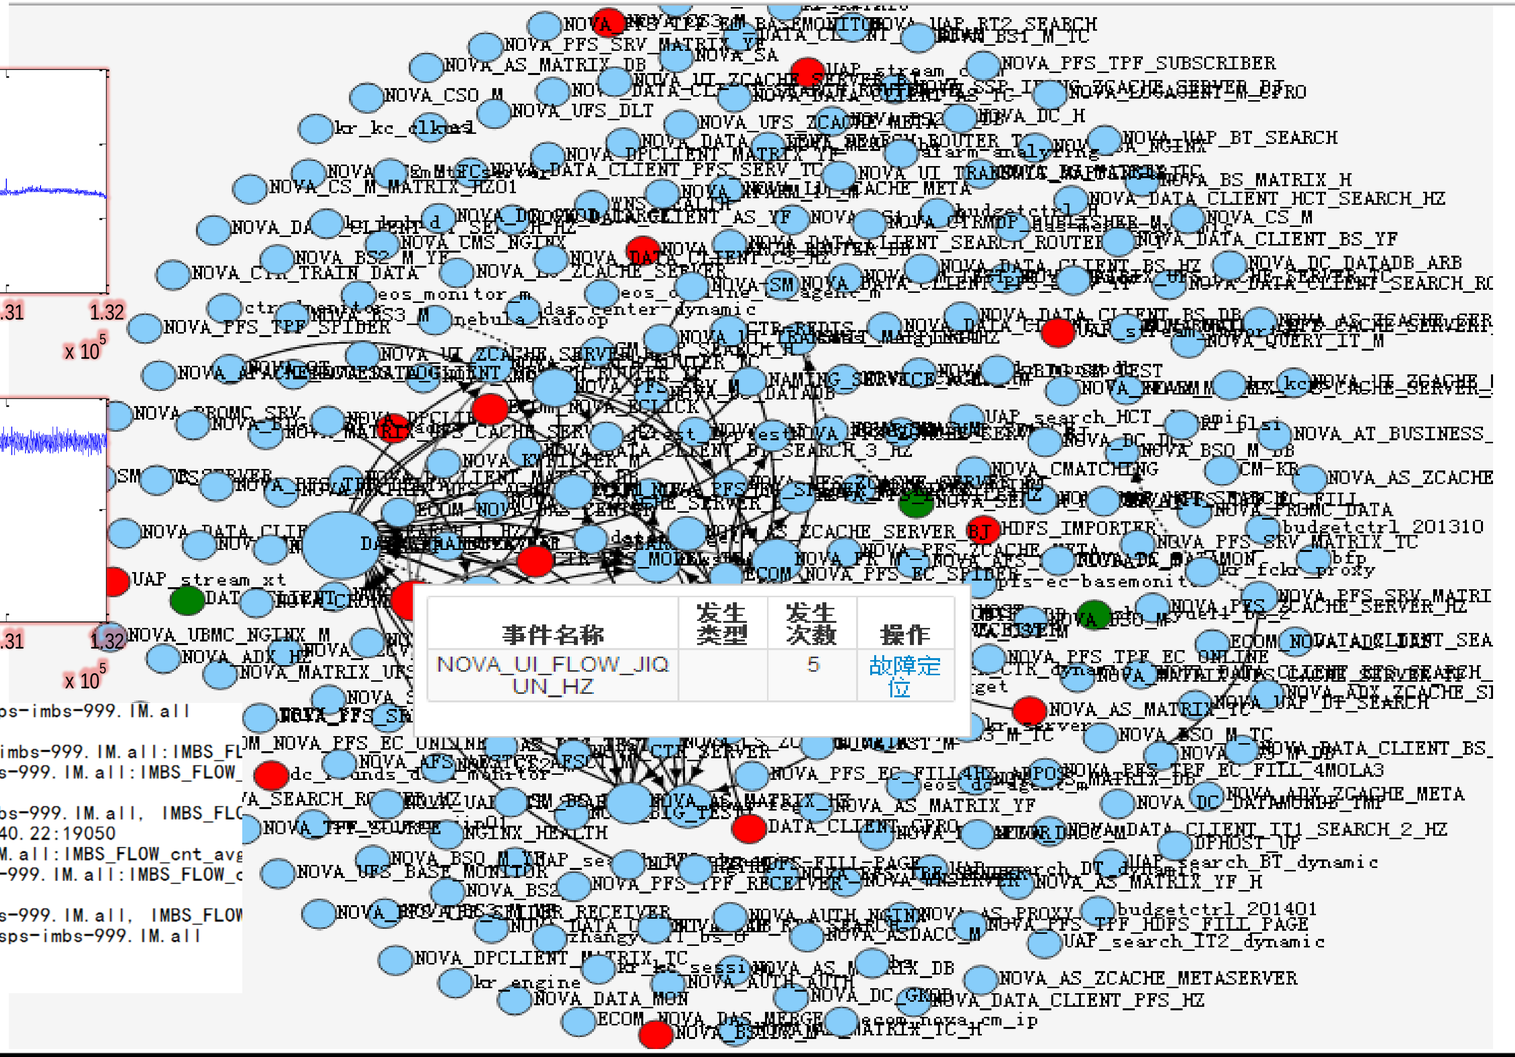

监控规模

- 监控数据
  - 这里只讲时序指标数据（不含日志）
  - 服务器指标数量：>1亿
  - 业务指标数量：>8千万
  - 数据增长速度：50TB/日

当前监控问题

问题发现 → 问题诊断 → 问题解决

- 指标繁多
  - 管理配置监控复杂
  - 误报、漏报严重
- 报警风暴
  - 太多噪音
  - Oncall人员应接不暇

- 故障定位
  - 没有服务拓扑
  - 指标与事件之间缺乏关联关系
  - 基本靠人的经验

- 止损
  - 不是服务自恢复
  - 基本靠人工操作

运维&监控的演变

- 运维人手不足，如何解决日益复杂化的运维问题？

发现问题篇：异常自动检测

如何合理设定阈值？

环比昨日的明显问题

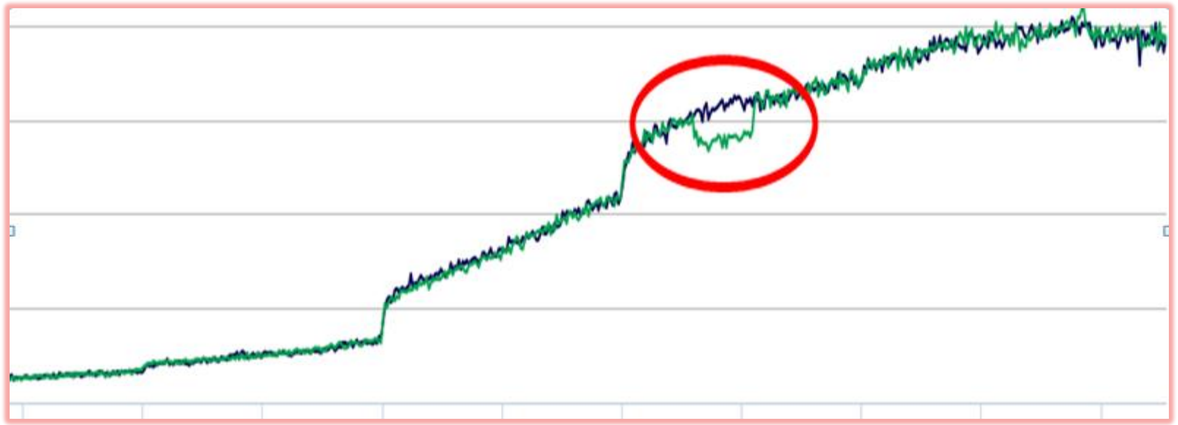

持续偏离的明显问题

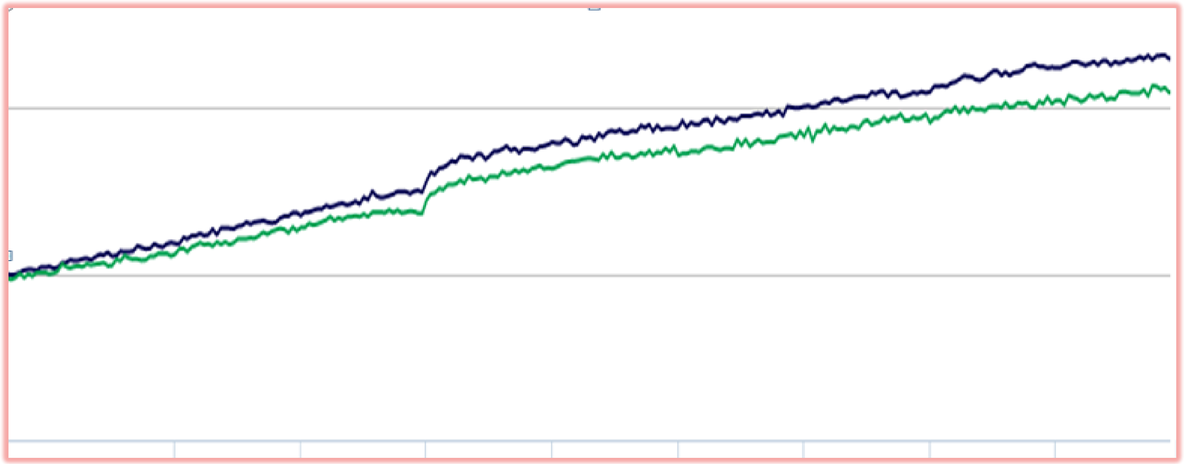

随时间周期漂移的指标数据

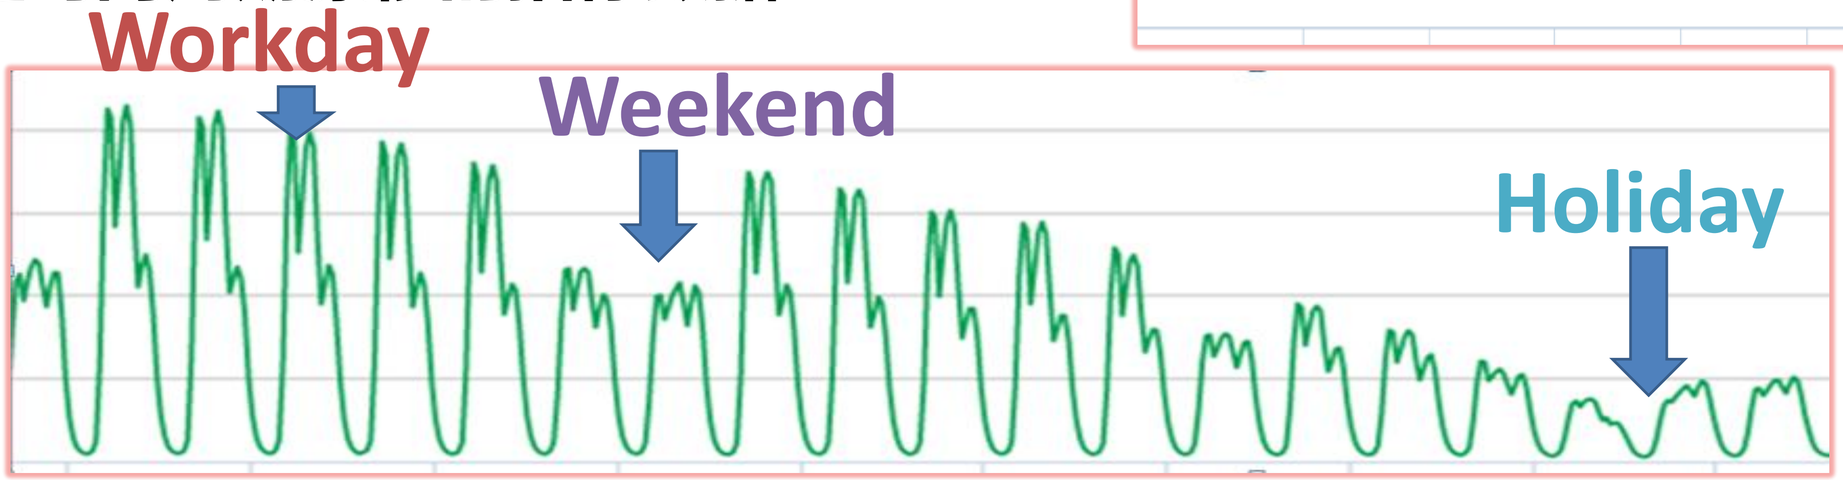

恒定阈值设定

- 简单恒定阈值的计算
  - 基于历史数据统计
  - 假设正态分布
  - 3-sigma $\bar{x} \pm 3\sigma$

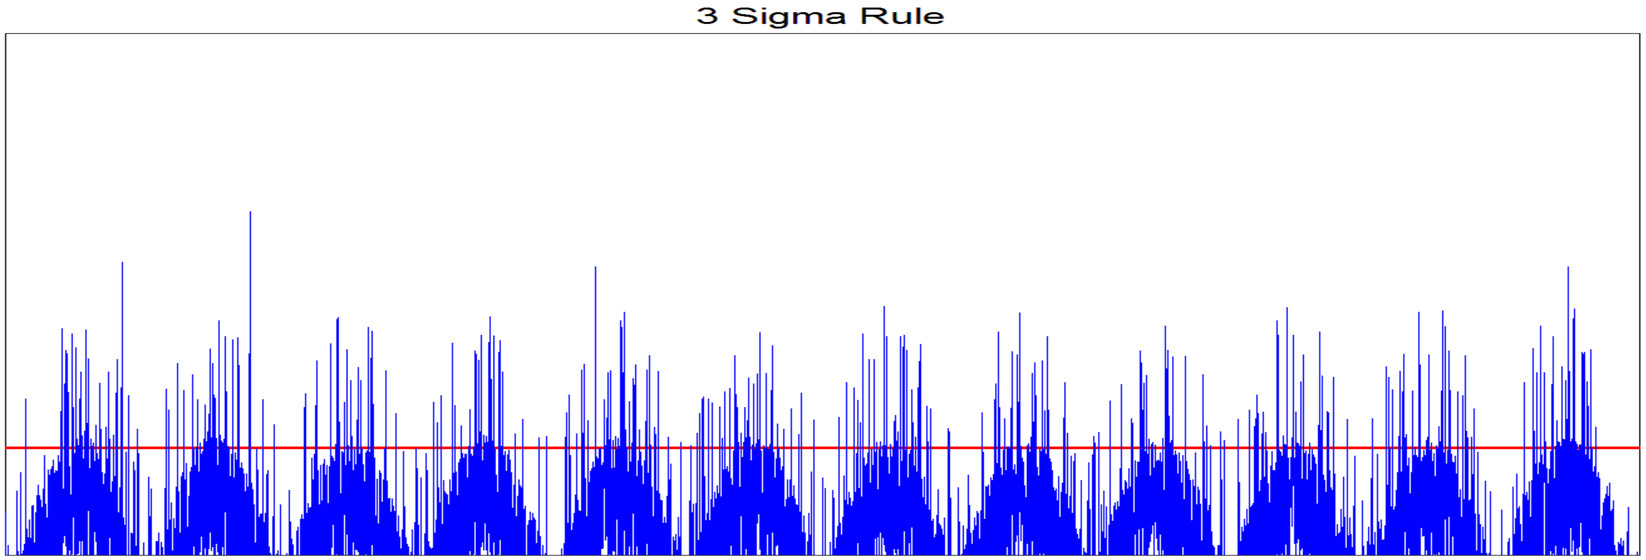

动态阈值的计算

- day vs night
- 多分布形式：将数据分段（e.g. window=15min）
- 按天同期计算统计阈值
- 分段3-sigma策略

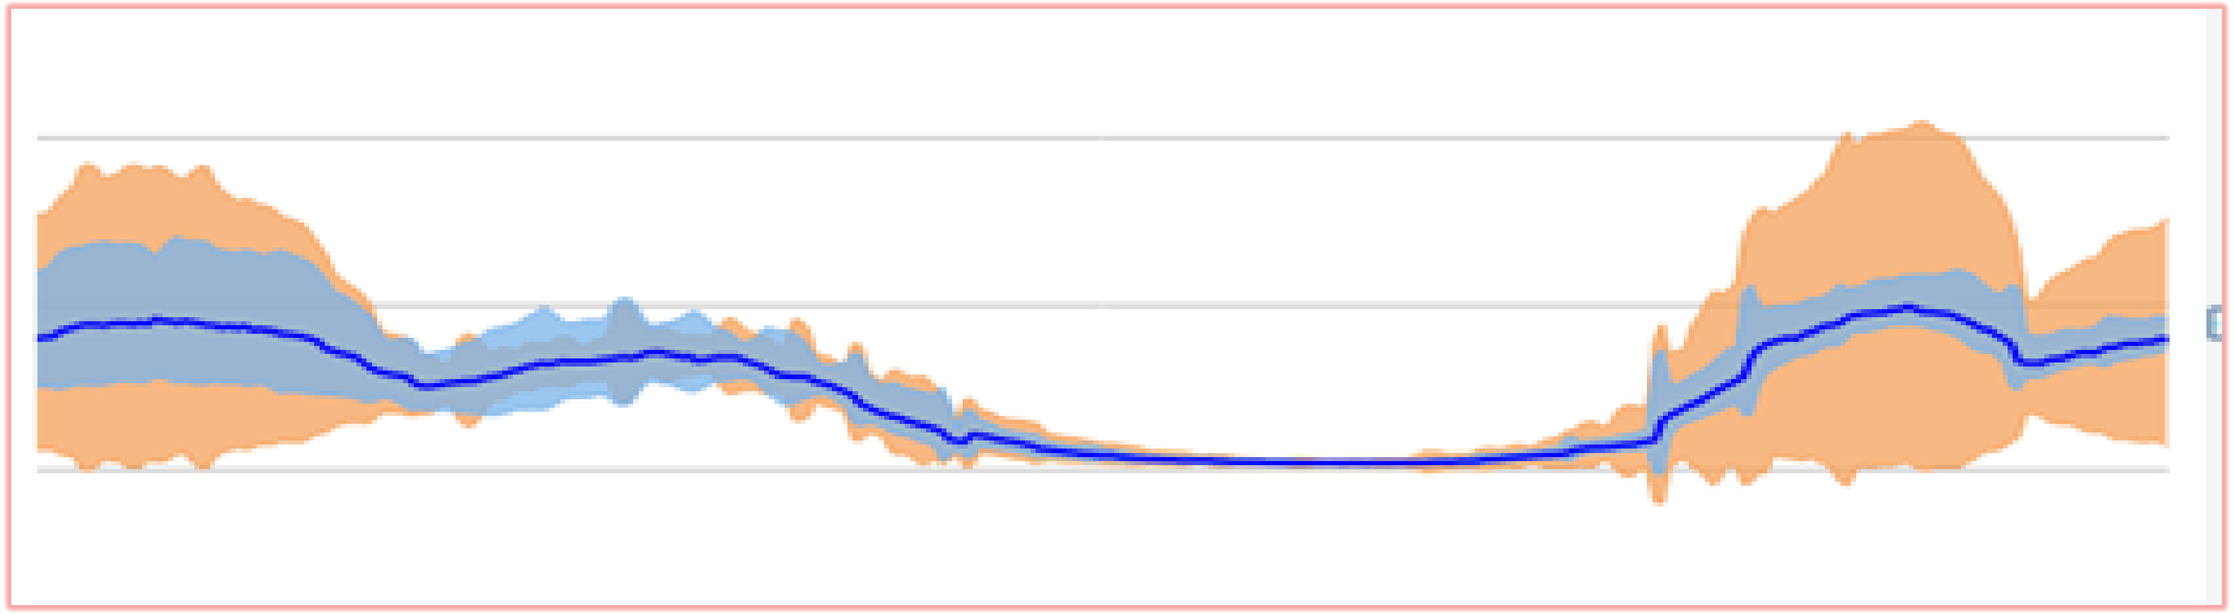

分类器

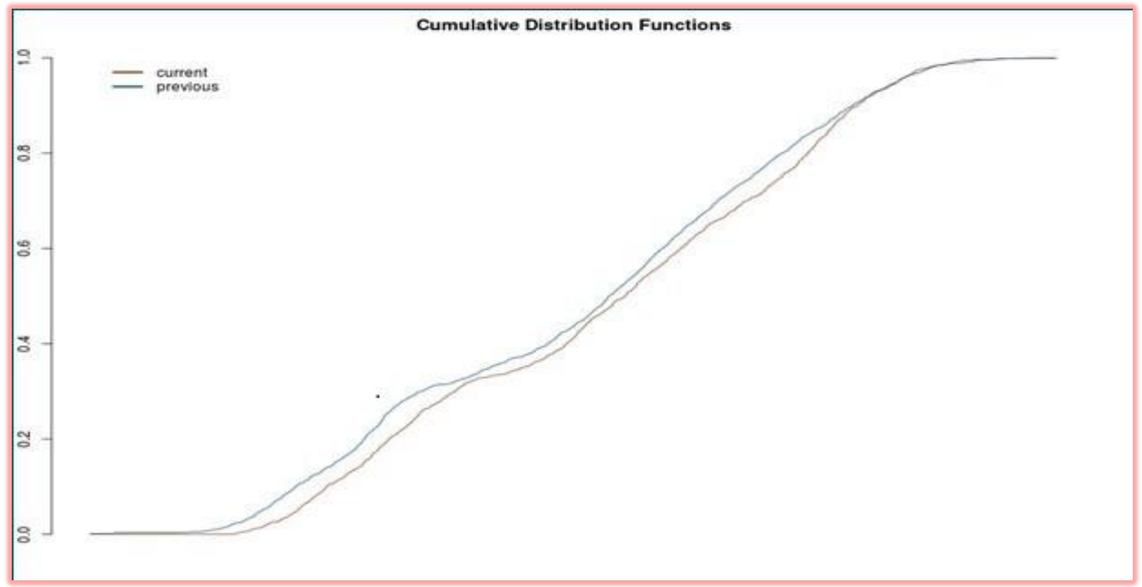

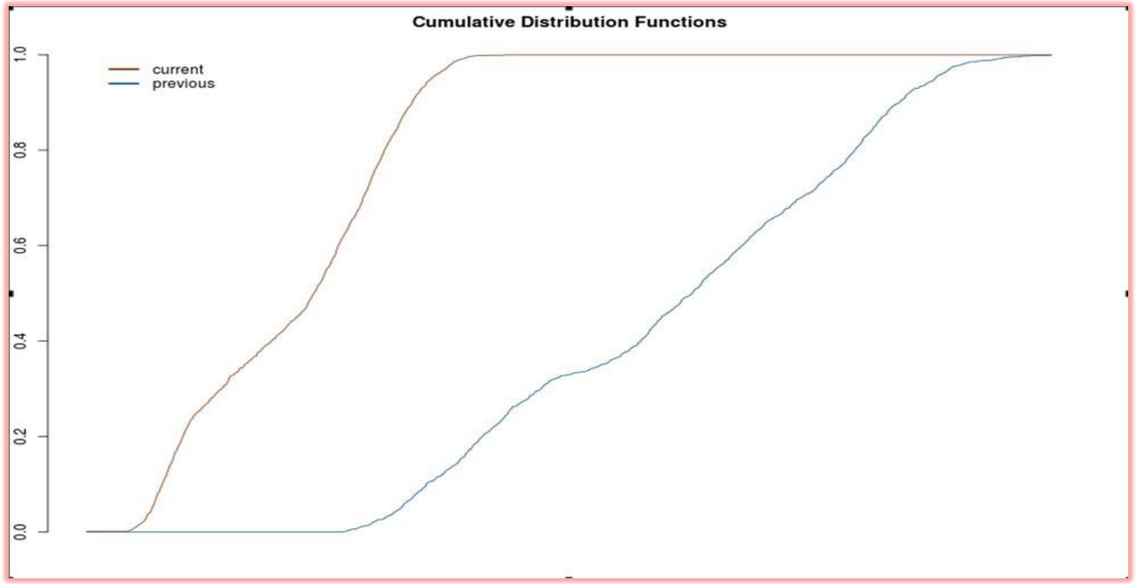

- 区分数据是否为多分布：
  - KS-test
  - 选择恒定阈值法或动态阈值法
  - 也可区分工作日/周末/长假

数据漂移

- 指标随时间周期性漂移
  - 工作日流量 vs. 周末流量 vs. 长假流量

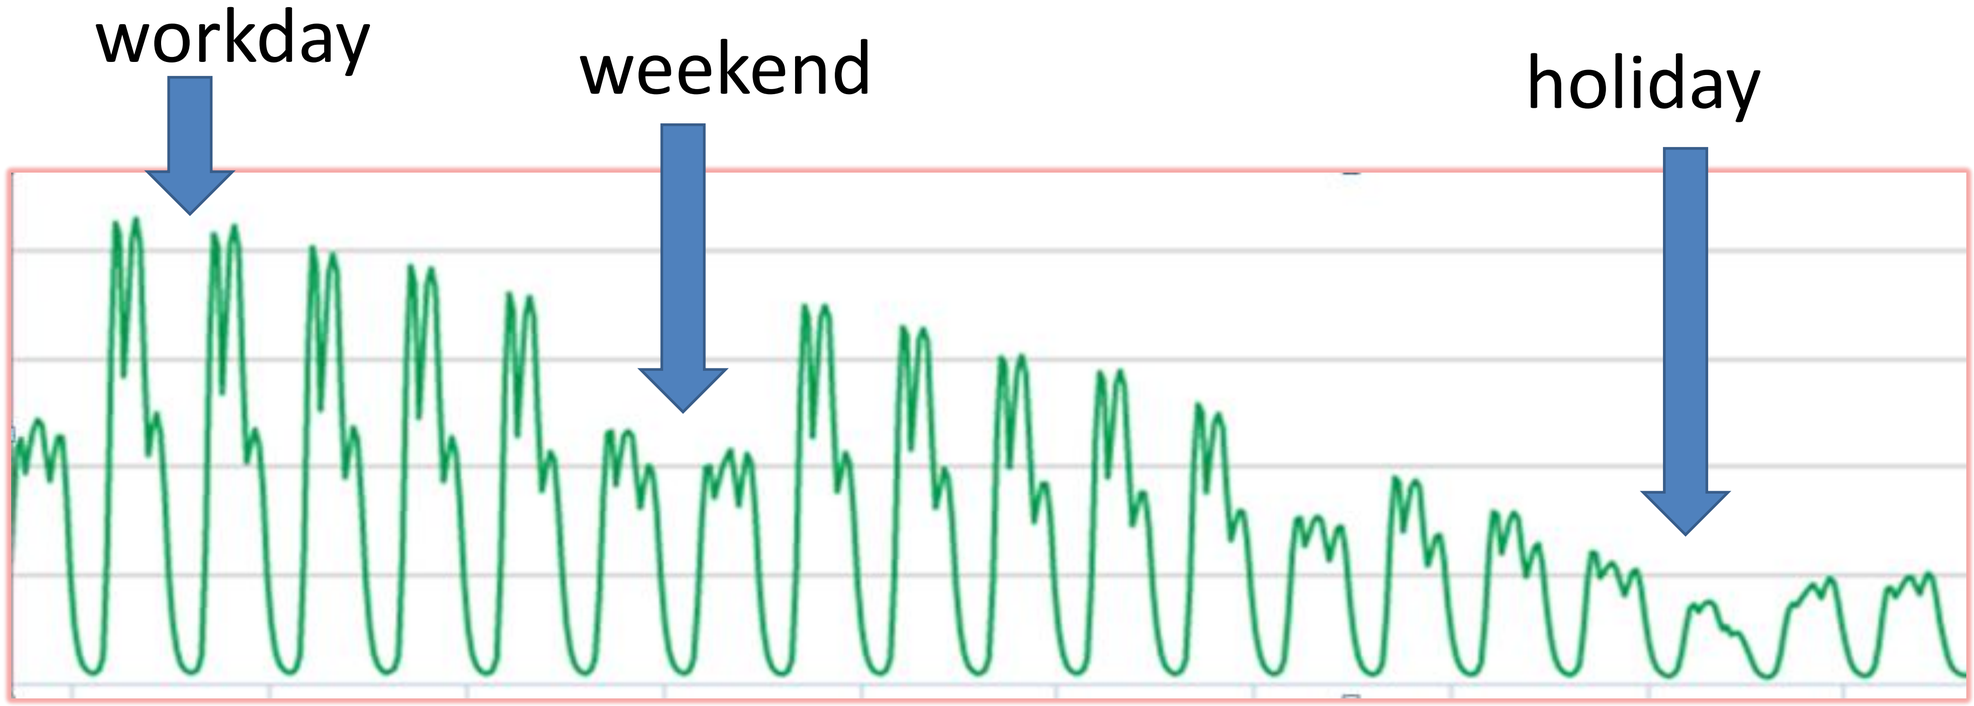

复杂动态阈值法

- Holt-winters & ARIMA
- 季节性和趋势性同时学习

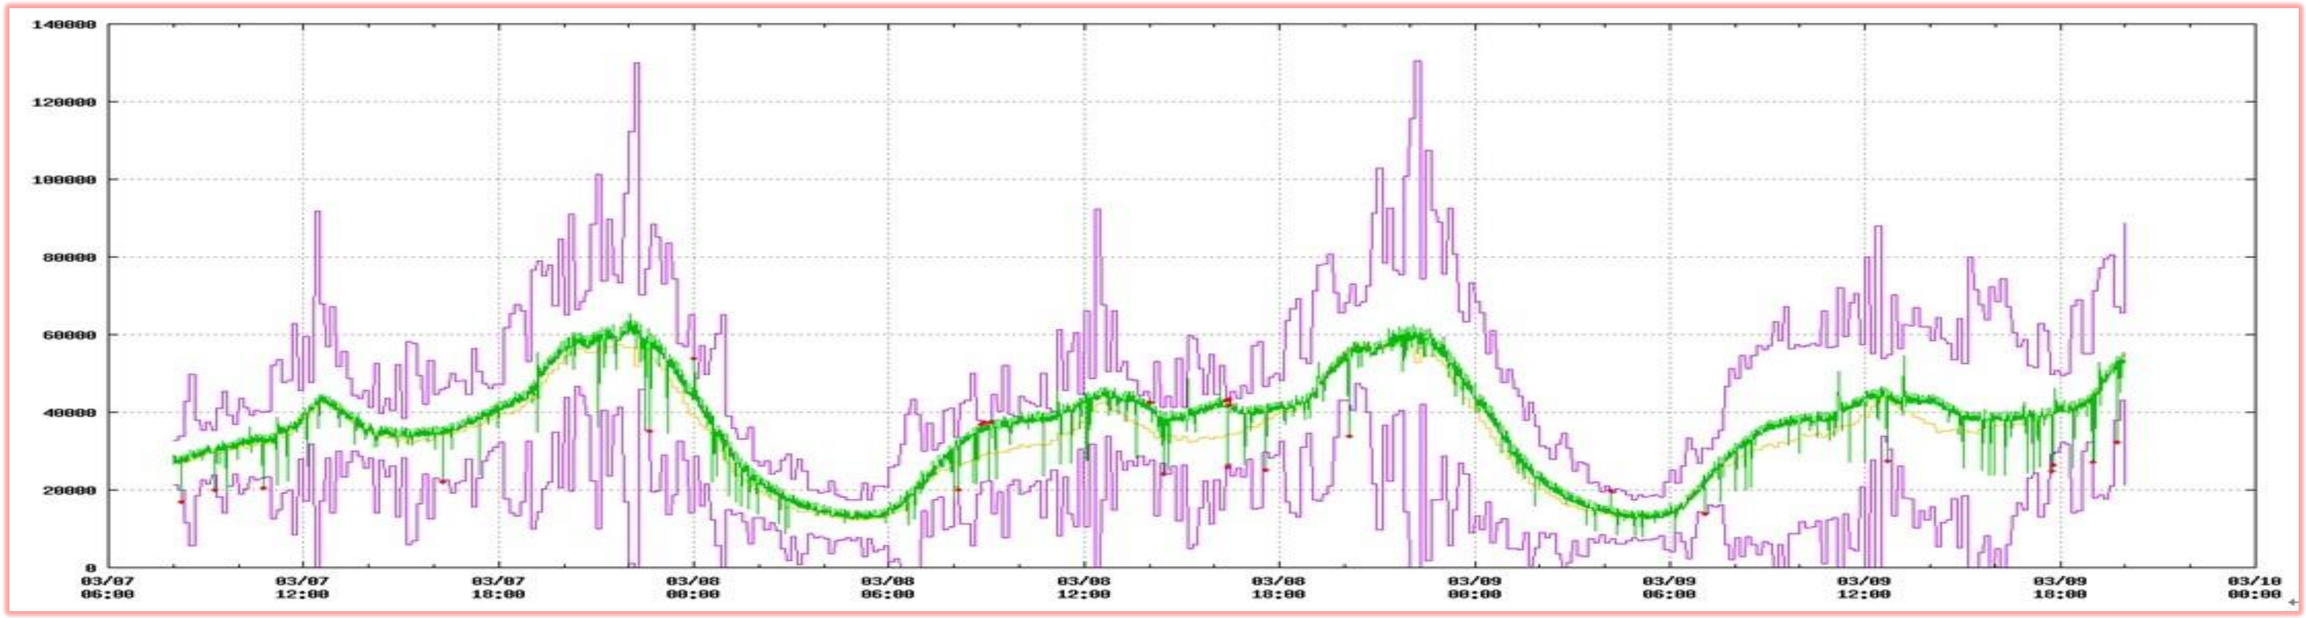

突增突降检测

- 局部平滑
  - 局部回归：LOESS
- 速度

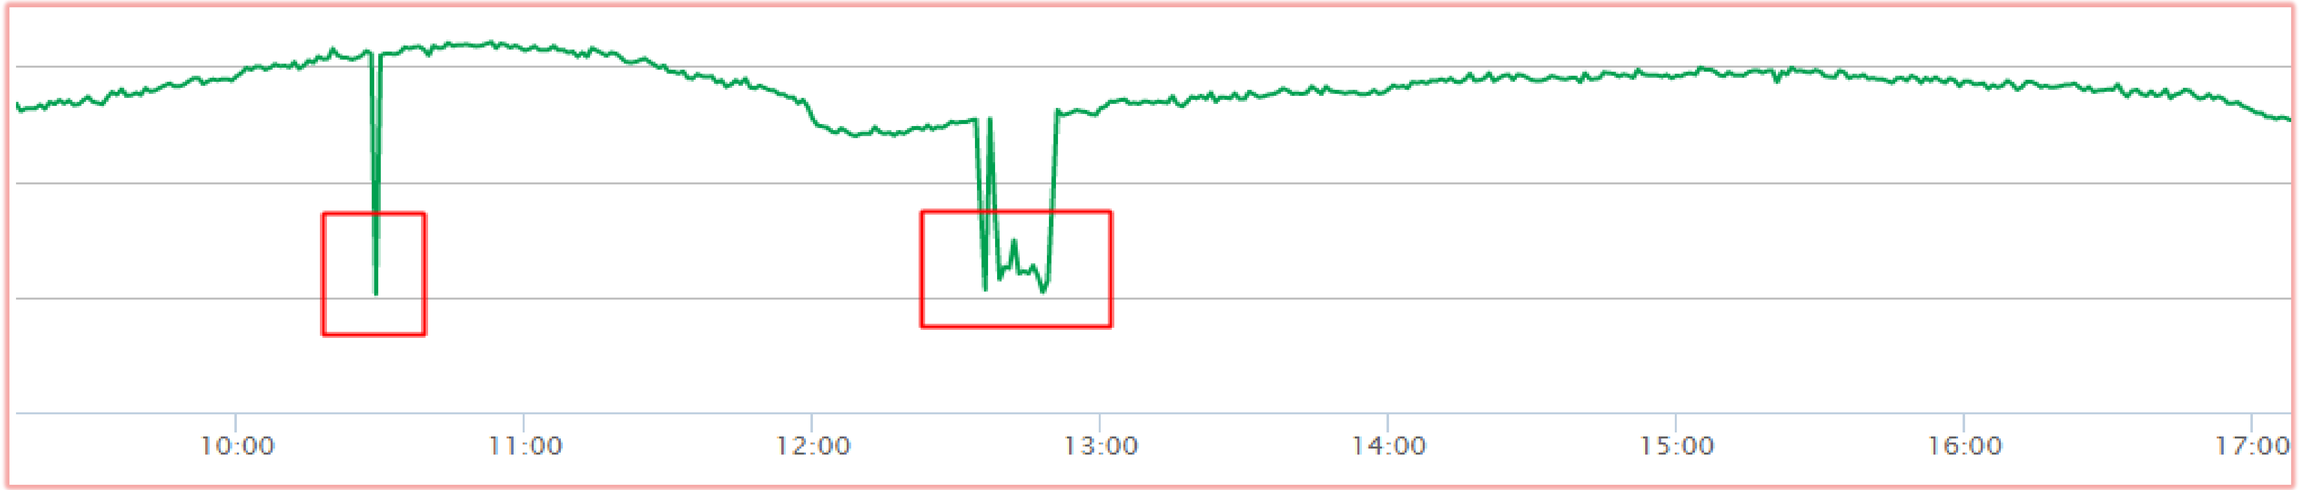

缓慢下降变化的判断

- 动态窗口累积计算
  - 监控系统精细采集的弊端
  - 10s, 30s =>15mins, 1hour, 24hours
  - 对动态累积窗口应用前述方法

自动生成的阈值 vs. 业务需求

- 工程师标注
  - 修改参数
  - 标记未检测到的异常
  - 标记错误的报警

- 机器学习
  - 标注报警 => 参数训练 => + / -

异常检测系统

- 离线部分

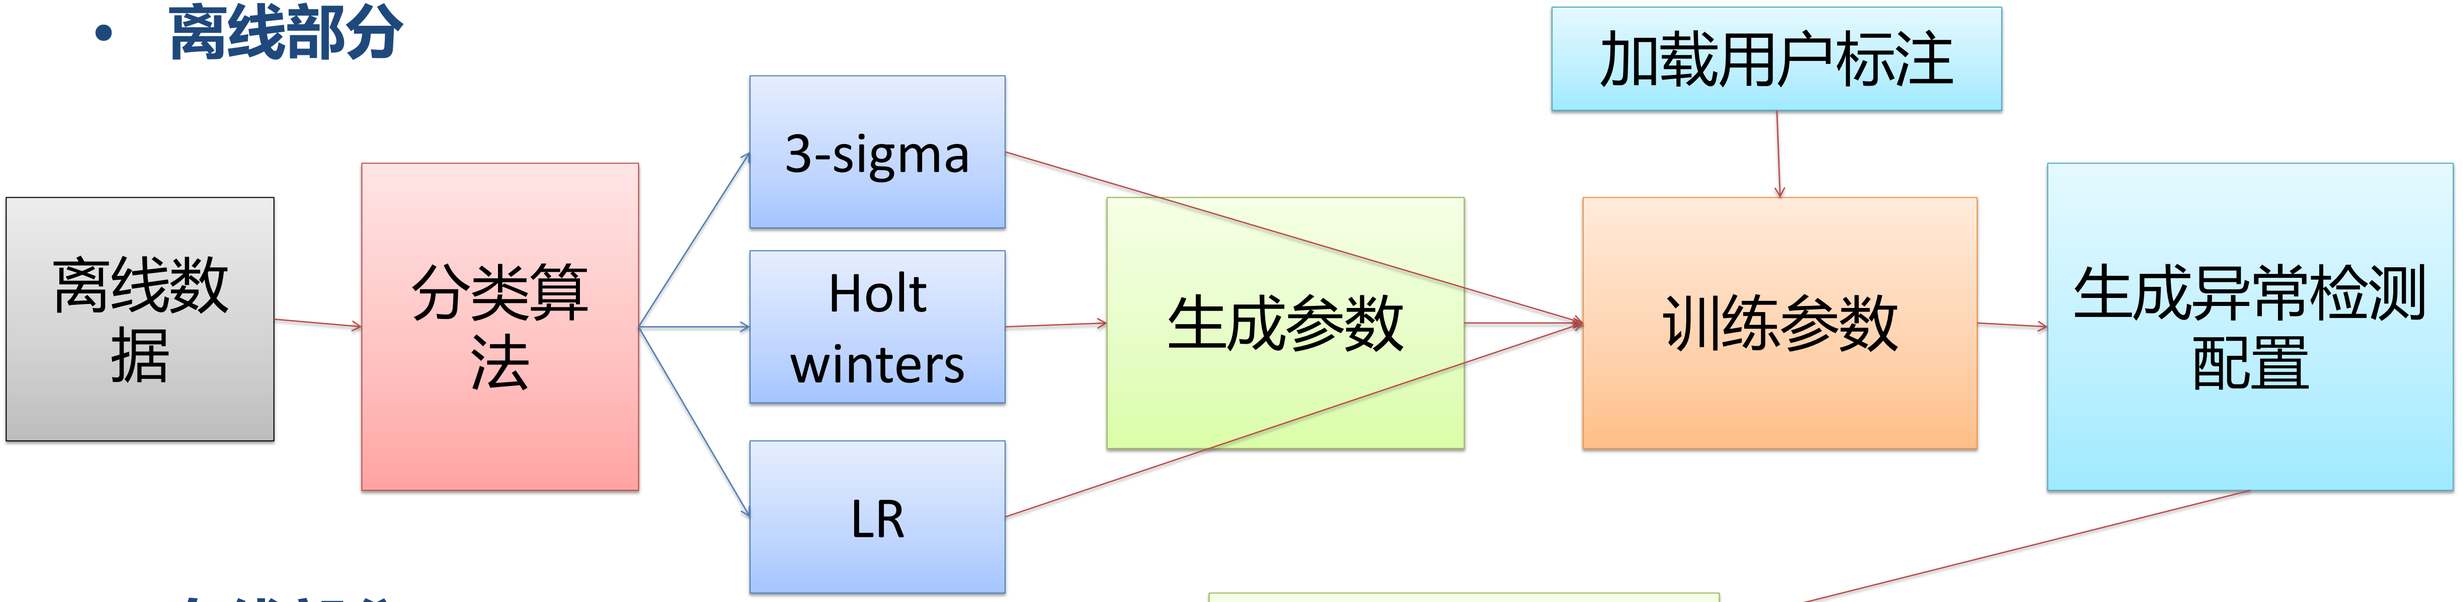

- 在线部分

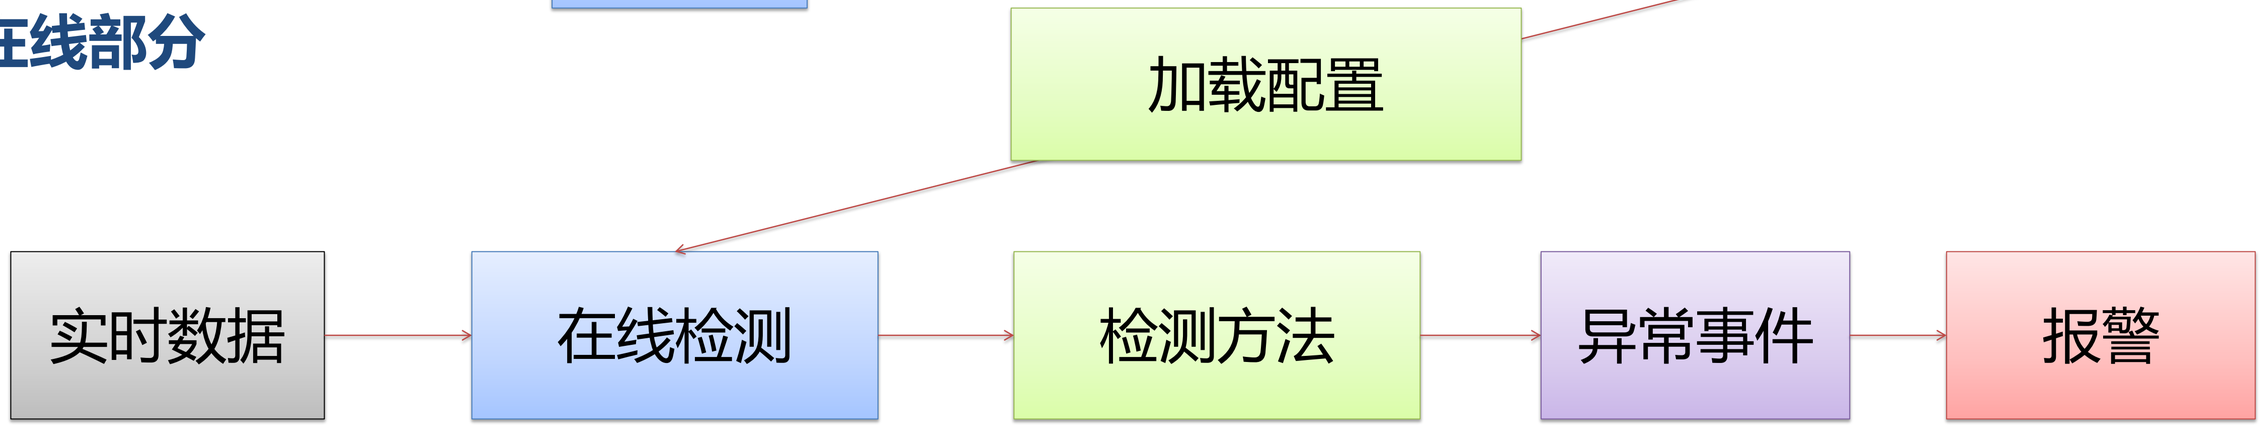

发现问题篇：精准报警

报警风暴

- 是否每次异常都应该报警？

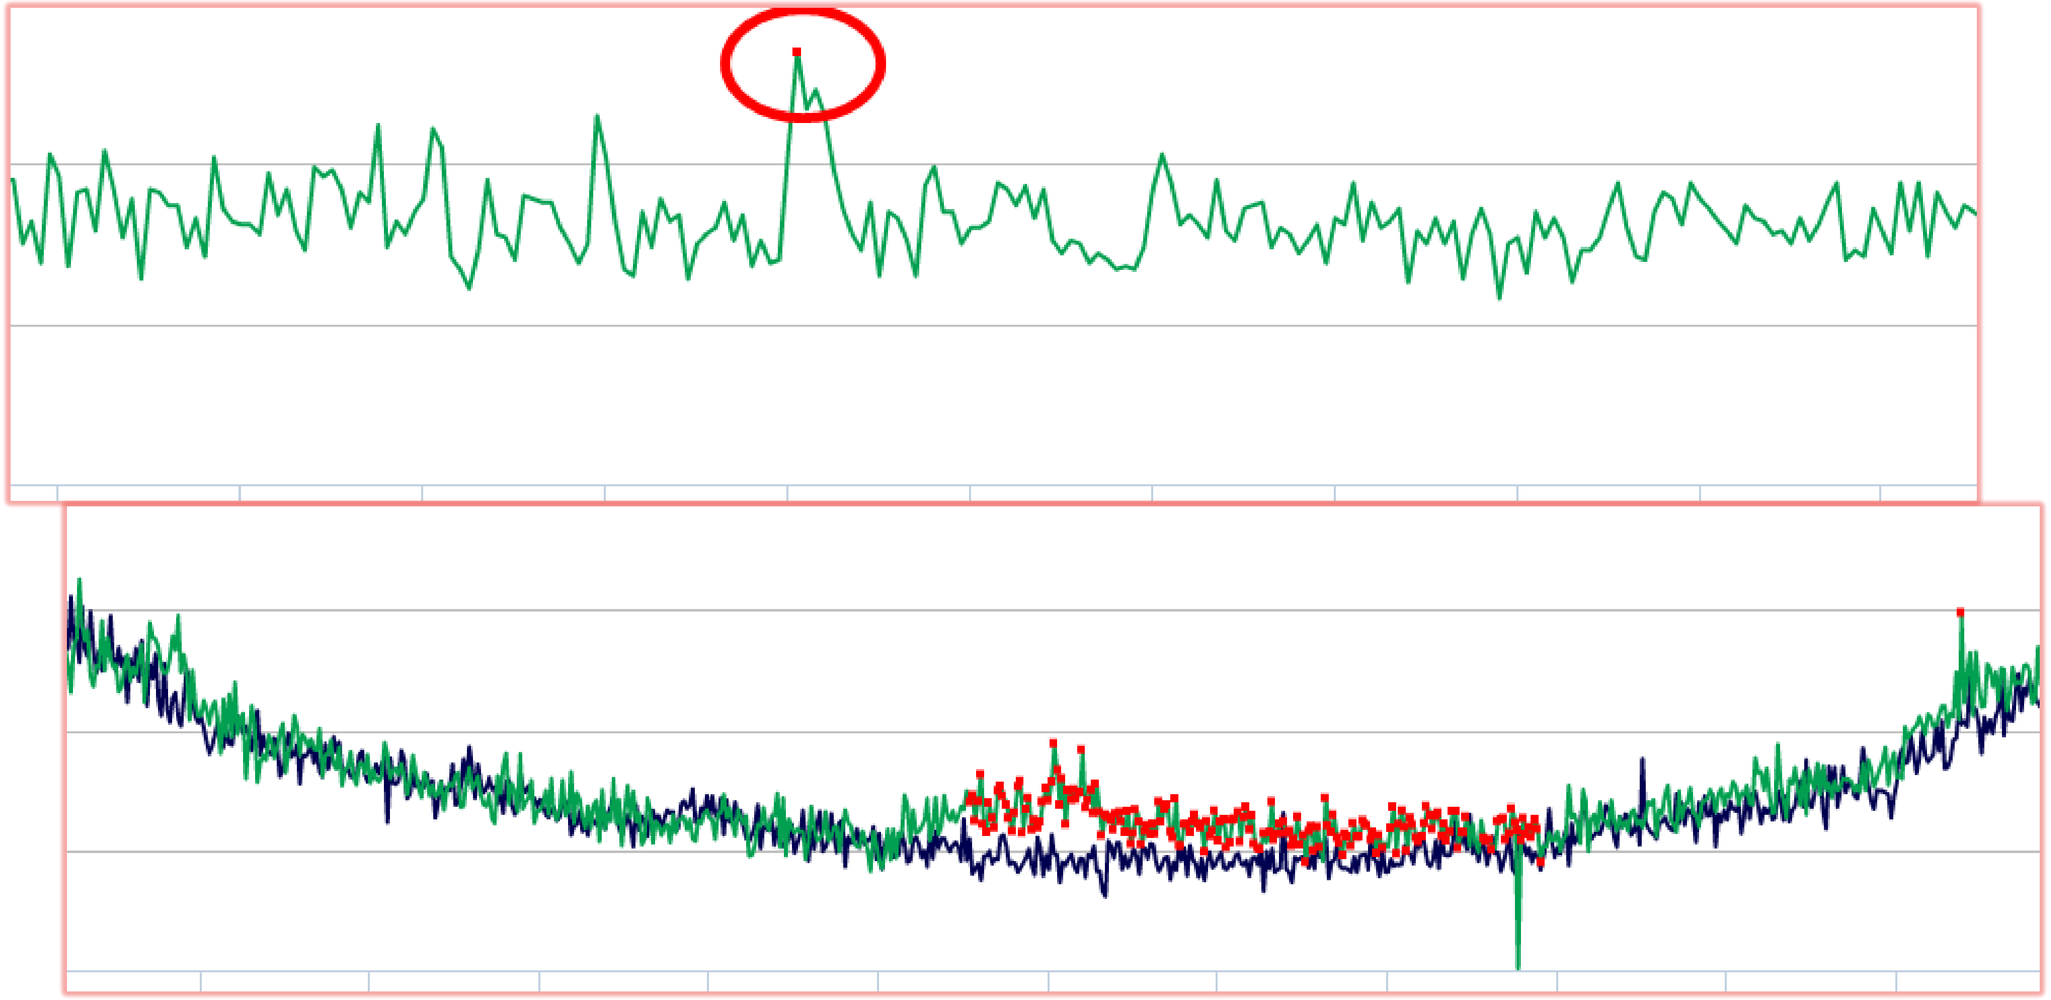

异常过滤

- Viterbi
- 将异常点转化为异常事件或状态

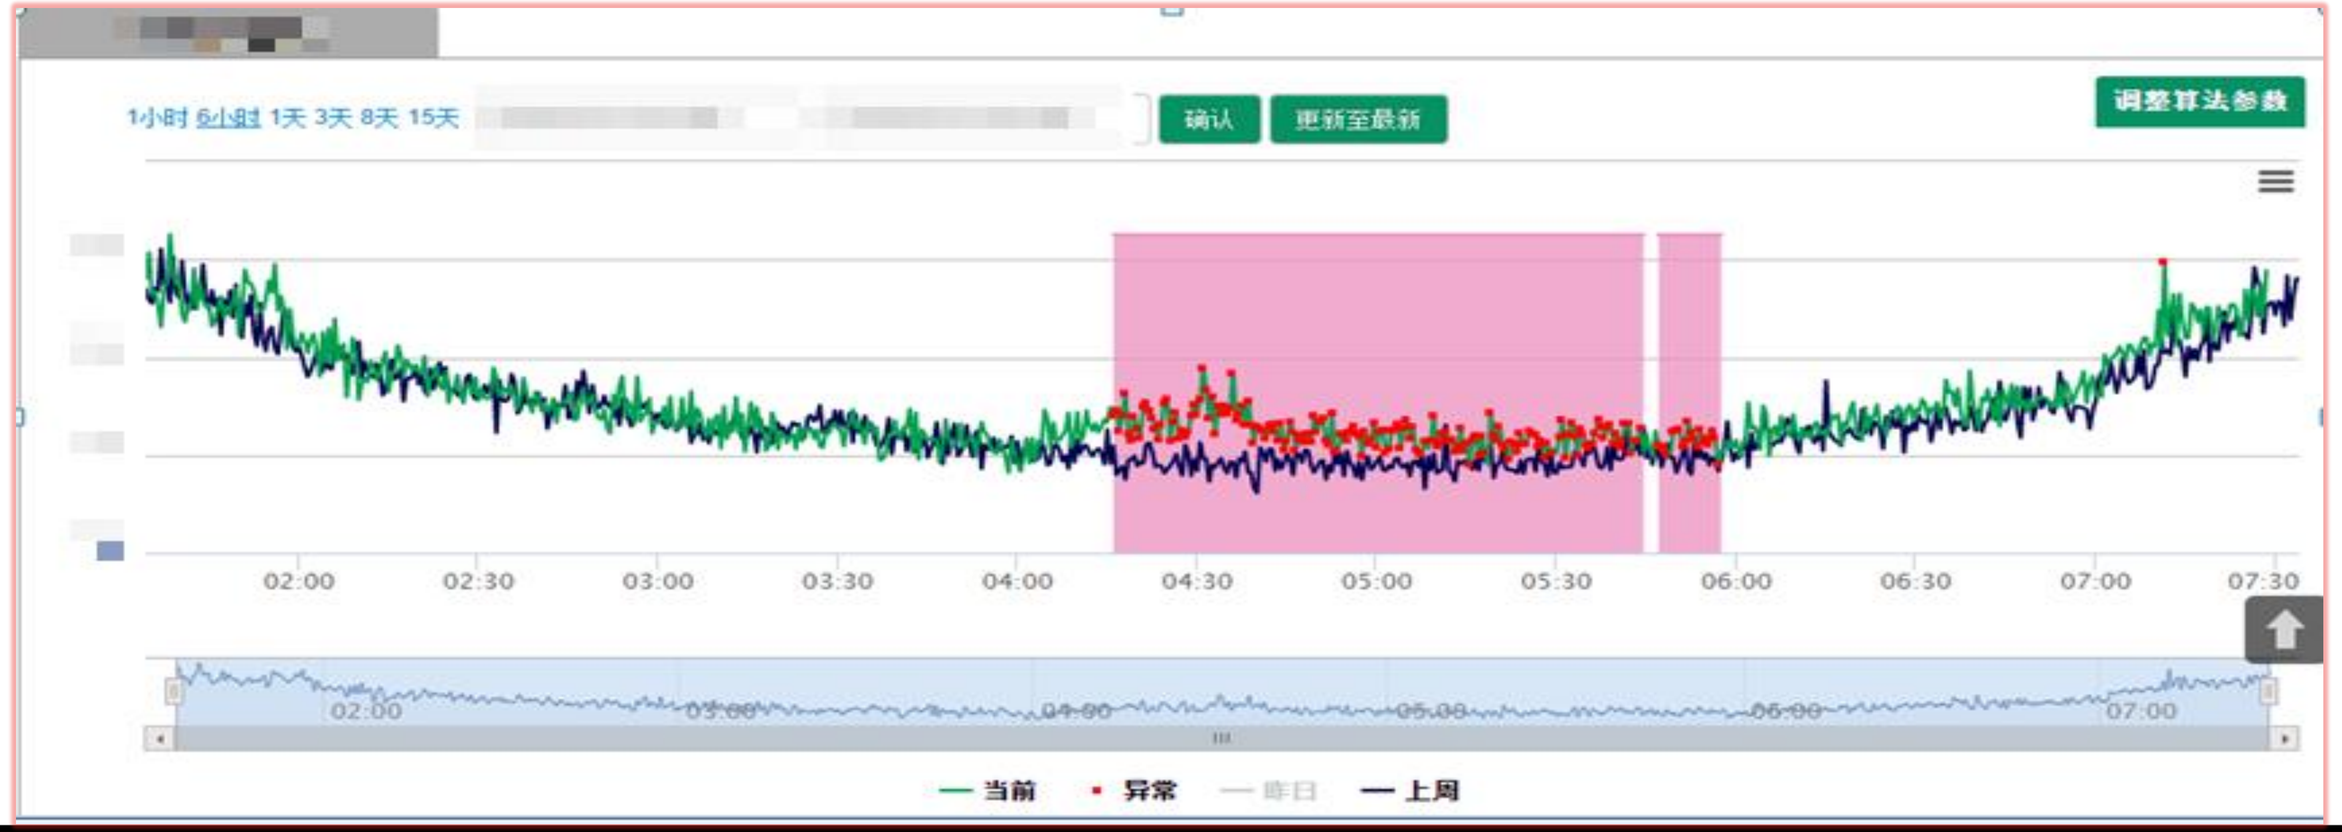

报警合并

- 简单策略
  - 固定时间窗口
  - 相同监控策略
  - 相同监控对象

- 复杂策略
  - 关联挖掘
  - 找到报警的频繁项集
  - 自动合并置信度较高的频繁项集

报警的频繁项集挖掘

2014-11-27 21:33:25，appui-81.pro.alll，appui-81.pro.all:instance:conn_php_failed_cnt_gt_0
2014-11-27 22:43:25，back-13.pro.all，back-13.pro.all:instance:runtime

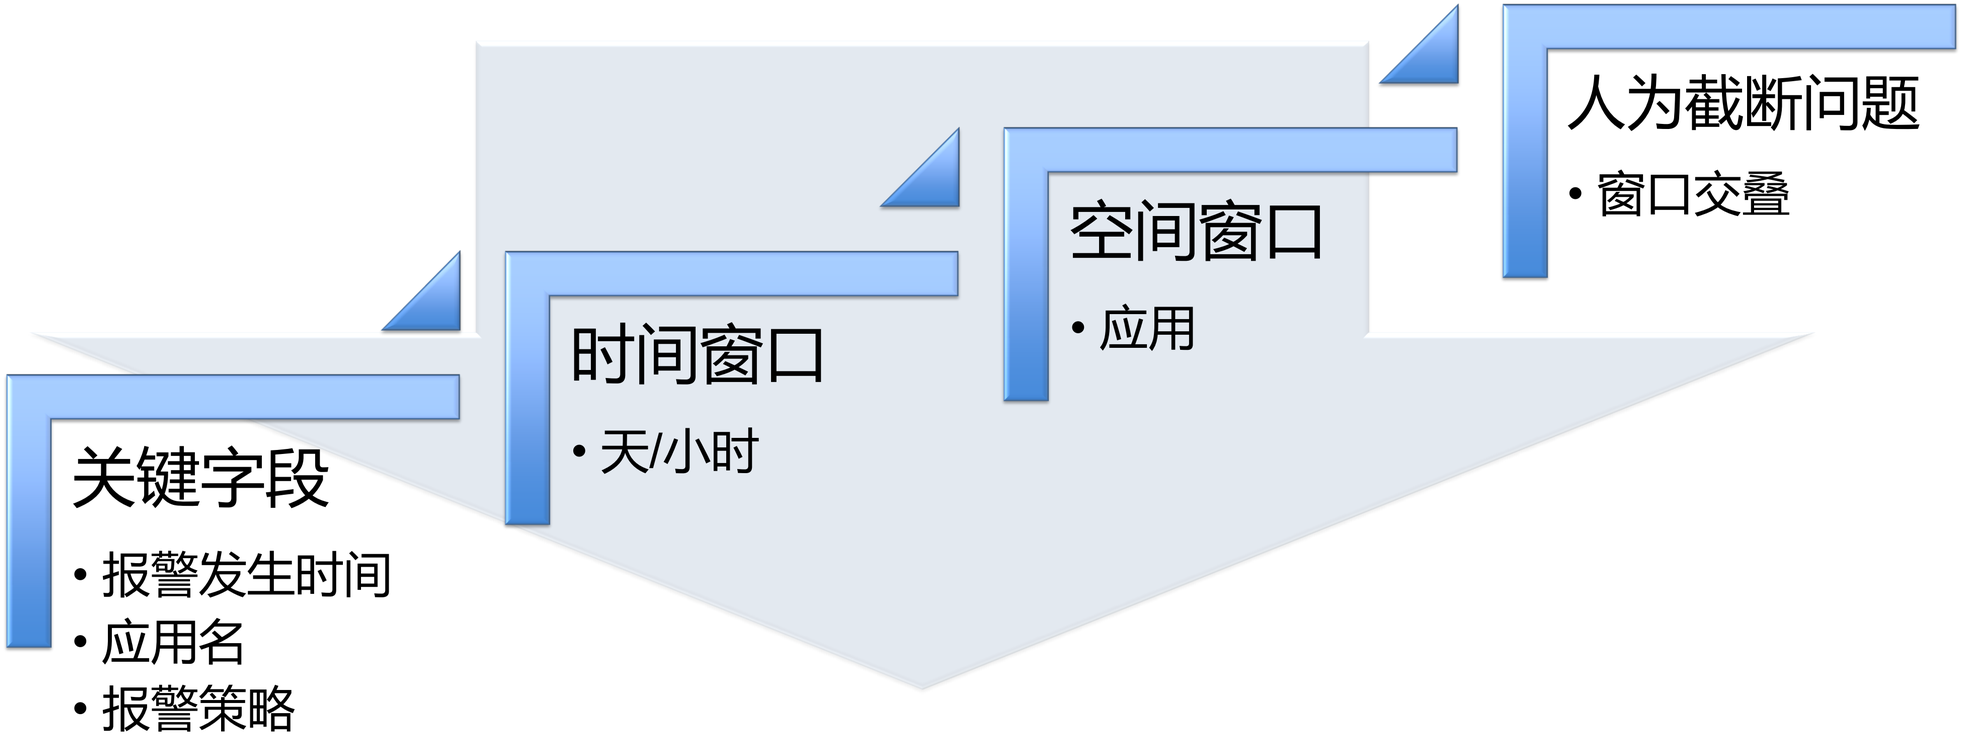

pro_2014-11-26 appui-81.pro.all:instance:conn..., back-13.pro.all:instance:runtime..., ...
pro_2014-11-27 appui-81.pro.all:instance:conn..., back-13.pro.all:instance:runtime..., ...
pro_2014-11-28 appui-81.pro.all:instance:conn..., back-13.pro.all:instance:runtime..., ...

报警依赖&升级

- 报警依赖
  - 策略依赖
  - 异常依赖
- 报警升级
  - 第一报警处理接收人错过报警时，通知更大范围处理人员
  - 核心指标报警持续异常时间达到向上通报阈值时，通知更高level人员

这样就够了吗？

- 分析问题篇
  - 建立关联分析
    - 常用于问题定位，迅速找到相关的指标

产品服务层级的关联关系

如何为复杂多样的运维数据建立关联？

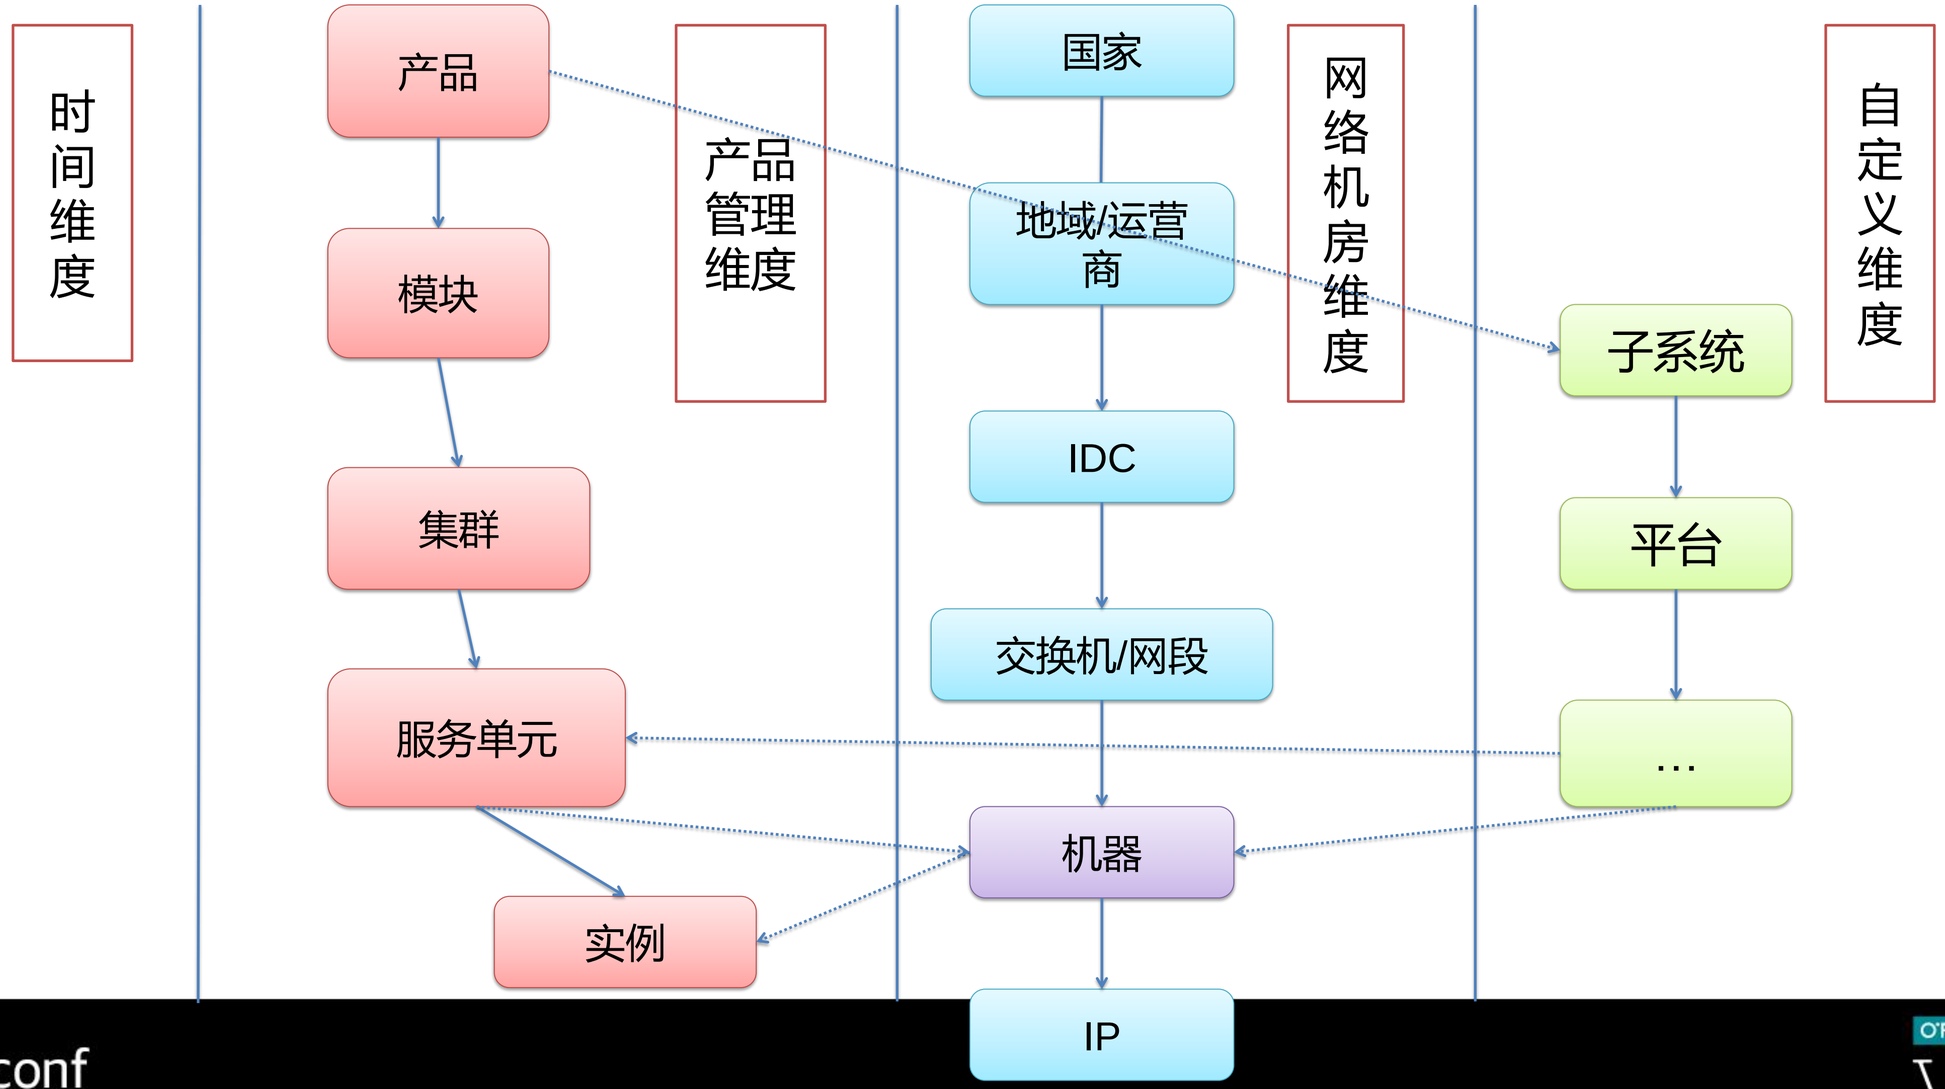

关联挖掘

- 事件&事件
  - 频繁项集挖掘
  - 所有运维事件：报警、变更、调度任务…
- 事件&时序
  - 指标异常经常部署变更事件相伴发生
  - 问题诊断&故障定位

多时序关联挖掘

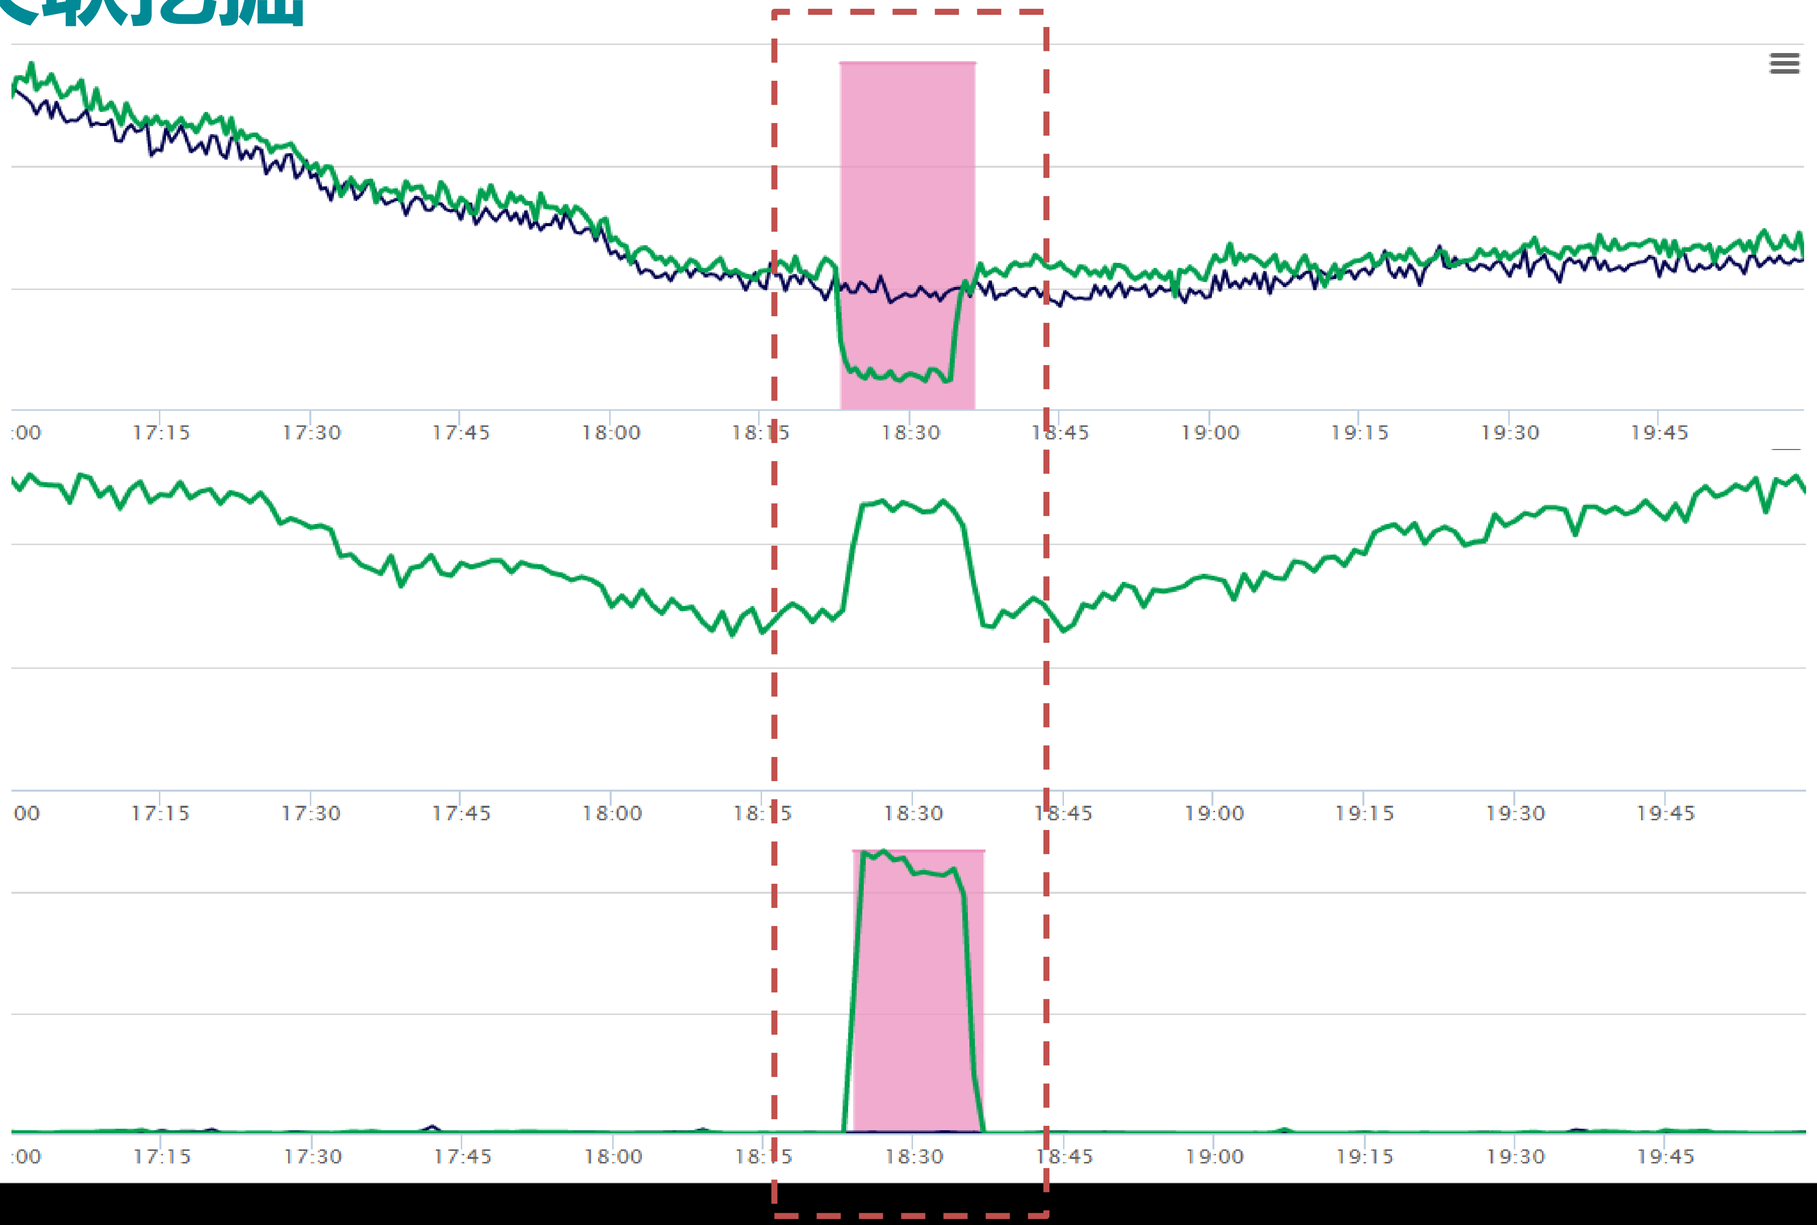
:00
17:15
17:30
17:45
18:00
18:15
18:30
18:45
19:00
19:15
19:30
19:45
00
17:15
17:30
17:45
18:00
18:15
18:30
18:45
19:00
19:15
19:30
19:45
:00
17:15
17:30
17:45
18:00
18:15
18:30
18:45
19:00
19:15
19:30
19:45

关联可视化

- 事件&事件关联
  - 事件流图
- 事件&时序关联
  - 指标趋势+变更事件展示

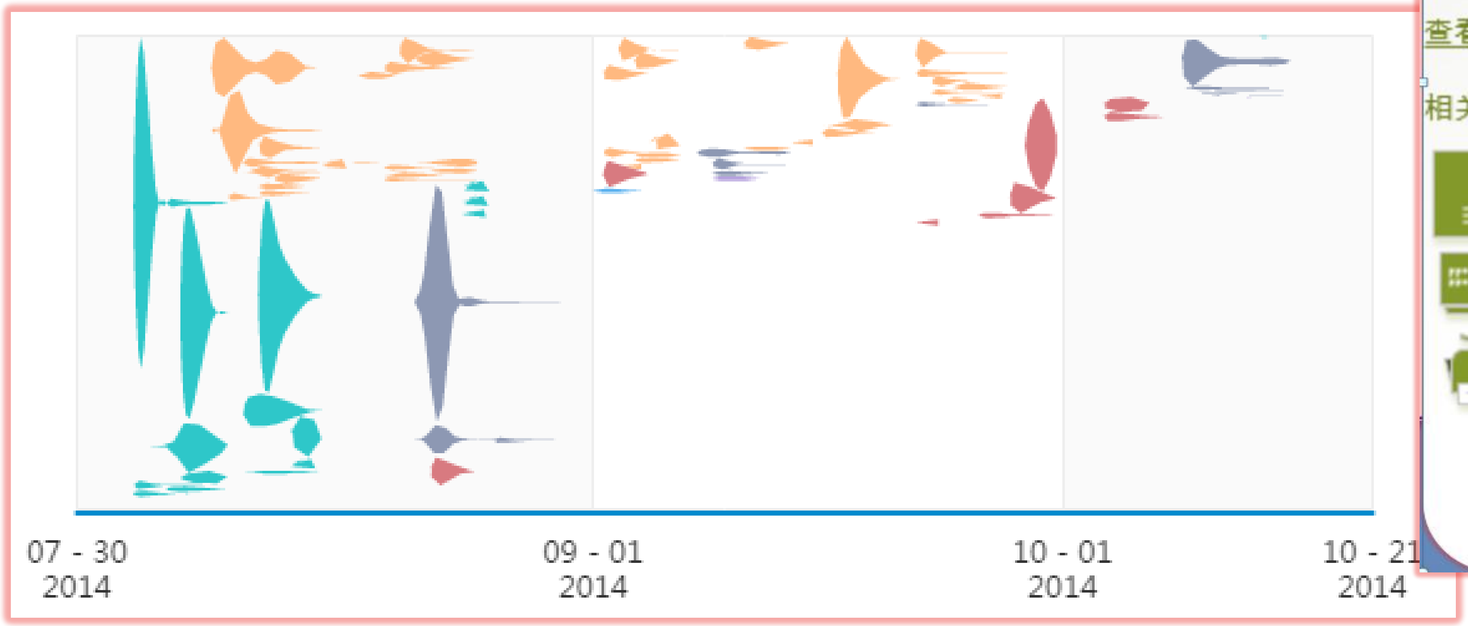

服务透视

- 模块调用关系
- 事件和模块关联

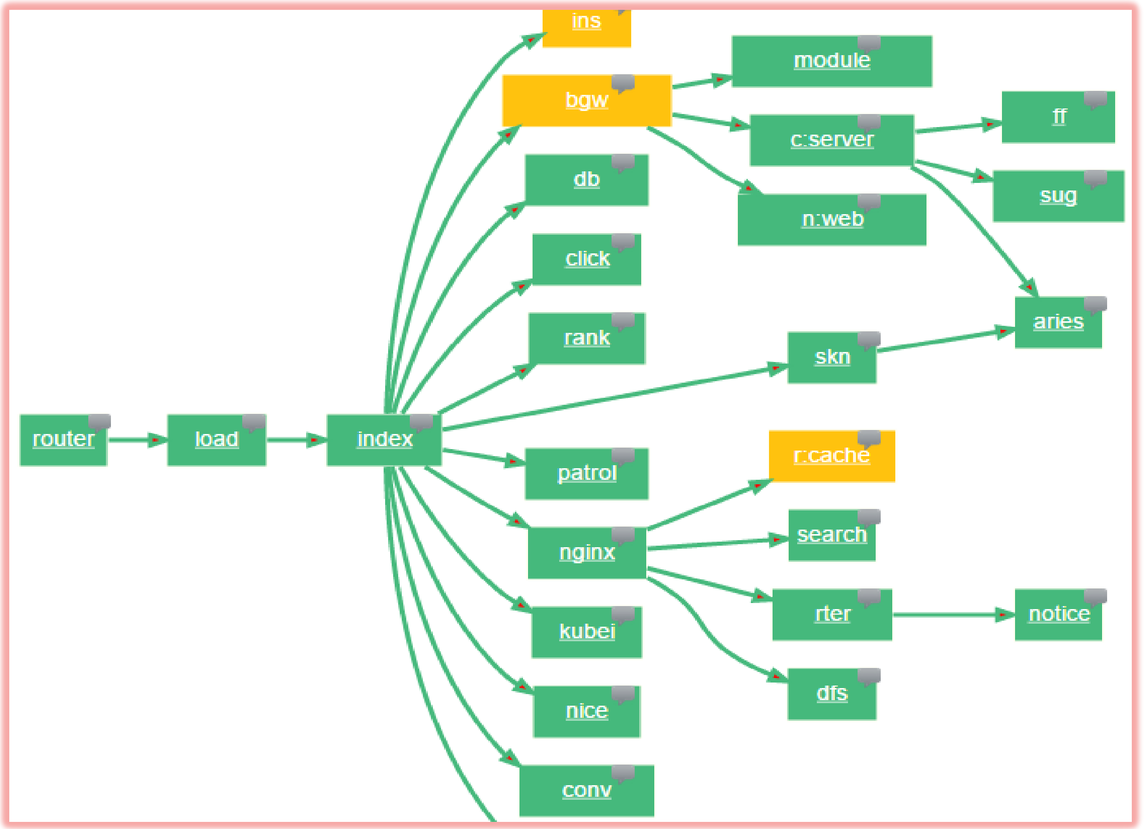

故障定位

- 找到了关联还不够
- 分析问题解决问题才是关键

多维数据分析

- 总体维度与细分维度
- 举例: 总体流量vs.分地域流量
- 按细分维度影响权重排序

属性	当天值	占比	天同比	天变化里	周同比	周变化里	操作
[redacted]	[redacted]	0.56%	-11.68%	-465.14	0.97%	33.79	查看
[redacted]	[redacted]	1.55%	-3.87%	-390.12	19.47%	1,578.63	查看
[redacted]	[redacted]	0.28%	-12.24%	-240.55	-2.85%	-50.60	查看
[redacted]	[redacted]	0.50%	-4.39%	-144.71	7.21%	211.84	查看
[redacted]	[redacted]	0.87%	-1.68%	-92.70	-1.61%	-88.87	查看
[redacted]	[redacted]	0.23%	-4.82%	-72.90	30.80%	339.08	查看
[redacted]	[redacted]	0.04%	-20.74%	-69.28	-0.03%	-0.08	查看
[redacted]	[redacted]	0.04%	-22.99%	-67.92	7.53%	15.93	查看
[redacted]	[redacted]	0.01%	-52.96%	-57.22	-33.17%	-25.23	查看
[redacted]	[redacted]	0.79%	-0.83%	-41.00	2.01%	97.13	查看

多维数据分析的应用

- 交叉维度展示异常情况
- 分地域、浏览器、运营商、数据中心…
- 热力图直接展现异常维度

故障诊断树

- 领域专家知识
- 逻辑推导引擎
- 迅速找到问题根因

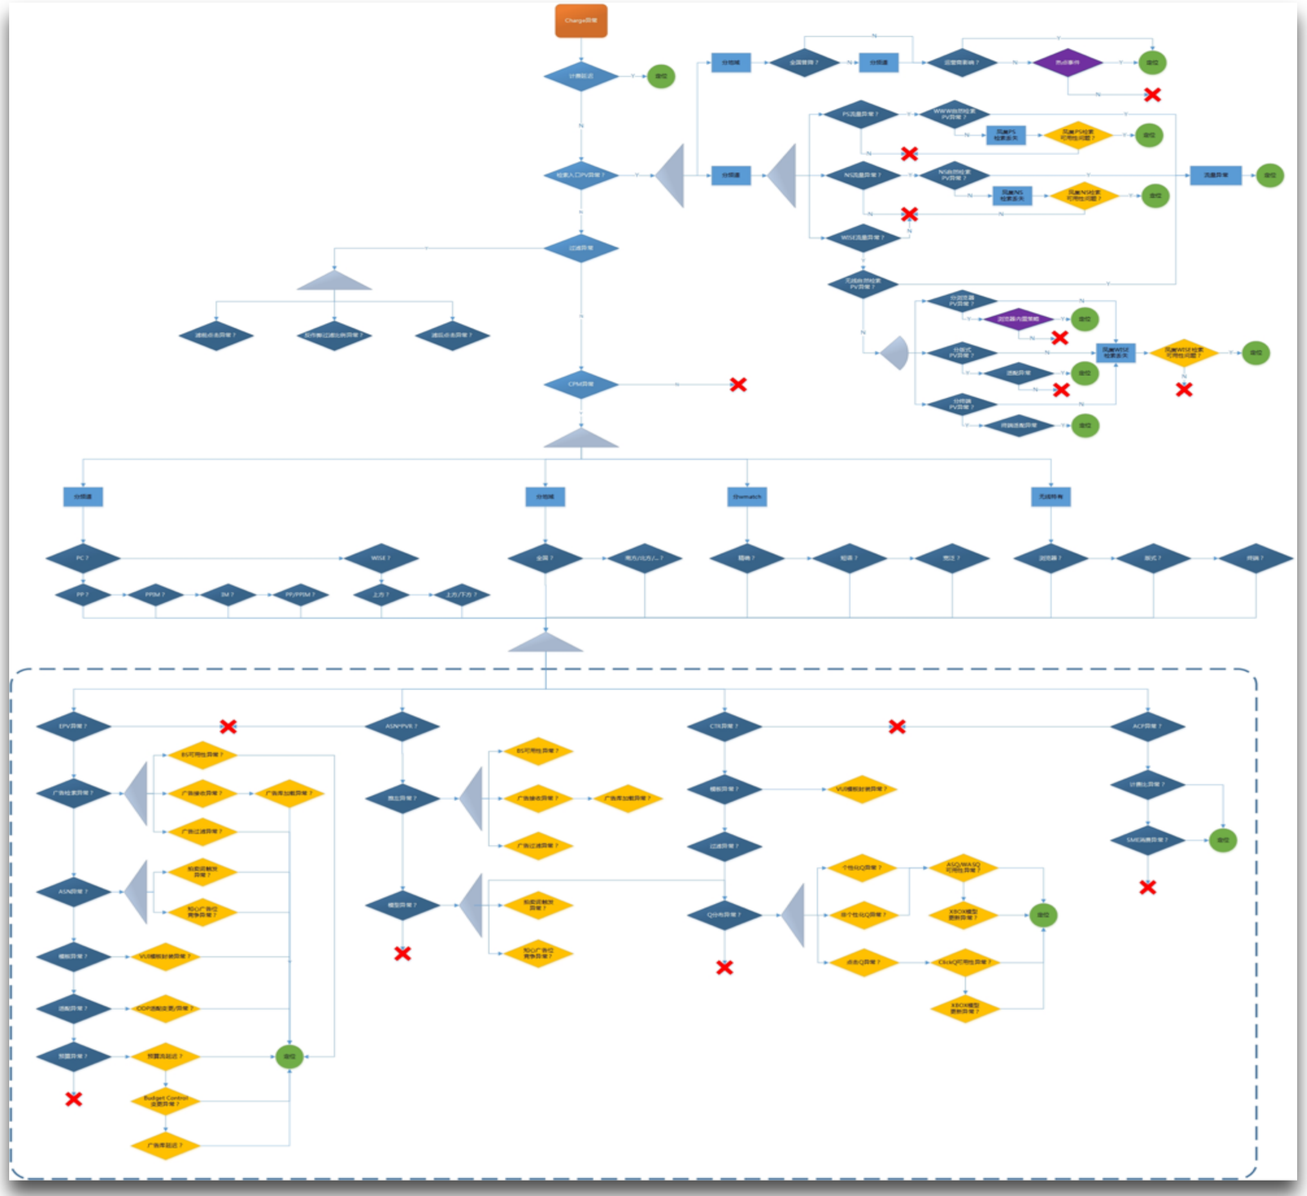

问题自动定位

随时间推演 → 推导路径 → 问题根因推荐

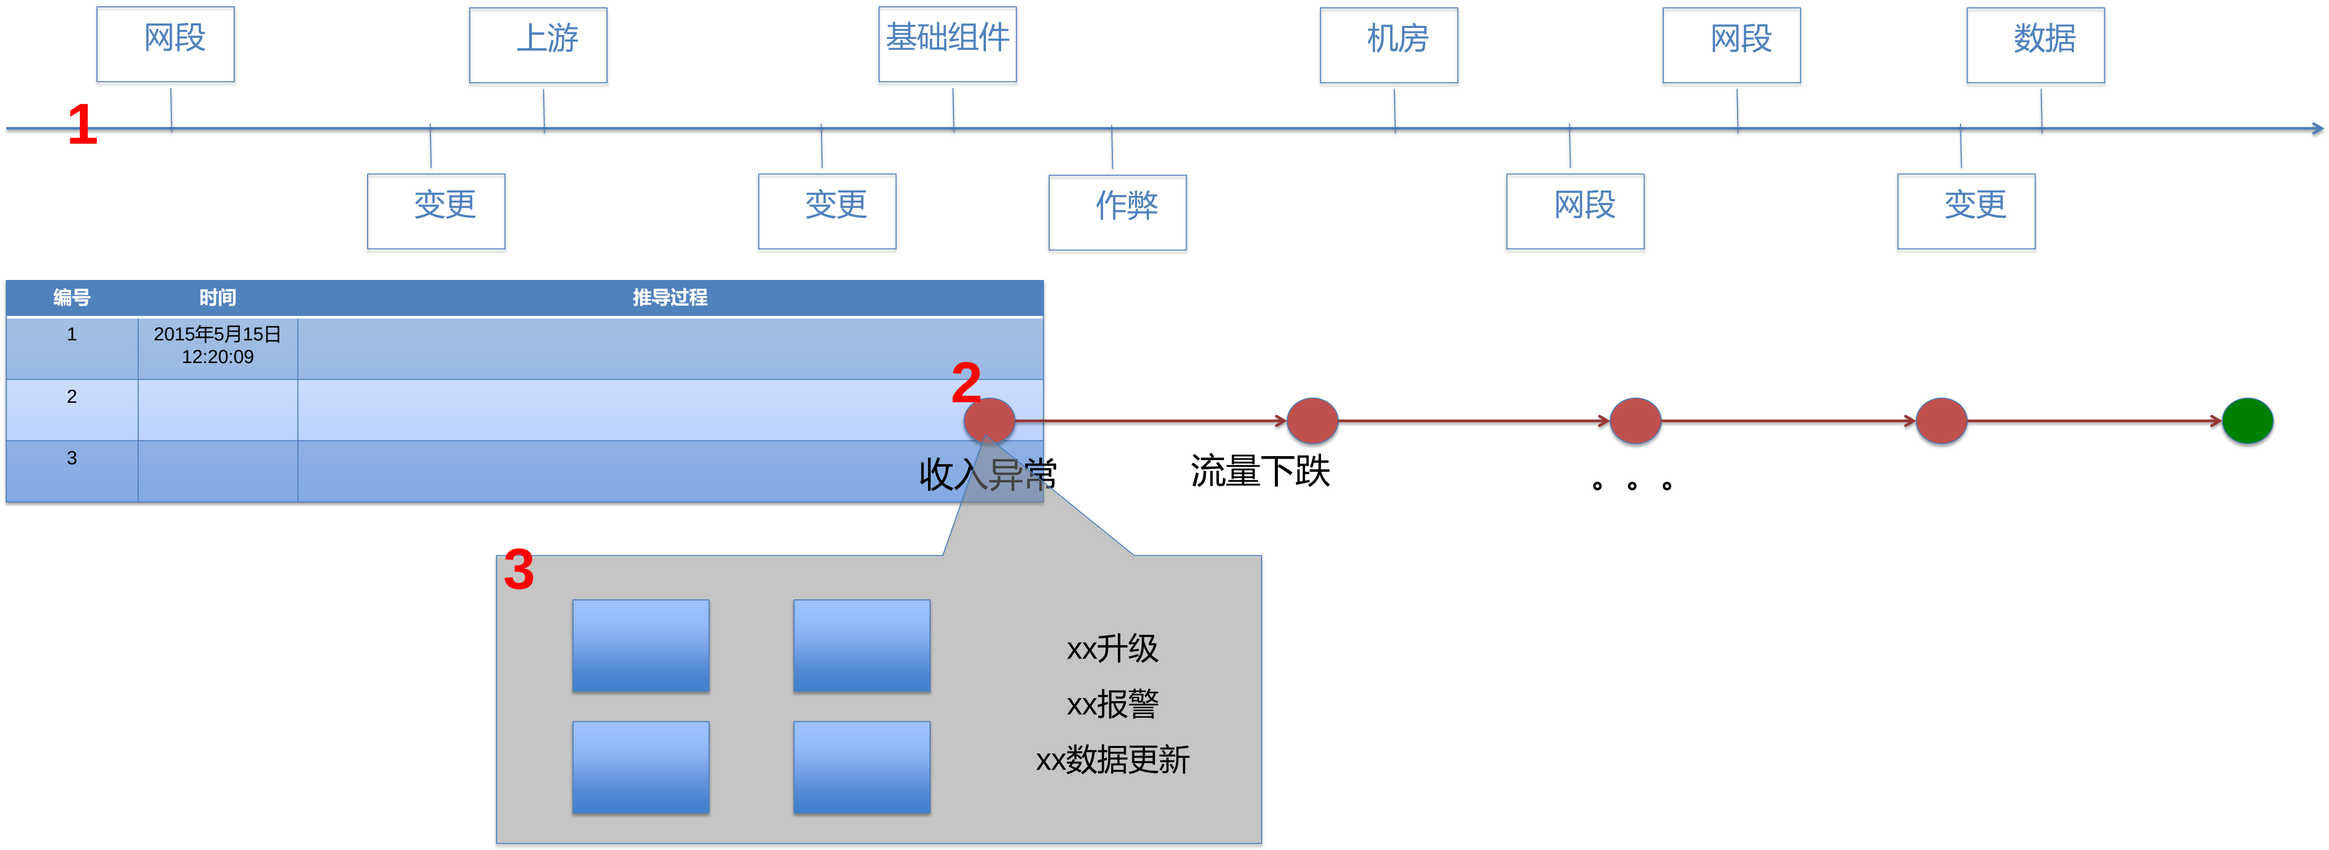

监控“闭环”

- 让监控系统的环闭合！
  - 问题发现 -> 分析决策 -> 处理 -> 循环往复
- 监控系统与部署调度系统结合
  - 监控系统产生决策
  - 部署调度系统执行

解决问题篇：单边故障自动止损

- 什么是单边故障？
  - 单个IDC故障、单个链路故障等
- 如何止损？
  - 实现自动冗余与调度
  - 智能监控系统负责动态决策
  - 部署调度系统复杂调度执行

灰度发布自动止损

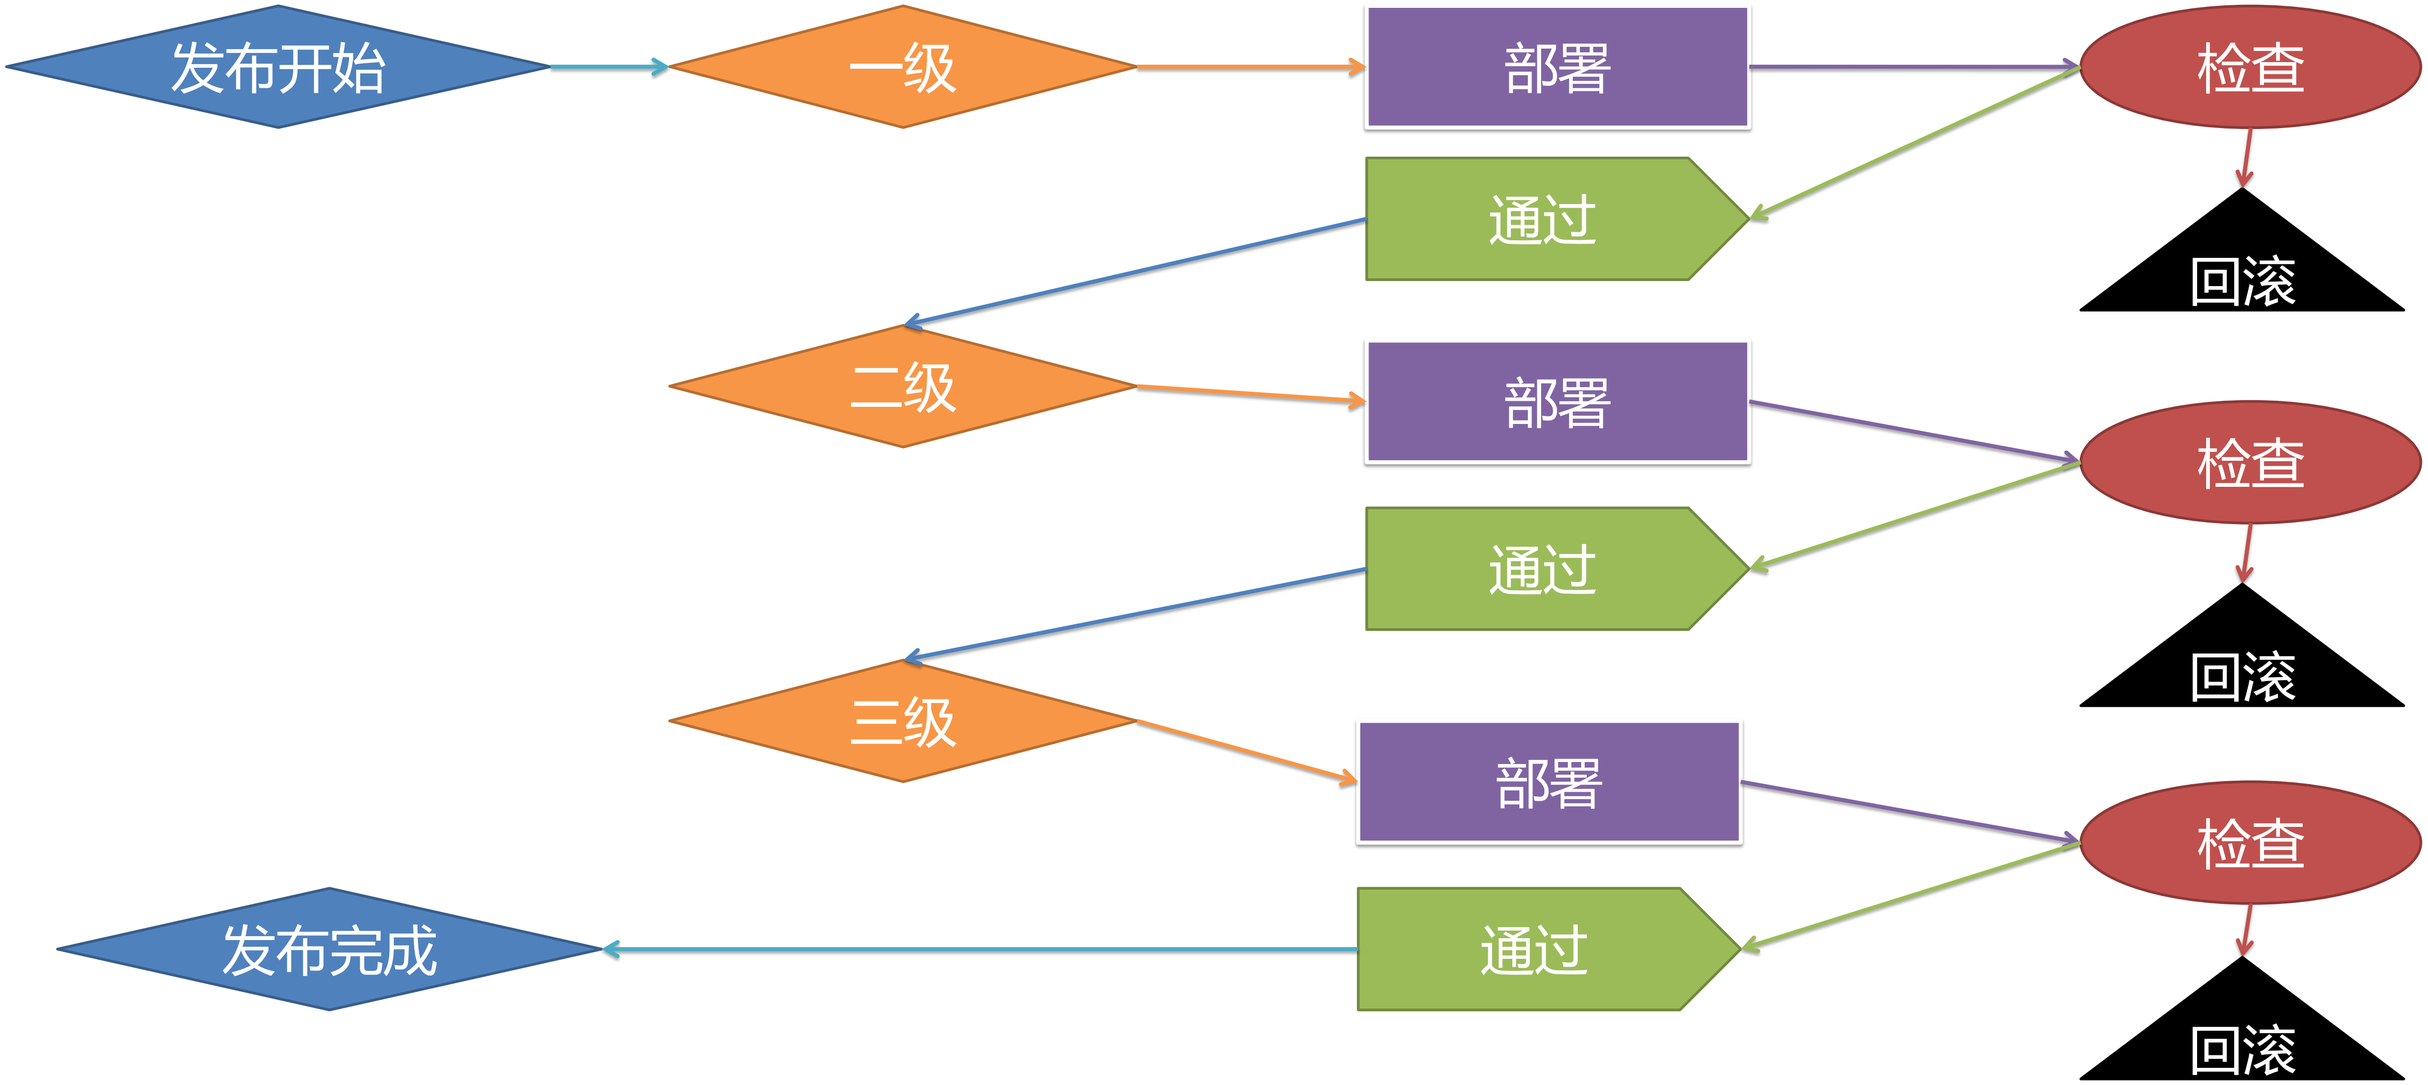

智能运维监控

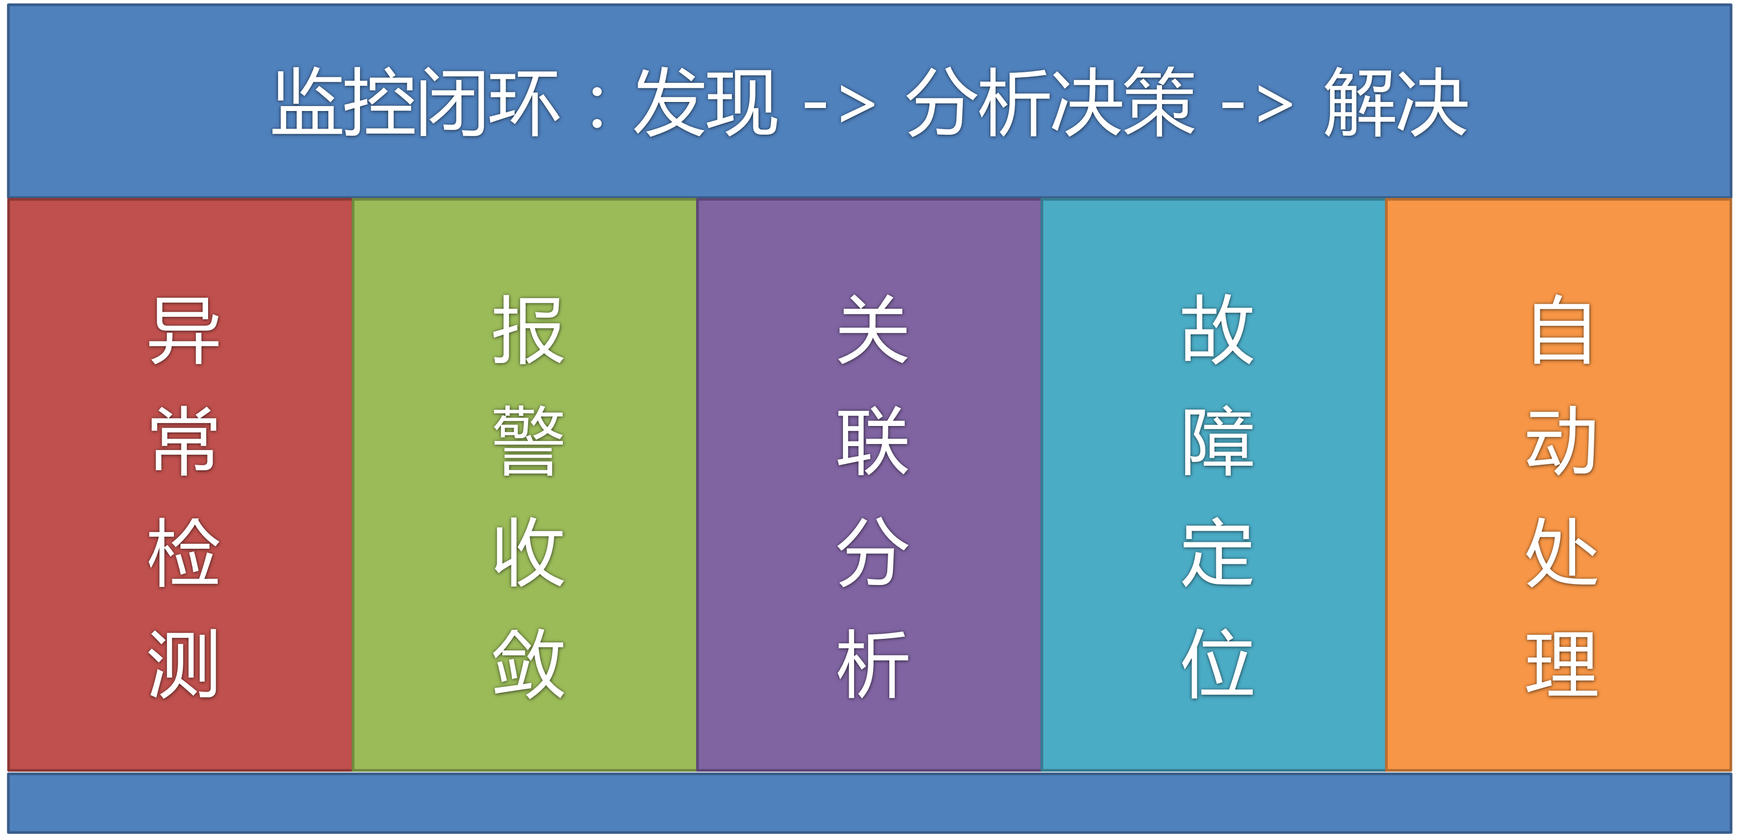

未来：变被动为主动

- 全方位覆盖
  - 在用户端（APP、浏览器等）、云端（机房、服务器、自身服务、第三方服务等）、管道（链路、运营商）等任何维度进行数据采集并进行异常自动检测
- 大数据分析&可视化
  - 分析运用已有数据，并把服务状态、问题影响分析等可视化
- 让监控更聪明
  - 自动学习并理解故障的趋势和模式
  - 自动发现服务或依赖环境的变更
- 预测故障
  - 先于故障发生之前解决

谢谢