



原来机器学习还可以这样玩！

8月24日
北京



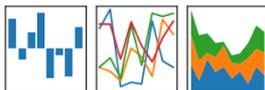
你心目中的机器学习是什么样子？



你可能正在用.....

pandas

$$y_{it} = \beta' x_{it} + \mu_i + \epsilon_{it}$$



- 1 Pandas 是一个开放源码、BSD许可的库，为Python编程语言提供高性能、易于使用的数据结构和数据分析工具。
- 2 Scikit-learn是专门面向机器学习的Python开源框架，它实现了各种成熟的算法，并且易于安装与使用。
- 3 Jupyter Notebook 是一个 Web 应用程序，便于创建和共享文学化程序文档，支持实时代码、数学方程、可视化和 Markdown，其用途包括数据清理和转换、数值模拟、统计建模、机器学习等等。

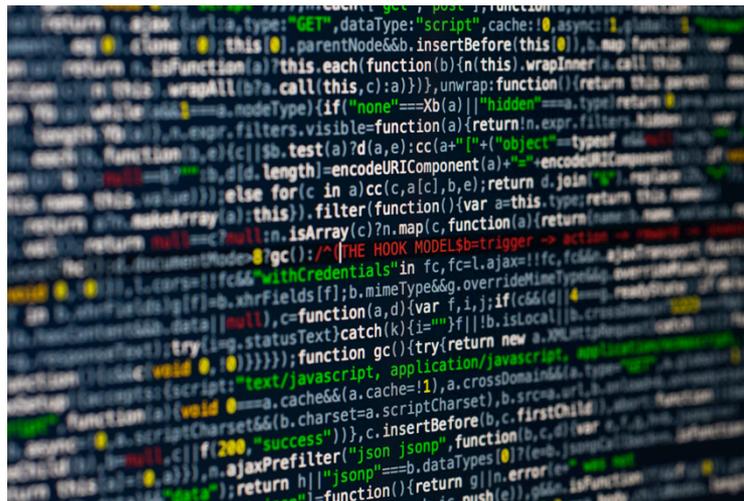
更早的时候你可能在用.....



过去发生.....

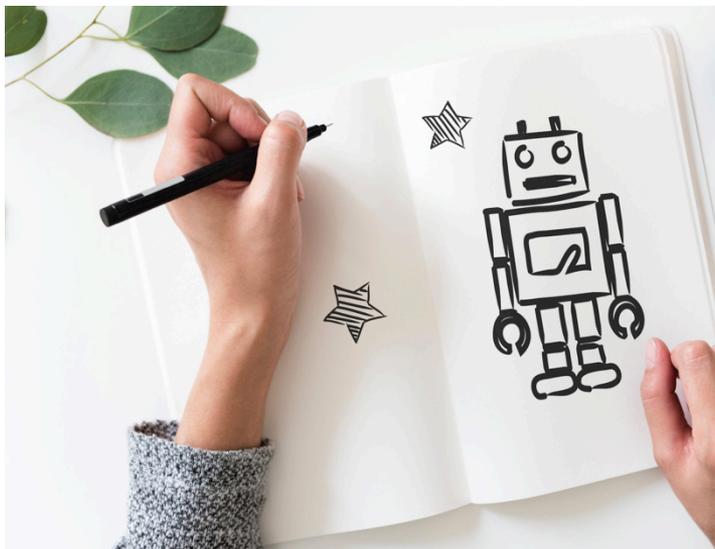


数据



计算能力

正在发生.....



自动



从洞察到行动

下一波颠覆性技术 - 增强型分析

Gartner确认2019年十大数据与分析技术趋势之一增强性分析：增强型分析利用机器学习（ML）与人工智能改变分析内容的开发、消费与共享方式。

- 到2020年，增强型分析将成为分析与商业智能、数据科学与机器学习平台以及嵌入式分析新购的主要驱动力；
- 增强型分析能够鉴别隐藏的模式，同时消除人为的偏见；增强型分析和自动洞察将最终嵌入到企业的应用之中；

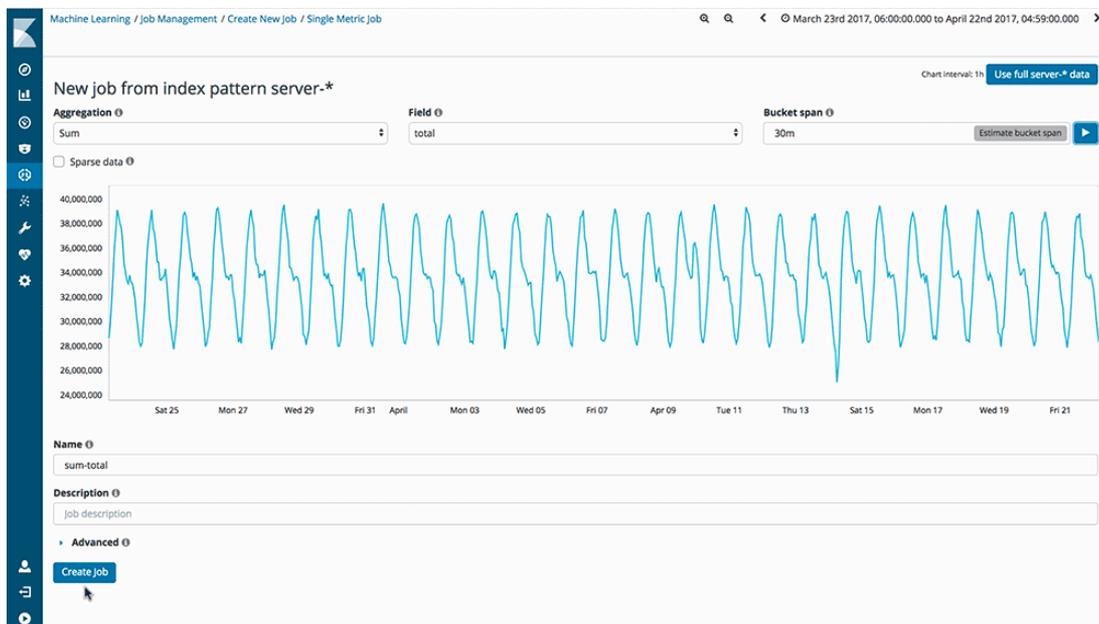
“By 2020, more than 40% of data science tasks will be ***automated***”

Elastic 机器学习

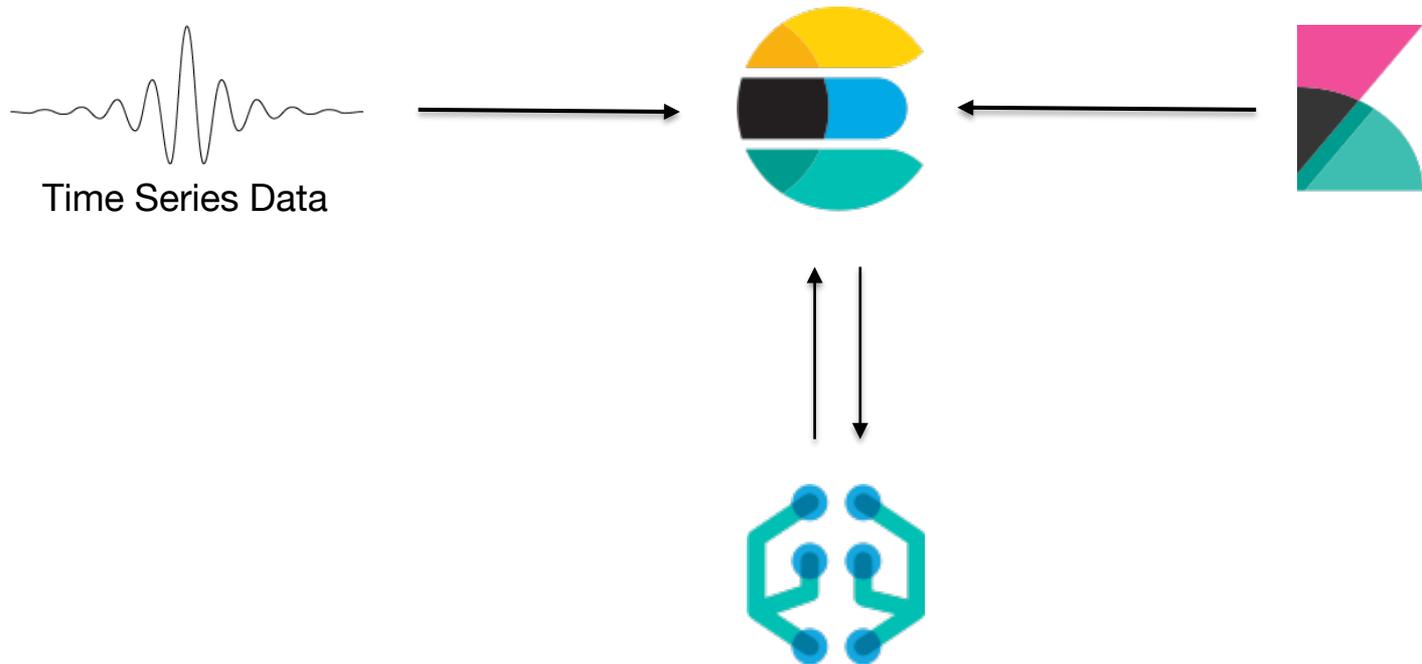
- 互动的
- 自动的机器学习任务
- 异常侦测
- 行为分析
- 预测

而不是:

- 通用的机器学习
- 魔法

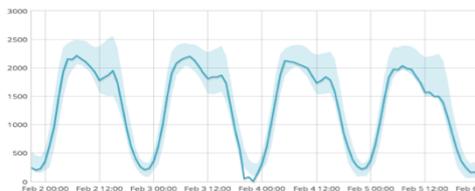


Elastic 机器学习 workflow

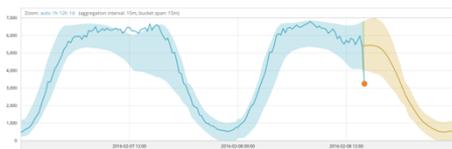


Elastic 机器学习 workflow

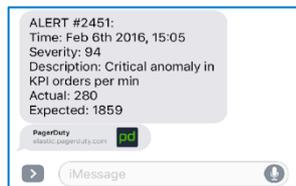
学习



预测



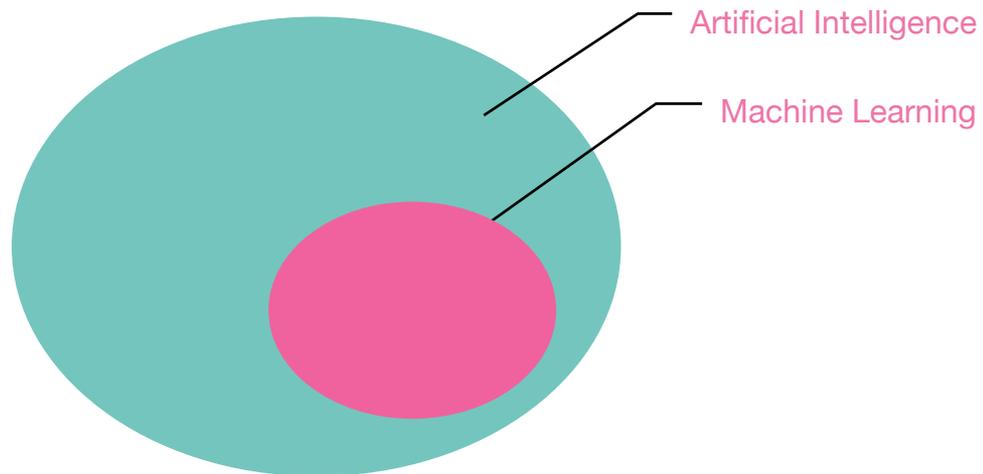
操作



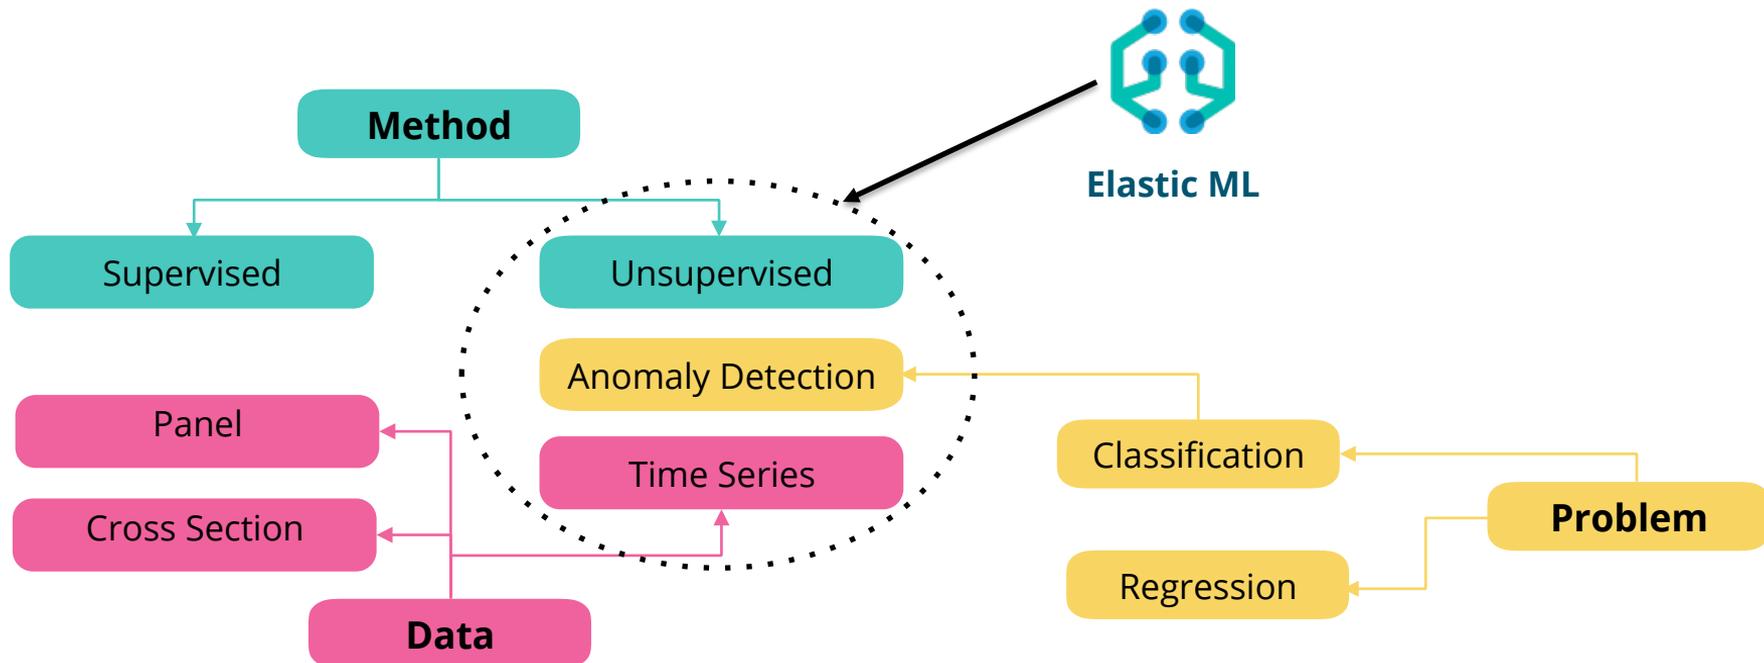
- 从数据中学习行为模式
- 自动生成模型，判断当前和未来的行为
- 考虑周期和季节性因素
- 对异常进行打分，按照严重程度告警
- 预测未来的行为
- 对历史和实时数据进行操作型实时分析
- 易于使用，提供可视化界面
- 提供Restful API

Elastic 机器学习能力范围

- 从数据中学
- 使用统计学和概率
- 无需编写程序



Elastic机器学习能力范围



Elastic 机器学习原理

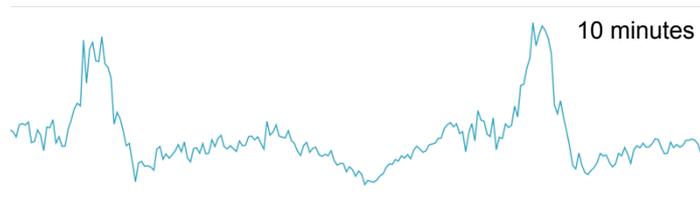
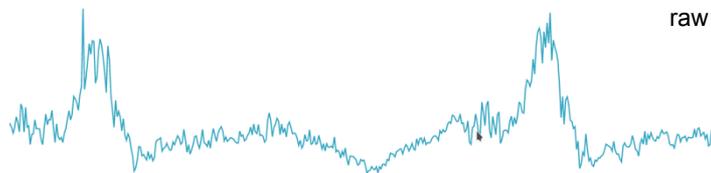
黑盒子里面发生了什么？

- 了解基本的概念
- 什么是模型？有多少模型？
- 从检测到推测



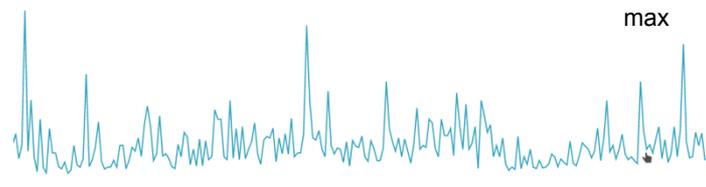
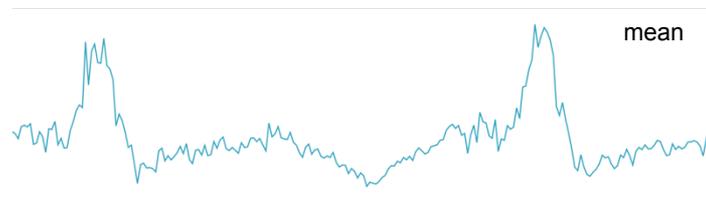
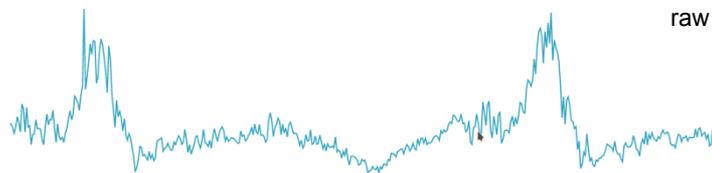
Elastic 机器学习原理

数据按照数据桶来进行聚合



Elastic 机器学习原理

函数定义了数据如何转换



Elastic 机器学习原理

使用到的算法

- 时序数据分解算法
- 相关分析
- 贝叶斯分布
- 聚类
- 分类

贝叶斯

过去发生的概率，满足某种概率分布，例如泊松分布

后验概率 = 标准相似度 * 先验概率

从统计学的角度，
来找到相似度

7.3之后，数据帧来了..

更强的数据转换能力

更强的OLAP特性

机器学习 / 数据帧 / 创建数据帧

新建数据帧 (公测版)

1 定义透视

索引模式 kibana_sample_data_ecommerce

查询

manufacturer.keyword

添加分组依据字段.....

聚合

- products.quantity.sum
- products.quantity.max
- products.base_price.max

添加聚合.....

Advanced editor

源索引 kibana_sample_data_ecommerce 显示 5 个字段, 共 28 个

category ↑	currency	customer_first_name	customer_full_name	customer_gender
Men's Accessories	EUR	Robert	Robert Hodges	MALE
Men's Accessories	EUR	Ahmed Al	Ahmed Al Garza	MALE
Men's Accessories	EUR	Robert	Robert Shaw	MALE
Men's Accessories	EUR	Ahmed Al	Ahmed Al Morrison	MALE
Men's Accessories, Men's Clothing	EUR	Kamal	Kamal James	MALE

每页行数: 5

数据帧透视预览

manufacturer.keyword ↑	products.base_price.max	products.quantity.sum
Angeldale	210	1220
Champion Arts	185	556
Crystal Lighting	110	50
Elitelligence	1	3076

每页行数: 5

Elastic机器学习的五大分析



基于自身历史行为的模型分析，通俗的说“自己和自己比”来甄别异常

基于种群内行为的模型分析，通俗的说“自己和种群中的其他个体比”来甄别异常

从海量数据中找出出现频率非常低的数据，例如从大量的错误信息中找出罕见的错误代码

透过对字符文本类的数据的聚类分组分析，无需理解字符文本含义，而定位到异常的信息

7.3新特性，以距离或者密度为基准的分类分析

为什么选择Elastic的机器学习

- IT系统过于复杂难以人工分析
- 人的限制：经验和人力
- 自动化过程提升效率
- 可以分析更多的数据
- 动态告警，而不是基于规则和阈值的静态告警
- 主导探测异常行为
- 找到相关的可能的原因



IT运维：日志和监控

告警
归因分析



安全分析

威胁狩猎



商业分析

趋势分析 KPI分析

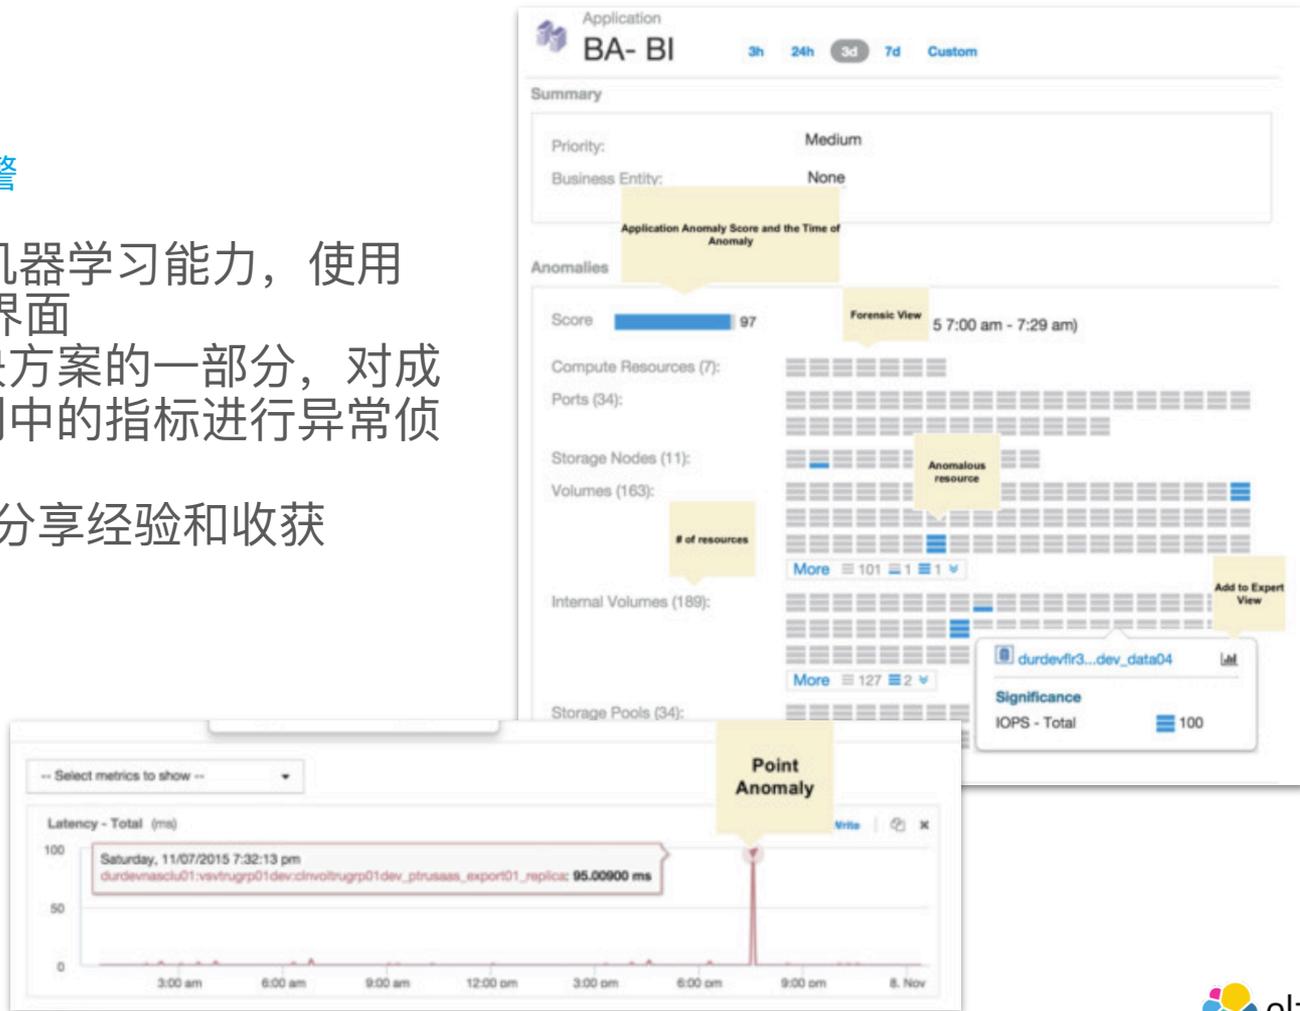




NetApp™

基于大量数据的运维预警

- OEM使用Elastic机器学习能力，使用NetApp的定制化界面
- 作为存储管理解决方案的一部分，对成百上千的存储阵列中的指标进行异常侦测
- Elastic{ON} 2018分享经验和收获





商业分析

- 跟踪客户在试用期间的转换率
- 发现的严重异常的事件发到 Slack 的交流组供进一步分析
- Elastic{ON} 2018 分享经验和收获





Let's Demo



机器学习“玩”起来

可用的公开数据：

1. <https://github.com/elastic/examples/tree/master/Machine%20Learning>
2. [Machine Learning with the Elastic Stack](#) 试验数据
3. <https://data.cityofnewyork.us/Transportation/2018-Yellow-Taxi-Trip-Data/t29m-gskq>



感谢有你，一路同行！

Elastic社区活动的机器学习的演讲
2019年8月





elastic
中文社区

专业、垂直、纯粹的 Elastic 开源技术交流社区

<https://elasticsearch.cn/>