



个推
GETUI

《浅谈大数据与AI结合的一些思路和应用》

令狐冲

2020.12.26

- 一、研究背景
- 二、异常值检测方法
- 三、基于统计的异常值检测
- 四、基于模型的异常值检测
- 五、流式异常检测实战应用



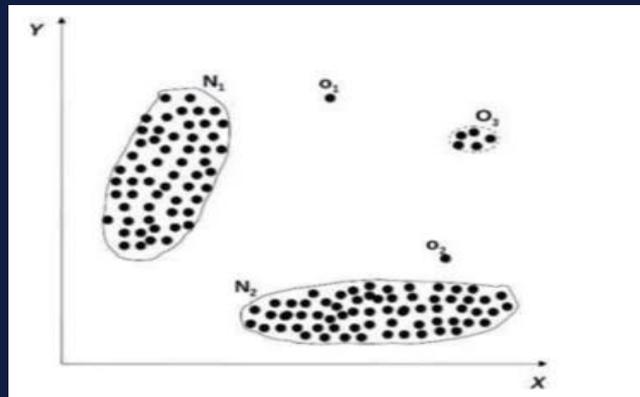
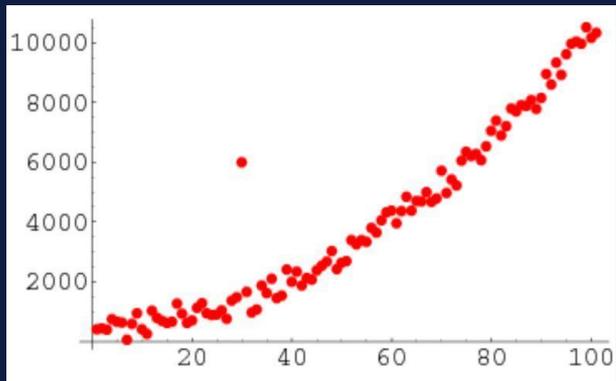
| 研究背景 |

研究背景

异常值（业务描述）



离群点（数学描述）



应用场景：

- 1、流量监控
- 2、金融欺诈
- 3、系统故障检测

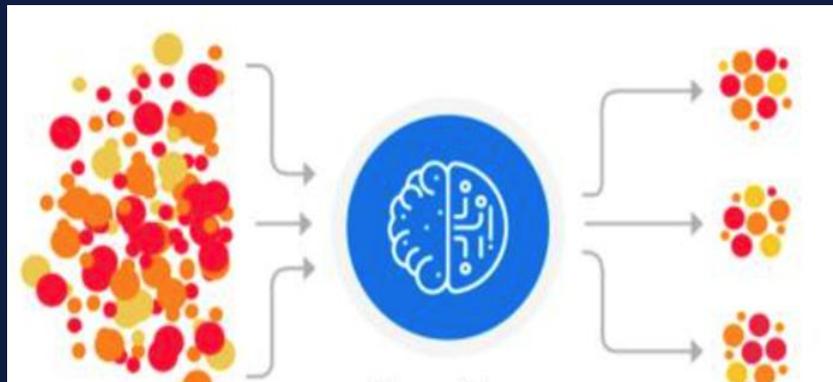


| 异常值检测方法 |

异常值检测方法



基于统计的方法

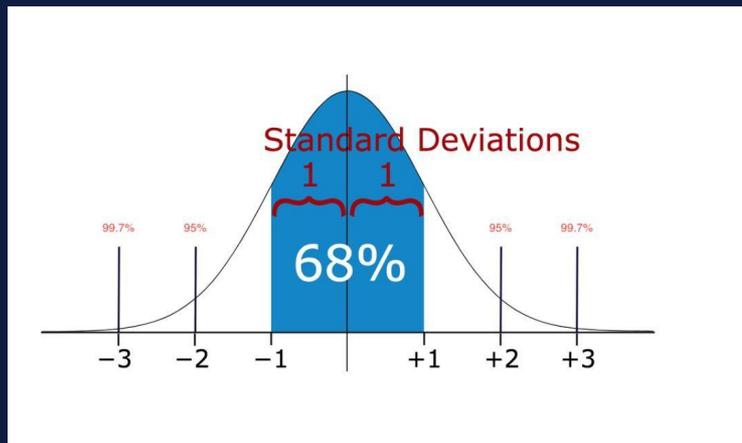


基于模型的方法

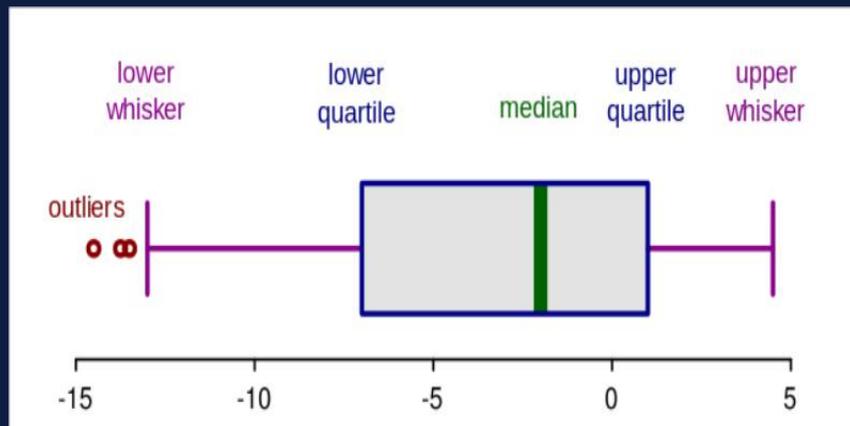


| 基于统计的异常值检测 |

基于统计的异常值检测

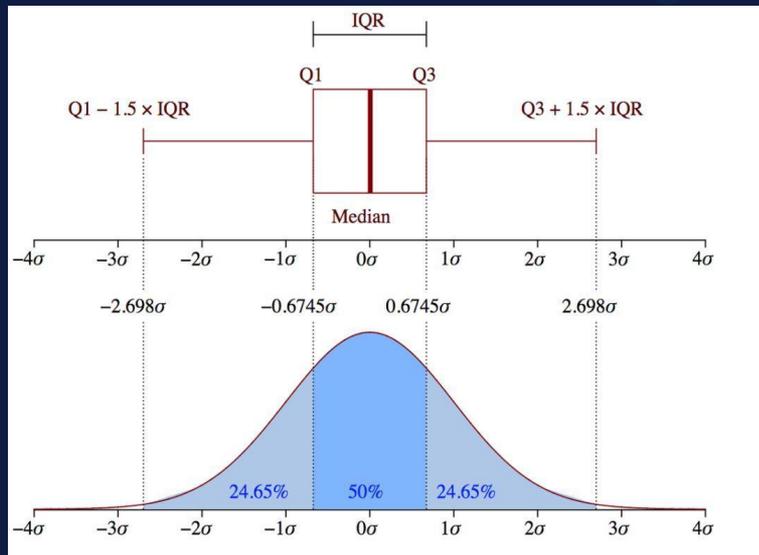


3 σ 法则



箱体图

基于统计的异常值检测



优点:

- 1) 简单方便
- 2) 坚实的统计学基础

缺点:

- 1) 需要较多的样本数据
- 2) 高维数据较难处理



| 基于模型的异常值检测 |

基于模型的异常值检测

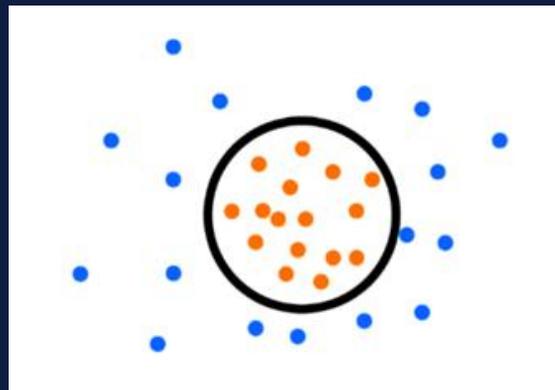
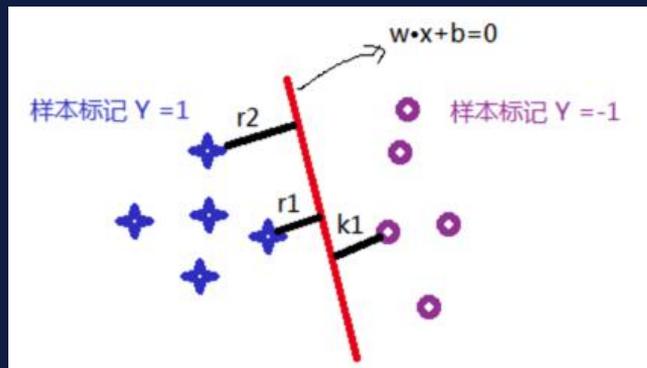
数学转化：分类问题，样本不均衡

一、有监督模型：

k-最近邻：KNN

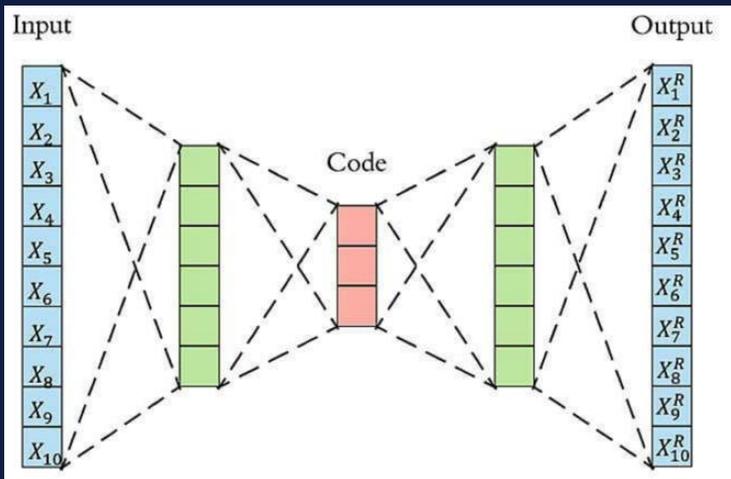
支持向量机：SVM (OneclassSVM)

神经网络：自编码器 (VAE)

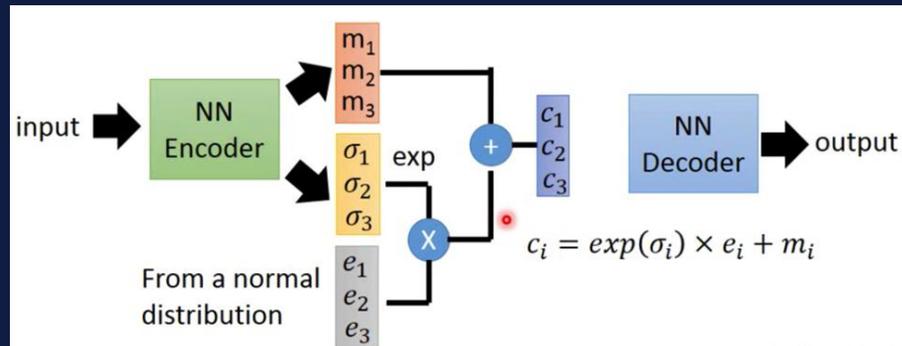


基于模型的异常值检测

神经网络方法



自编码器 (AE)



变分自编码器 (VAE)

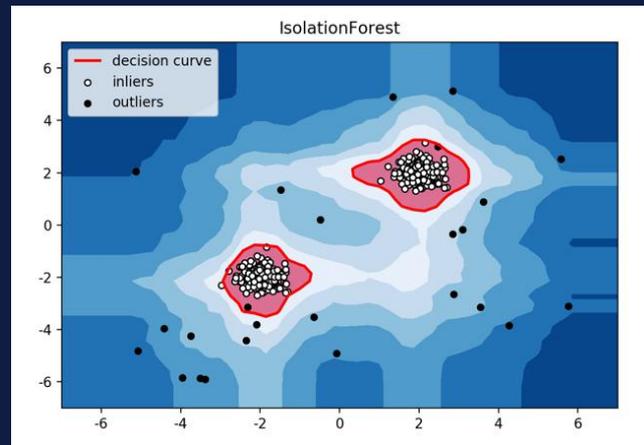
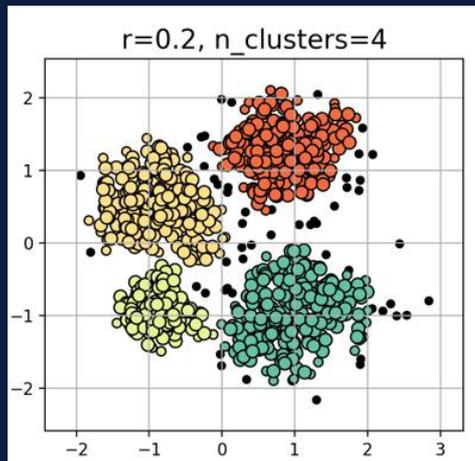
基于模型的异常值检测

二、无监督模型：

密度聚类：DBSCAN

孤立森林：IsolationForest (IF)

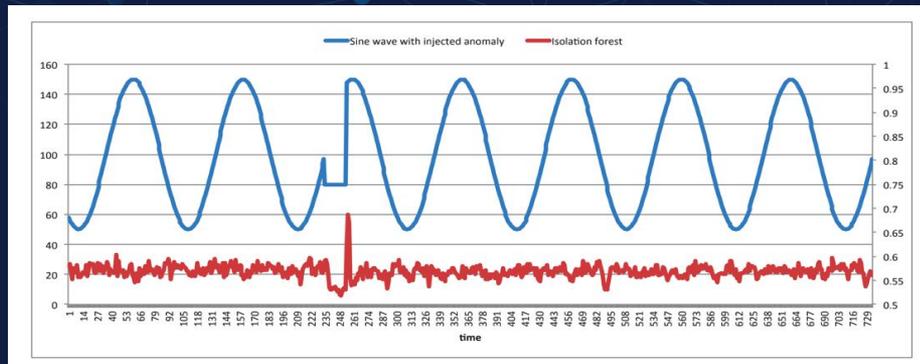
随机剪切森林：RadomCutForest (RCF)



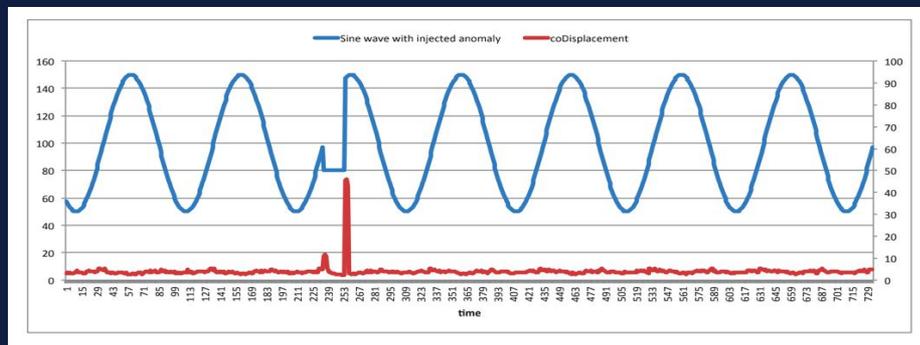
基于模型的异常值检测

$$c(n) = 2H(n-1) - \frac{2(n-1)}{n}$$

$$s(x, n) = 2^{-\frac{E(h(x))}{c(n)}}$$



IF算法



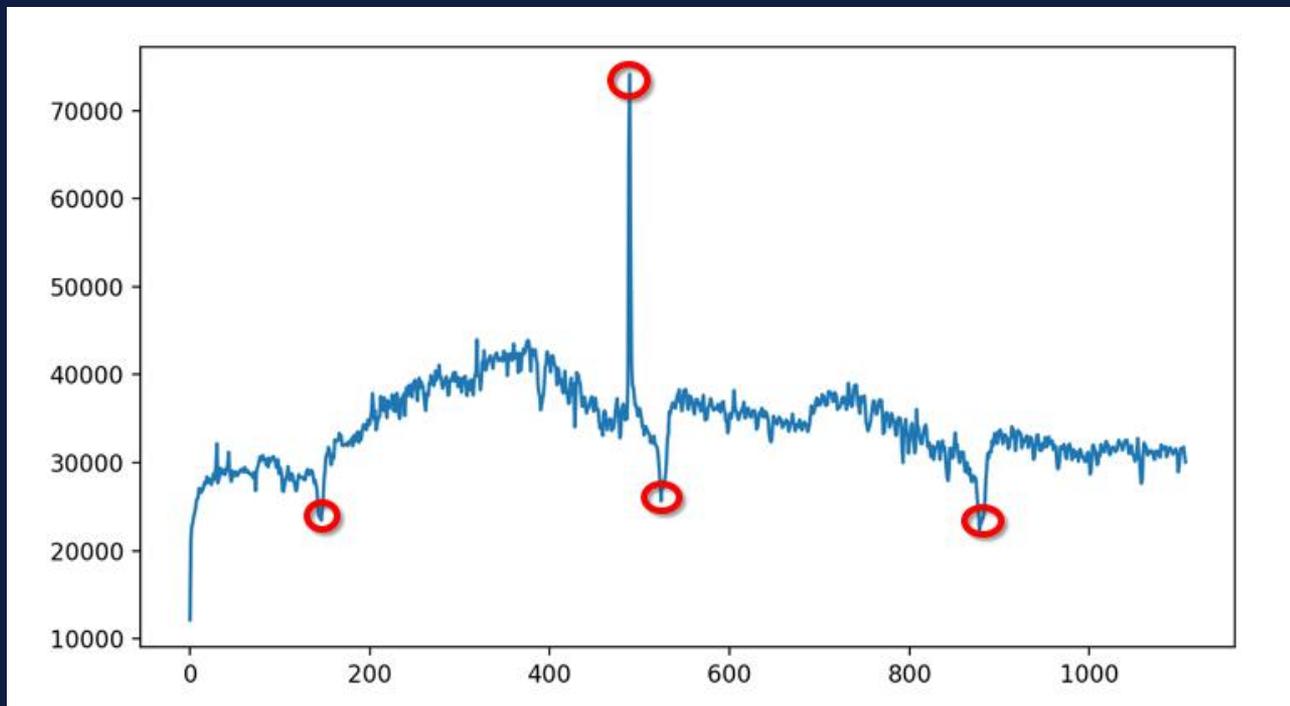
RCF算法



| 异常值检测实战应用 |

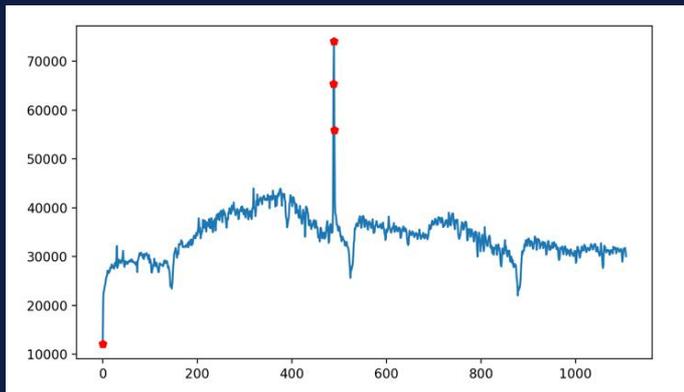
异常值检测实战应用

某APP从2016.08.16至2019.09.21的日活如下图所示：

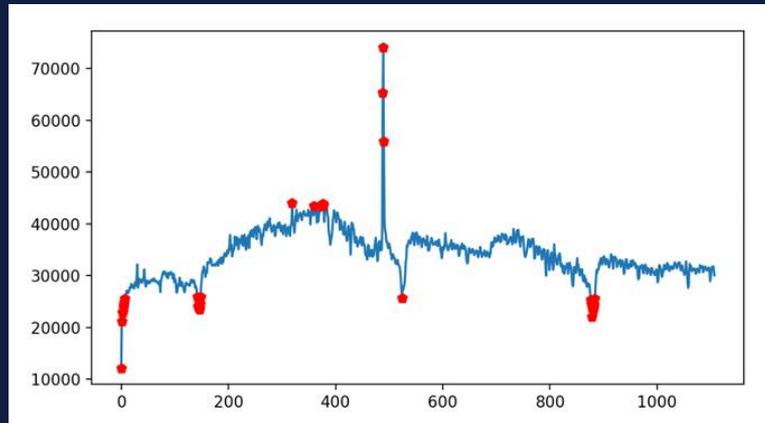


异常值检测实战应用

当成静止数据时的异常值检测：



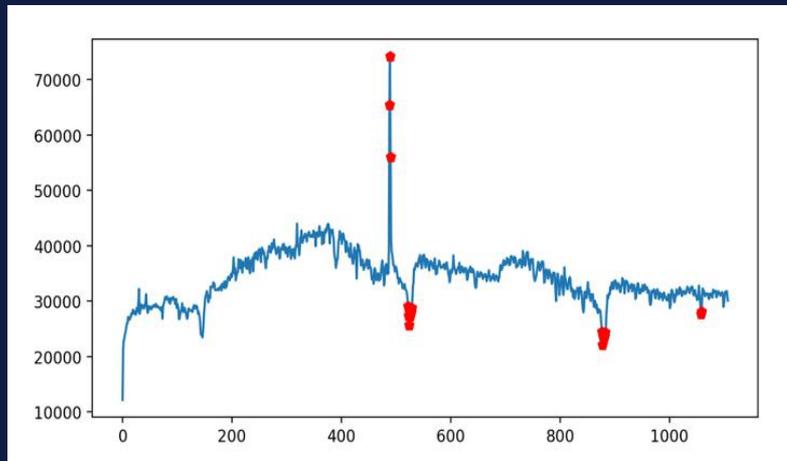
基于统计的 3σ 法则



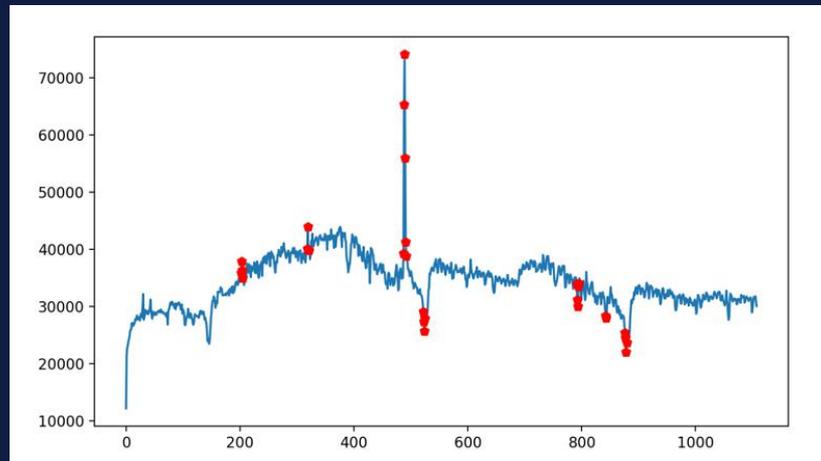
孤立森林算法

异常值检测实战应用

当成流式数据时异常值检测：

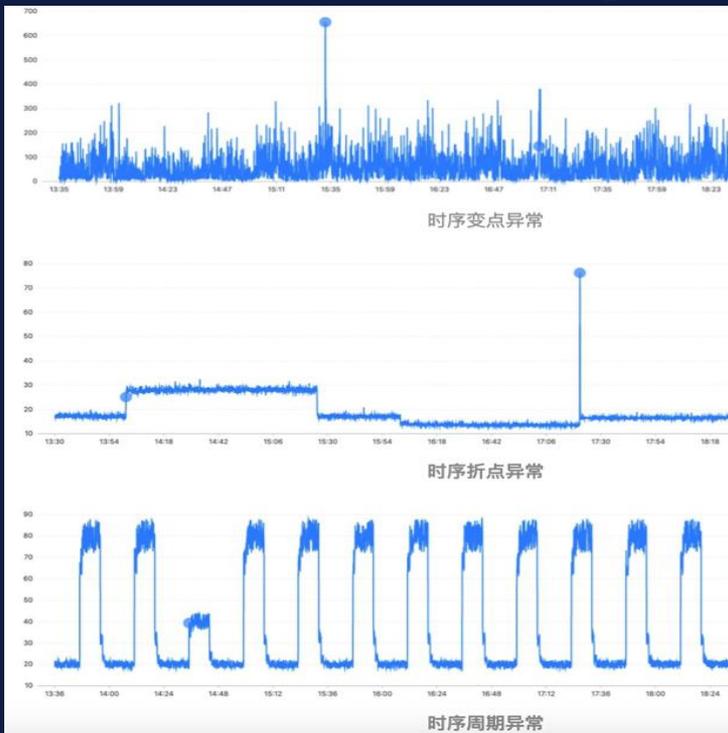


基于统计的滑动 3σ 法则



RCF算法

异常值检测实战应用



| | 变点异常 | 折点异常 | 周期异常 |
|------------|------|------|------|
| 流式统计算法异常检测 | 强 | 中 | 弱 |
| 流式树算法异常检测 | 中 | 强 | 中 |
| 流式图算法异常检测 | 强 | 中 | 强 |

结合实际业务，合适才是最好

公司简介

个推成立于2010年，是专业的数据智能服务商，致力于用数据让产业更智能。公司以海量的数据积累和创新的技术理念，构建了移动开发、用户增长、品牌营销、公共管理和智能风控等多领域的数据智能服务生态。



个推十周年感恩特惠月

活动截止至：2020年12月31日

爆款开发者工具

消息推送VIP

免费用一年

用户画像

免费用一年

应用统计

免费用一年

热门大数据产品

人群洞察工具

免费试用

人口数盘

免费试用



立即扫码领取福利



个推公众号



个推技术学院公众号

数据让产业更智能

EMPOWER WITH DATA

