智能运维中的
异常检测和根源分析

赵宇辰

智能运维中的异常检测和根源分析

- **性能监控里的时间序列**
- 传统方法
- AI + 时间序列
    - 异常检测
    - 根源分析
- 总结

性能监控里的时间序列

常见的时间序列 / metrics：

- Block Time (ms), Average Block Time (ms)
- Calls, Number of Calls
- Calls/min, Calls per Minute
- CPU Used (ms), JVM CPU Burnt (ms/min)
- Errors/min, Errors per Minute
- Response Time (ms), Average Response Time (ms), Avg. Time per Call
- Slow Transactions, Number of Slow Calls
- Stalled Transactions, Stall Count
- Wait Time (ms), Average Wait time (ms)

性能监控里的时间序列

常见的时间序列类型：

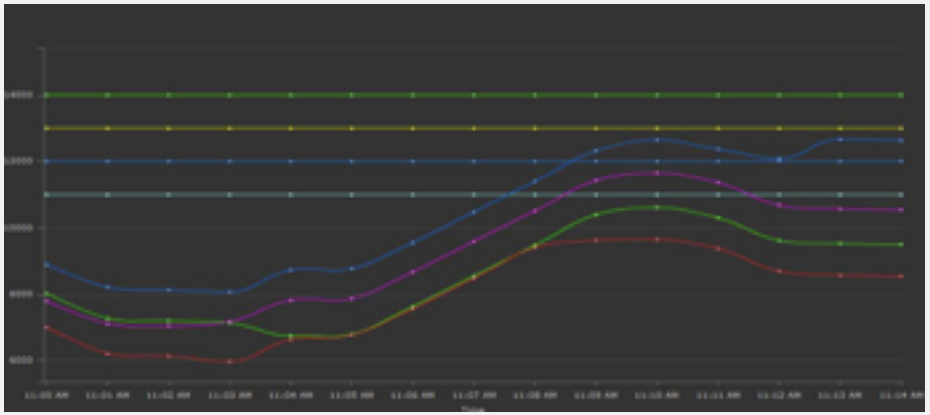

- Backends / 后端
- End User Monitoring / 用户UE
- Mobile / 手机
- Service End Points / 服务端
- Overall Application Performance / 全局
- Business Transaction Performance / 业务相关
- Application Infrastructure Performance / 基础设施
- Errors / 错误

性能监控里的时间序列

常见的时间序列计算：

- 原始数值（observation）
- 最小值 / 最大值（min / max）
- 总和（sum）
- 平均值（avg）
- 数量（count）
- 百分比（%）
- 百分位数（percentile）

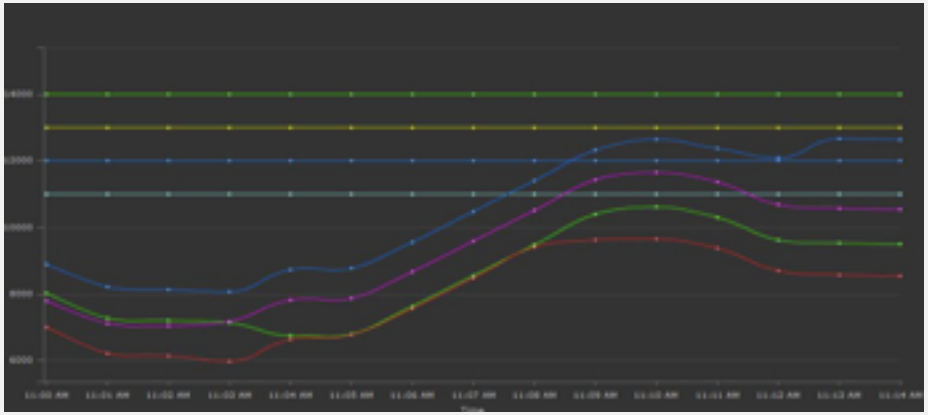

智能运维中的异常检测和根源分析

- 性能监控里的时间序列
- **传统方法**
- AI + 时间序列
    - 异常检测
    - 根源分析
- 总结

传统方法

方法一：固定阈值

- 如果value > 阈值X，发出警报
- 如果value < 阈值Y，发出警报

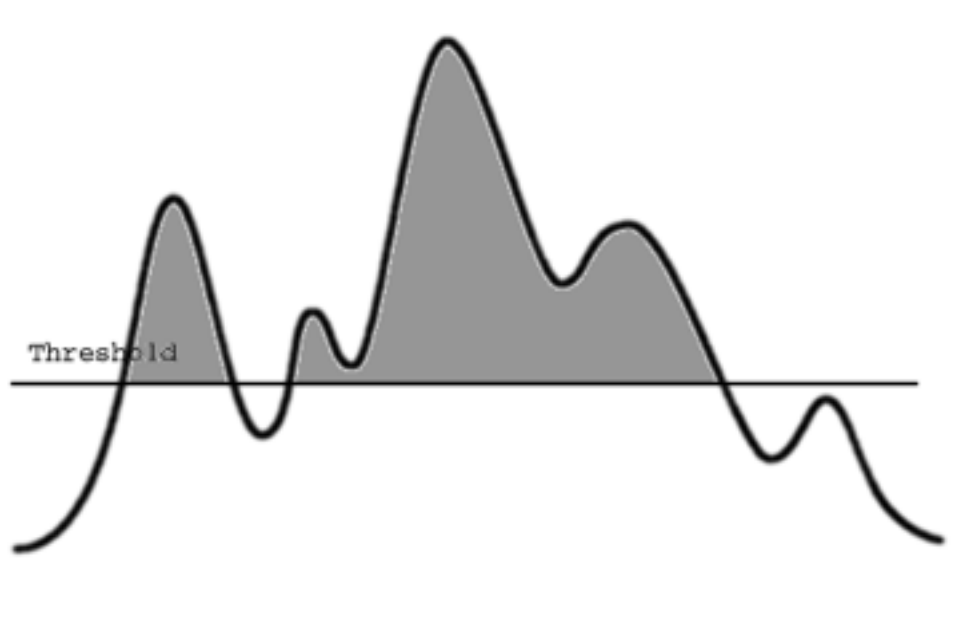

传统方法

方法二：动态阈值

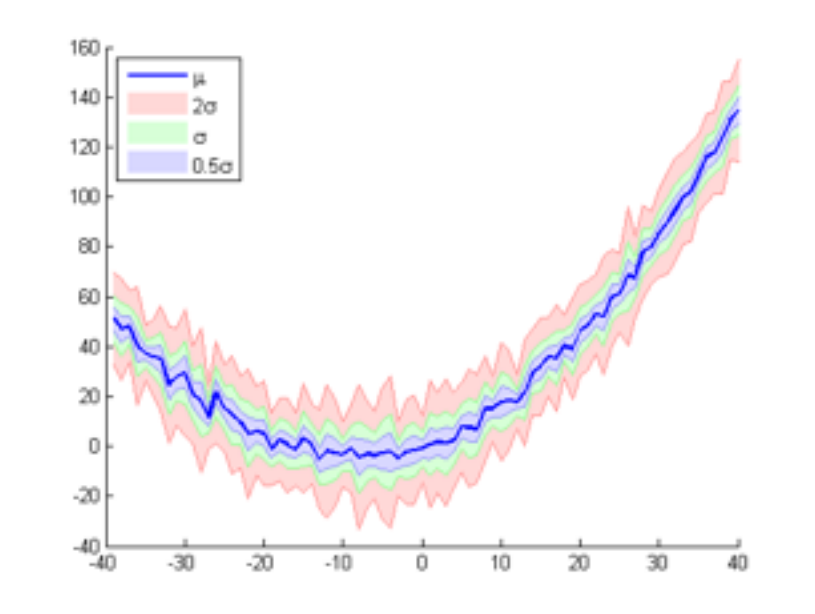

- 计算

  （1）平均值 μ

  （2）方差 σ

- 正常取值区间：$\mu \pm 2\sigma$

- 如果value在区间外，发出警报

传统方法往往效果不好

原因1:

忽视周期性（seasonality）

周期性的时间序列

- 每两小时的定时任务（cron job）
- 每两周升级计划

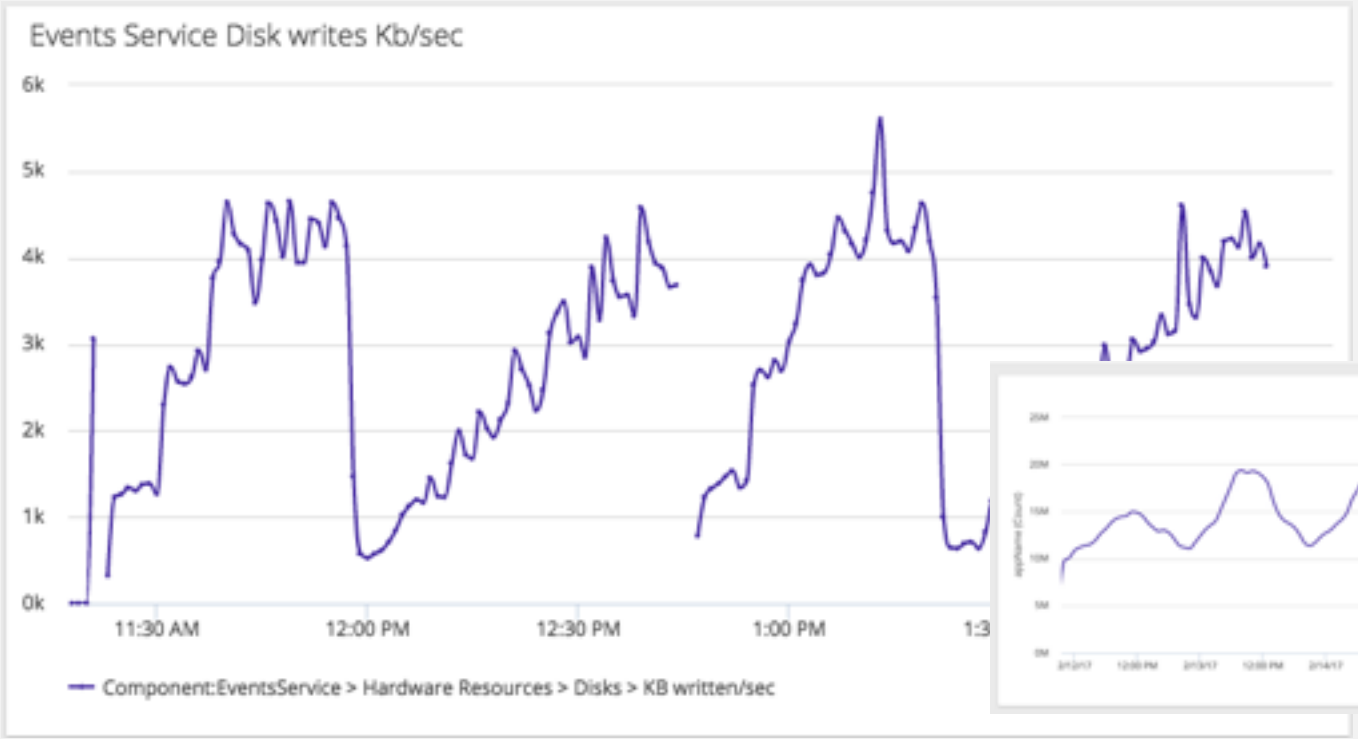

周期性的时间序列

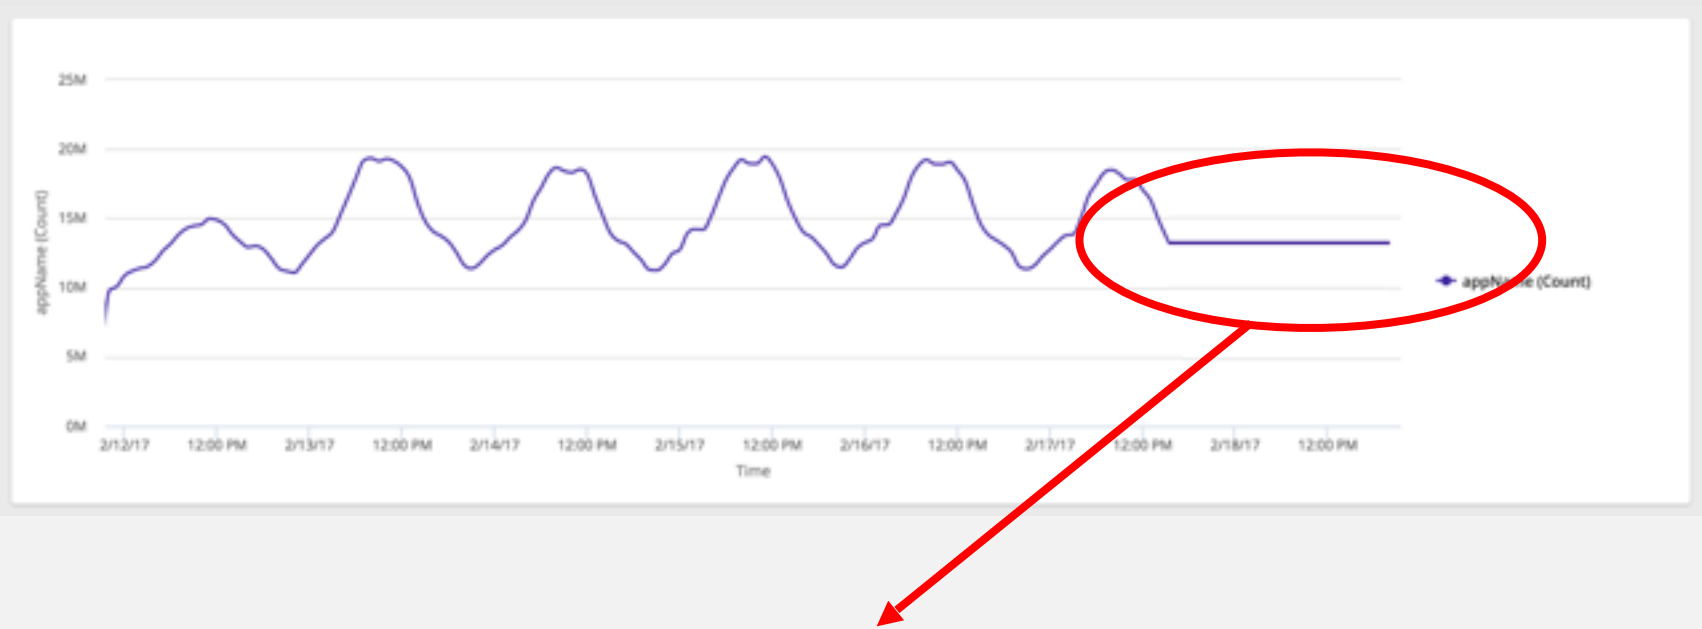

在平均值附近，传统方法不会发出警报，

但是否真的没有异常?

原因2:

忽视趋势（trend）

时间序列里的趋势

时间序列里往往包含趋势：

- 增长的趋势
- 降低的趋势

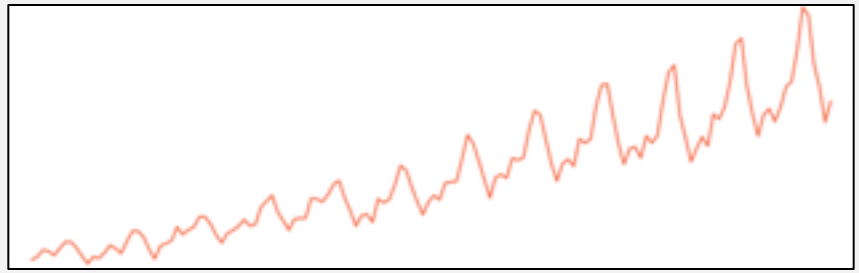

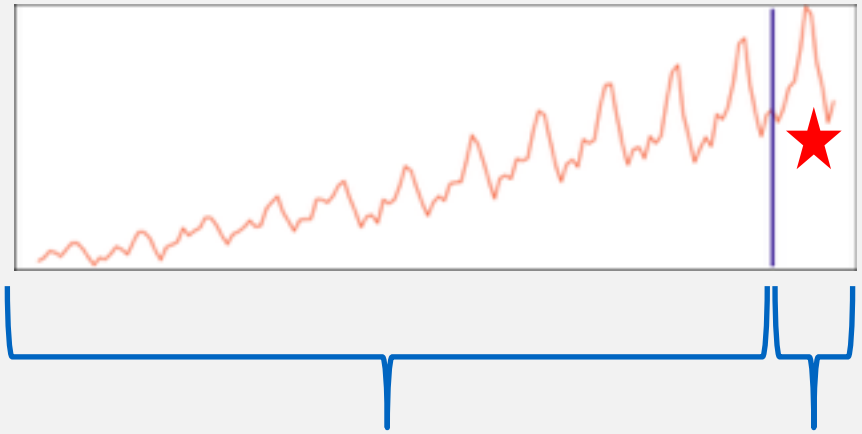

传统方法（固定阈值 / 历史平均值）

- 用过去的数据作为标准
- 造成误判（false positive）

原因3:

数据是不完美的

周期性的时间序列

- 计算

  （1）平均值 μ

  （2）方差 σ

- 正常取值区间：$\mu \pm 2\sigma$
- 如果value在区间外，发出警报

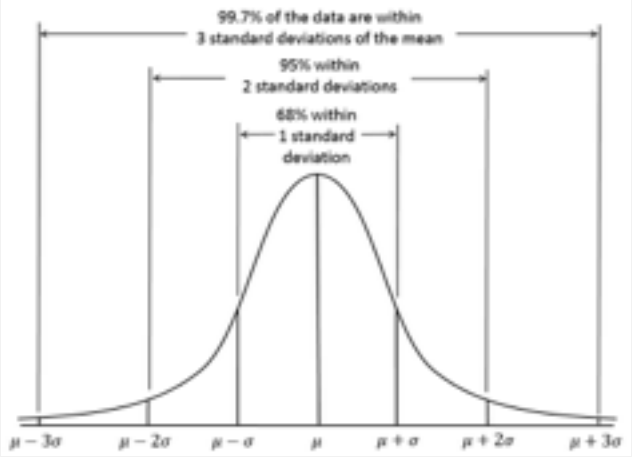

基于normal distribution的假设

即便数据符合normal distribution…

假设每个metric每一分钟有一个值（比如errors per min, avg latency per min等）

- 每天有：1 x 60 x 24 = 1,440 数据点
- 假设我们用μ ± 3σ区间
- 根据normal distribution定义，99.7% 的数据在该范围内
- 1,440 x 99.7% = 1435.68个数据点被认为正常
- 系统认为1,440-1435.68 = 4.32个数据点为异常

这意味着：

- 即使完全正常，每天每个metric会收到**4.32个**错误警报提醒（false alarms）！

原因4:

数据孤岛

数据孤岛

- 每个metric被单独考虑
- 系统里有成千上万个metric
- 彼此相互联系 / 关联
- 能否把所有的metrics联合起来一起考虑?

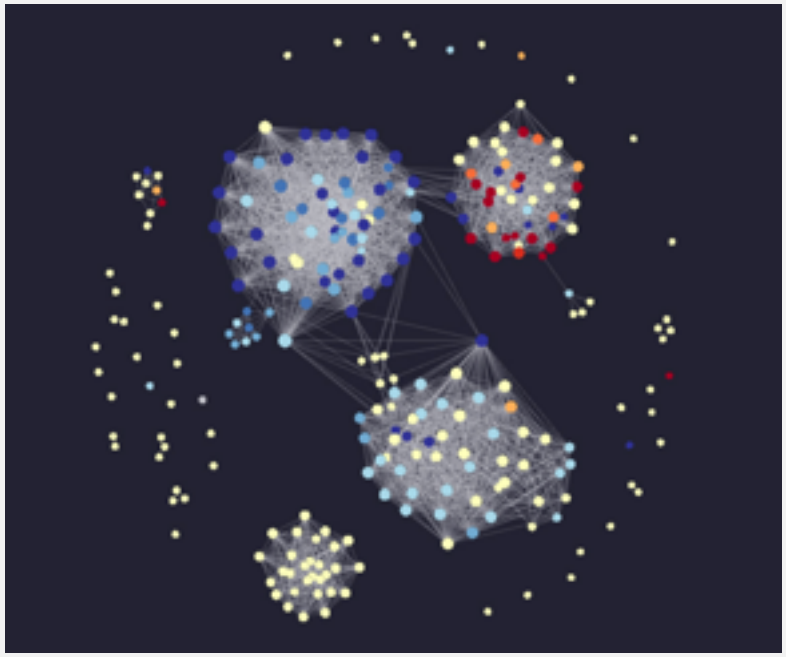

智能运维中的异常检测和根源分析

- 性能监控里的时间序列
- 传统方法
- AI + 时间序列
  - 异常检测
  - 根源分析
- 总结

Moving Average Based

- 对历史值赋予不同权重
- Autoregressive Integrated Moving Average (ARIMA)
- 几乎所有的time series包里都有实现
- 缺点:
  - 需手动设置参数
  - assumption较为简单

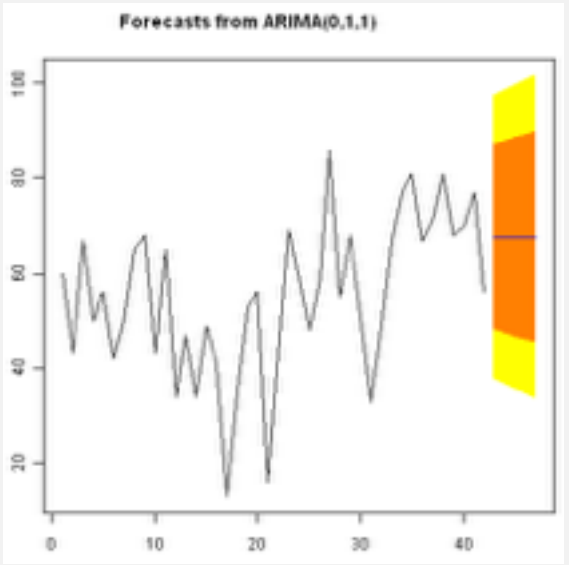

Exponential Smoothing Based

- Double exponential (Holt-Linear):
  - 能追踪level和trend
- Triple exponential:
  - 能追踪level和trend
  - 还能追踪seasonality
- 缺点:
  - 需手动设置参数

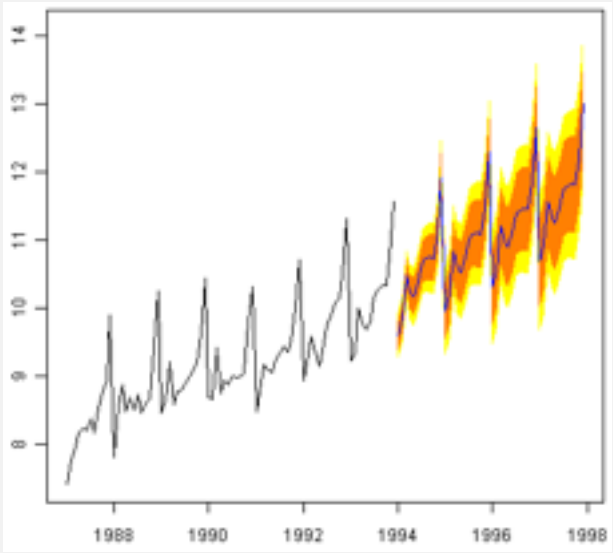

分解（decomposition） Based

- DFT (Discrete Fourier Transform) / 傅立叶分解
  - 对周期性数据效果较好
  - 对spike model能力较弱

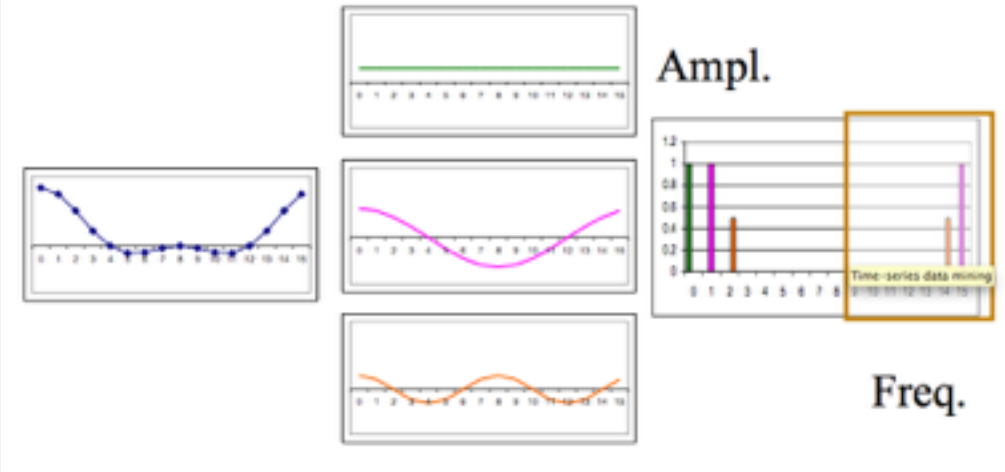

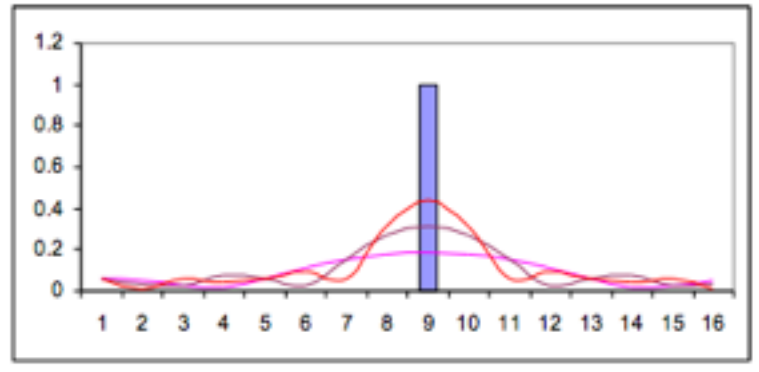

分解（decomposition） Based

- DWT (Discrete Wavelet Transform) / 小波分解
  - 速度快，压缩能力强
  - 对spike等异常非常有效
- 在分解后的模块（比如小波分解后的components）上再进行auto regression

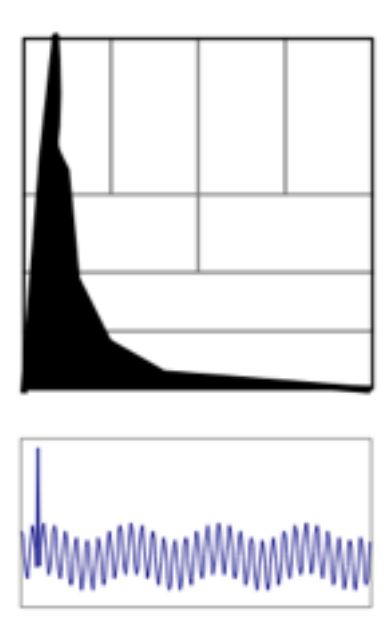

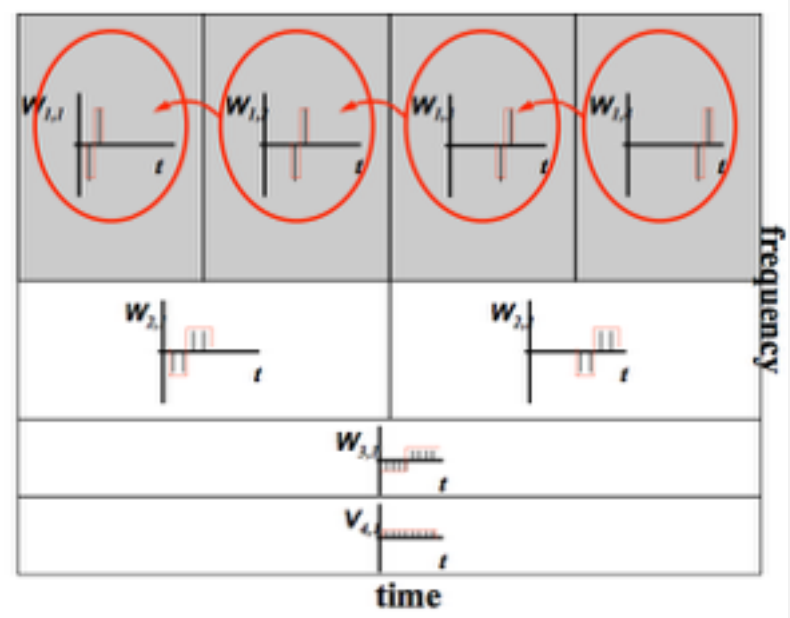

深度学习（Deep Learning） Based

- Feedforward Neural Network
- Recurrent Neural Network (e.g., LSTM)
- Convolutional Neural Network

LSTM 例子:

- 1 input
- a hidden layer with 4 LSTM neurons
- an output layer

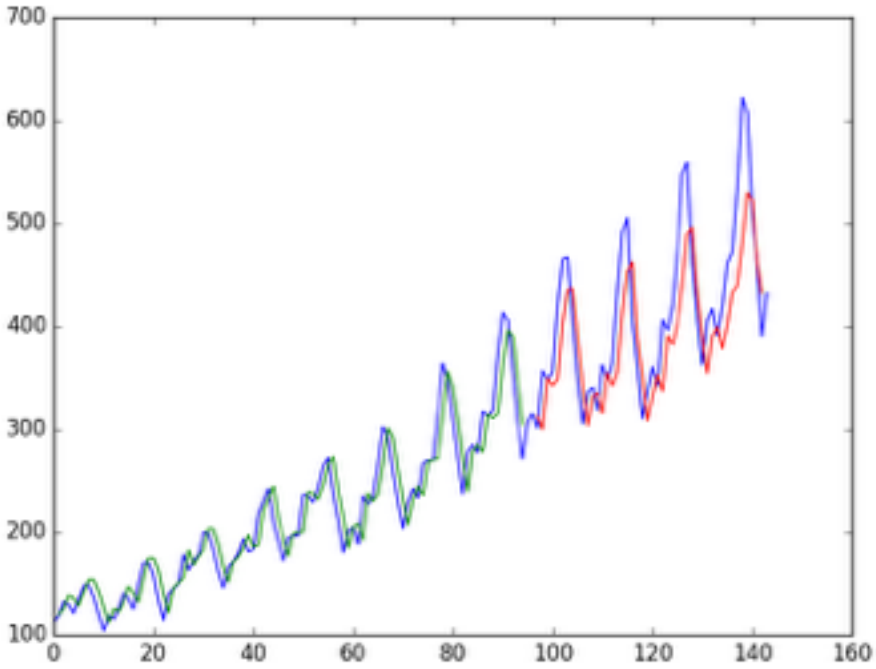

矩阵（Matrix） Based

用sliding window构建矩阵，假设矩阵为low rank

分解矩阵后重建，差异大的地方为异常

- Principle Component Analysis
- SVD
- Robust PCA
- Auto-Encoder Neural Network
- Convolutional Auto-Encoder Neural Network

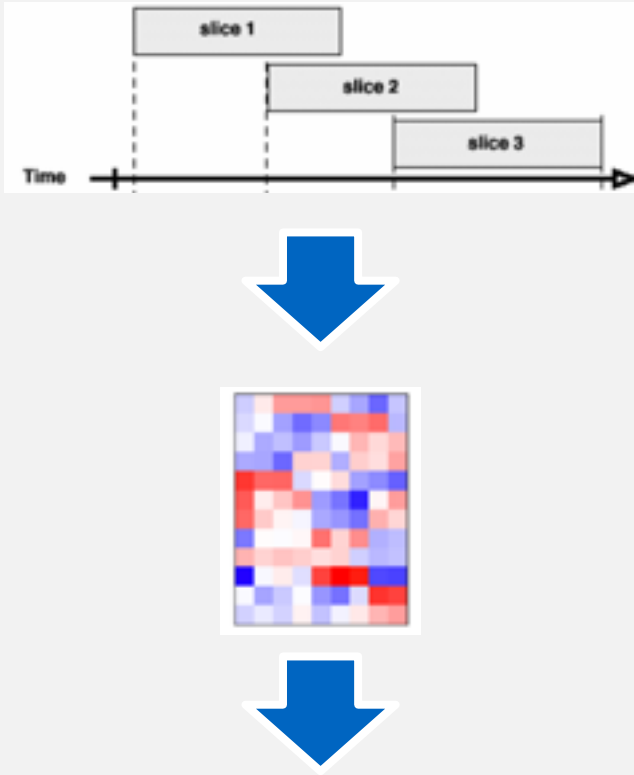

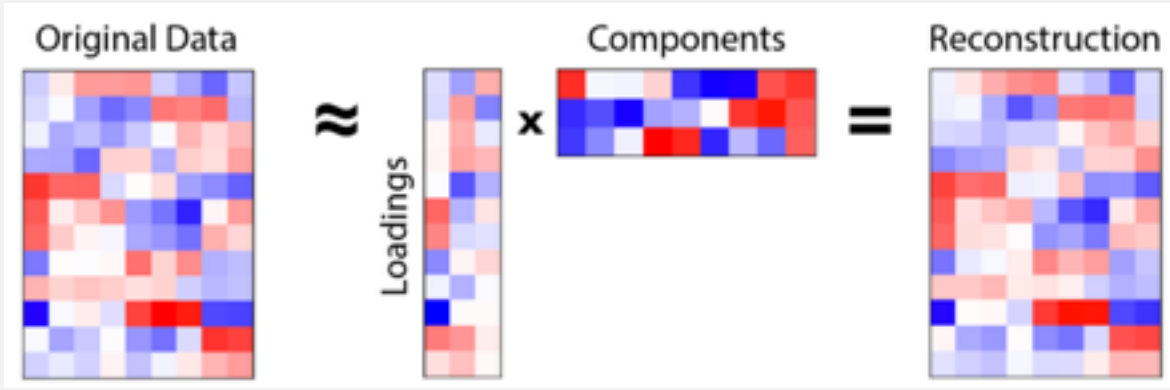

业界应用

- Twitter: **Seasonal Hybrid ESD (S-H-ESD)**

https://blog.twitter.com/2015/introducing-practical-and-robust-anomaly-detection-in-a-time-series

- Netflix: **Robust PCA**

http://techblog.netflix.com/2015/02/rad-outlier-detection-on-big-data.html

- Numenta: **neural network**

http://numenta.com/press/2015/11/10/numenta-anomaly-benchmark-nab-evaluates-anomaly-detection-techniques/

- Anodot: **online machine learning algorithm**

http://www.anodot.com/

- Linkedin: **exponential smoothing**

https://github.com/linkedin/luminol

- Uber: **multivariate non-linear model**

https://eng.uber.com/argos/

Credit: Yi Hong @ AppDynamics

这么多方法，

到底选哪个呢?

自动模型选取：Ensemble Learning

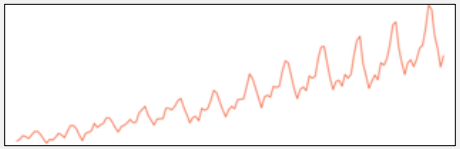

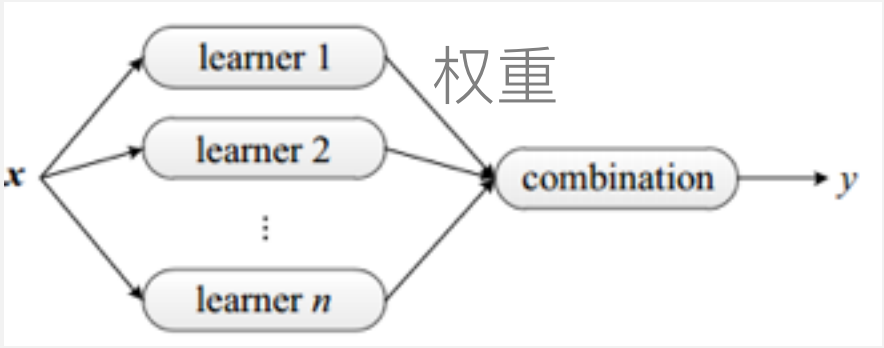

异常 / 非异常

- 多个模型同时预测
- 根据历史数据调整不同模型权重
- 无需人工选取 / 调整
- 自动得到一个共同决策

异常检测

- 产生警报


Anomaly Detection
40
30
20
10
0
41,902
41,903
41,904
41,905
41,906
41,907
41,908
41,909
41,910
41,911


!
ALERT


WHAT'S YOUR
NEXT STEP?

智能运维中的异常检测和根源分析

- 性能监控里的时间序列
- 传统方法
- AI + 时间序列
    - 异常检测
    - **根源分析**
- 总结

所有metrics集合

异常的metrics　　正常的metrics

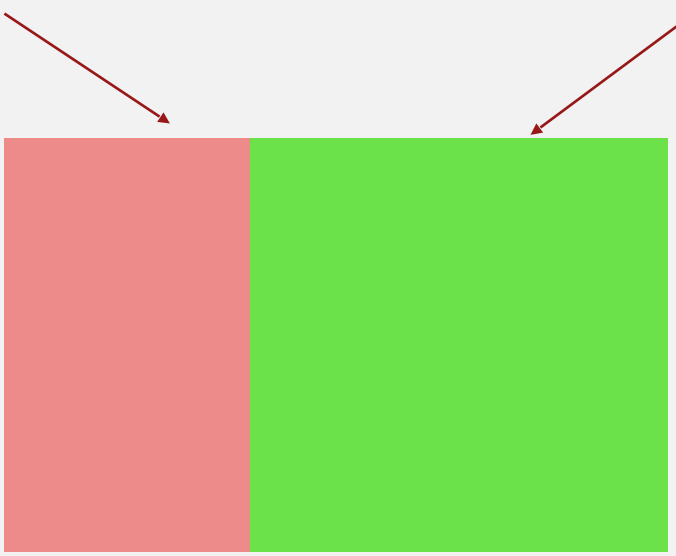

基于相关性的RCA

- 从异常的metrics里找到最相关的metric
- 算法：Pearson correlation
- 生产环境例子：

异常的metrics

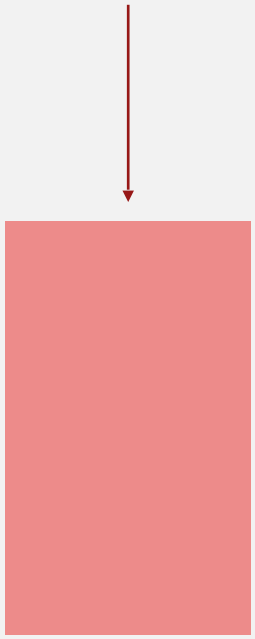

警报metric：
Overall Response Time

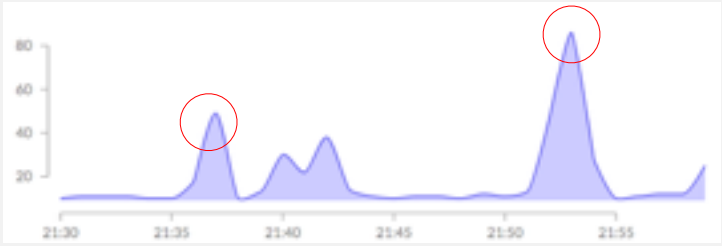

最相关的metric（相关度0.9876）：
es_data-02|QueryPhase|Slow Calls

基于决策树的RCA

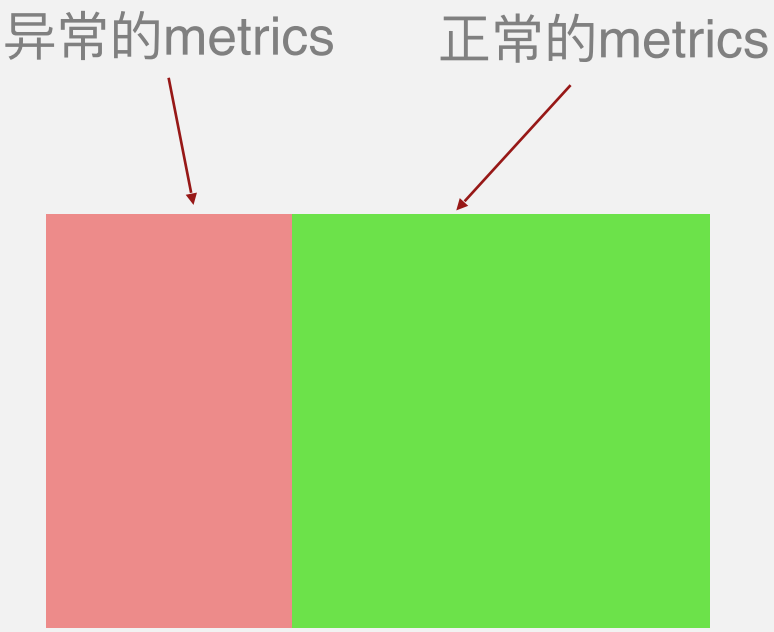

- 将异常 / 正常metrics分成labeled data
- 算法：decision tree（或其他classifier）
- 总结出异常metrics的规律
- 生产环境例子：

  生成的Rules

  - EsIndexCluster=prd28-7 && node=indexer_insert_001_prd28
  - Application=prd28-analytics && EsIndexCluster=prd28-2 && transactionName=InsertEventIndexingStage
  - EsIndexCluster=prd28-1 && tier=indexer_prd28

  RCA：

  - ES Cluster = prd28, stage = insert, tier = indexer

AI + 性能监控

听云 TINGYUN | IT大咖说 知识分享平台

异常检测

被动式
(reactive)

根源分析

实时
(real time)

预测

前瞻性
(proactive)

智能运维中的异常检测和根源分析 - 总结

- 性能监控里的时间序列
- 传统方法
  - 固定阈值
  - 基于平均值的动态阈值
- 为什么传统方法不work?
  - 忽视周期性
  - 忽视趋势
  - 数据不完美
  - 数据孤岛

- AI + 时间序列
  - 异常检测
    - Moving average based
    - Exponential Smoothing Based
    - 分解（decomposition） Based
    - 深度学习（Deep Learning） Based
    - 矩阵（Matrix） Based
    - 自动模型选取：Ensemble Learning
  - 根源分析
    - 基于相关性的RCA
    - 基于决策树的RCA
  - 预测

THANK YOU