

PASER: 加性多维 KPI 异常根因定位模型*

靖宇涵^{1,2}, 何波¹, 张凌昕¹, 李天星¹, 王敬宇^{1,2}, 刘聪³



¹(网络与交换技术国家重点实验室(北京邮电大学), 北京 100876)

²(杭州东信北邮信息技术有限公司, 北京 100191)

³(中国移动通信有限公司研究院, 北京 100053)

通信作者: 王敬宇, E-mail: wangjingyu@bupt.edu.cn

摘要: 利用多维属性关键性能指标(key performance indicators, KPI)的可加性特征, 能够实现对大型互联网服务故障的根因定位. 由一项或多项异常根因导致的 KPI 数据变化, 会导致大量相关 KPI 数据值的变化. 提出一种基于异常相似性评估和影响力因子的剪枝搜索异常定位模型(pruning search model based on anomaly similarity and effectiveness factor for root cause location, PASER), 该模型以多维 KPI 异常传播模型为基础, 提出了衡量候选集成为根因可能性的异常潜在分数评估方案; 基于影响力的逐层剪枝搜索算法, 将异常根因的定位时间降低到了平均约 5.3 s. 此外, 针对异常根因定位中所使用的时间序列预测算法的准确性和时效性也进行了对比实验, PASER 模型在所使用的数据集上的定位表现达到了 0.99 的 *F*-score.

关键词: 智能运维; 多维 KPI; 根因定位; 剪枝搜索

中图法分类号: TP309

中文引用格式: 靖宇涵, 何波, 张凌昕, 李天星, 王敬宇, 刘聪. PASER: 加性多维 KPI 异常根因定位模型. 软件学报, 2022, 33(2): 738-750. <http://www.jos.org.cn/1000-9825/6212.htm>

英文引用格式: Jing YH, He B, Zhang LX, Li TX, Wang JY, Liu C. PASER: Root Cause Location Model for Additive Multidimensional KPIs. Ruan Jian Xue Bao/Journal of Software, 2022, 33(2): 738-750 (in Chinese). <http://www.jos.org.cn/1000-9825/6212.htm>

PASER: Root Cause Location Model for Additive Multidimensional KPIs

JING Yu-Han^{1,2}, HE Bo¹, ZHANG Ling-Xin¹, LI Tian-Xing¹, WANG Jing-Yu^{1,2}, LIU Cong³

¹(State Key Laboratory of Networking and Switching Technology (Beijing University of Posts and Telecommunications), Beijing 100876, China)

²(EBUPT Information Technology Co., Ltd., Beijing 100191, China)

³(China Mobile Research Institute, Beijing 100053, China)

Abstract: Additivity of multidimensional KPIs (key performance indicators) was used to achieve root cause location for large-scale Internet services. The anomaly caused by one or more root causes usually results in the change of a large number of relevant KPIs. A pruning search model based on anomaly similarity and effectiveness factor for root cause location (PASER) was proposed, which indicated the probability of candidate set becoming root cause using potential score based on the anomaly propagation model of multidimensional KPI. The pruning search algorithm used in PASER also managed to reduce the location time to about 5.3 seconds on average. In addition, the selection of time series prediction algorithm was also discussed. PASER had finally achieved a performance of 0.99 *F*-score on the experimental dataset.

Key words: AIOps; multidimensional KPIs; root cause location; pruning search

* 基金项目: 国家自然科学基金(62071067); 教育部-中国移动科研基金(MCM20200202); 北京邮电大学-中国移动研究院联合创新中心

收稿时间: 2020-08-01; 修改时间: 2020-10-05; 采用时间: 2020-11-24; jos 在线出版时间: 2021-01-15

智能运维(artificial intelligence for IT operations, AIOps)将机器学习的方法应用到 IT 系统运维领域, 以提升运维工作的自动化和智能化程度, 高效率地进行系统异常的处理. 关键性能指标(key performance indicators, KPI)是衡量网络服务工作状态的重要指标, 如页面浏览量、网络流量等. 此前有很多针对 KPI 变化检测异常的相关研究, 如文献[1-3]. 在实际运维场景中, 由一项或者多项异常根因导致的 KPI 数据变化, 会导致大量相关 KPI 数据值的变化. 在异常发生时, 快速、准确地对异常发生的根本原因进行定位, 是降低异常检测的时间复杂度、提升运维反馈效率的重要课题.

对于复杂环境中的异常根因定位问题, 此前进行过许多不同类型的研究. Pinpoint^[4]使用聚类分析诊断大型动态 Internet 服务的根本原因. SCORE^[5]、Shrink^[6]和文献[7]使用共享风险链路组模型对第 1 层骨干网上的 IP 网络故障进行定位, 并尝试定位能够解释故障的最小风险组合. Sherlock^[8]主要使用包跟踪、路由跟踪和网络配置文件跟踪等方法, 根据大型企业网络元素之间的多层依赖关系对性能问题进行定位. Argus^[9]使用层级的数据结构对具有相同属性的用户组进行聚集和性能度量, 尝试定位存在性能故障的用户. ABSENCE^[10]采用用户使用数据的树形结构来检测移动网络中的故障. FOCUS^[11]则是一种确定多维日志中长期瓶颈的方法. Adtributor^[12]关注广告系统中的收入调试问题, 它对多维数据上的异常数据进行了分析和定位, 但只处理一维数据的根因集合. iDice^[13]对大型软件系统中的新异常报告进行根因定位, 并对候选根因组合的属性进行搜索, 但 iDice 主要处理根因集合中元素数量较少的情况.

具有多个维度属性(如运营商、省份和数据中心)的加性多维 KPI 数据(如页面浏览量、收入和错误统计)是互联网公司监控服务性能的常用和重要指标. 当整体 KPI 发生异常时, 如何定位异常发生的根本原因是一个非常重要的课题. 然而, 这项任务非常具有挑战性, 主要由于以下两种原因: 一方面是极大的数量, 多维 KPI 数据的总量通常非常大; 另一方面, 不同的 KPI 维度组合是相互依存的, 因此, KPI 在某个根因组合上发生的异常, 将会导致其他维度上的 KPI 数据发生变化. 针对加性多维 KPI 之间的关联, HotSpot^[14]提出了使用蒙特卡洛树搜索的根因定位方案, 并对异常的传播方式进行了分析.

为了准确、快速定位到加性多维 KPI 异常的根因维度组合, 本文提出了一种基于异常相似性评估和影响力因子的剪枝搜索异常定位模型(pruning search model based on anomaly similarity and effectiveness factor for root cause location, PASER). PASER 选择恰当的预测算法来保障对大量异构的 KPI 曲线进行预测的时效性和准确性. 同时还设计了全局可对比的根因潜在分数公式以及基于影响力判断的剪枝搜索算法, 为剪枝搜索提供有效的评判标准. 此外, 模型针对搜索结果中的根因偏移现象提出了可解释的修正方案, 有效提高了根因定位的准确性.

本文的主要创新和贡献包括:

- 1) 优化的潜在分数公式主要关注加性多维 KPI 数据中异常等比例传播的特点, 减弱了极大 KPI 值对根因定位的不利影响;
- 2) 依据异常发生时多维 KPI 值的变化特征, 提出了影响力的概念, 并在此基础上提出了高效的剪枝搜索方案. 该方案能够在有限的搜索空间内对候选根因集合进行全量对比, 保证了搜索方案的准确性;
- 3) 评估了定位模型中使用的预测算法的准确性和时效性, 主要针对多维 KPI 数据中大量异构 KPI 曲线的数据预测做出了选择和优化.

本文第 1 节描述加性多维 KPI 异常定位的案例、场景和问题, 并对异常传播的特征进行介绍. 第 2 节对 PASER 异常定位模型的设计和结构做出说明, 包括预测算法的选择和定位方案的设计. 第 3 节对 PASER 模型的时效性、准确性进行实验. 最后, 第 4 节对本文的研究工作和结论做出总结.

1 问题说明

1.1 多维 KPI 异常定位案例

为了提供良好的服务质量, 互联网企业往往对一组关键性能指标(KPI)进行监控^[15], 其中, 具有多维属性

的可加性 KPI(如业务交易量、页面访问量、网络流量)与应用运行状态密切相关,因此应密切监控.表 1 为某互联网公司的交易量指标报表示例,交易量是一个具有 3 个维度(机房;省份;渠道)的多维 KPI 数据,报表按照每 5 分钟记录所有最细粒度的交易量数据.每条记录包含属性值的每个时间间隔的 KPI 值,例如(机房 A;广东;渠道 1).由于 KPI 的可加性,这些最细粒度的 KPI 记录可以归纳为更粗粒度的 KPI.例如,(机房 A;广东;*)的交易量表示机房 A、广东省的全部渠道业务量的总和,其中,*为通配符.

Table 1 Case of transaction reports

表 1 交易量指标报表示例

| 时间戳 | 机房 | 省份 | 渠道 | 交易量 |
|------------|------|-----|------|--------|
| 1538150400 | 机房 A | 北京 | 渠道 1 | 28 040 |
| 1538150400 | 机房 B | 上海 | 渠道 2 | 25 736 |
| 1538150400 | 机房 A | 广东 | 渠道 2 | 25 834 |
| 1538150700 | 机房 A | 北京 | 渠道 1 | 26 452 |
| 1538150700 | 机房 B | 上海 | 渠道 2 | 24 279 |
| 1538150700 | 机房 A | 广东 | 渠道 2 | 16 875 |
| ... | ... | ... | ... | ... |

当时间戳=1538150700 时,总交易量数据发生突降,运维人员可以通过图 1 所示报表的不同维度,检查业务量指标在不同维度的变化情况,从而进行异常定位.其中,业务量在广东省份维度、渠道 2 维度分别发生突降,进一步检查省份&渠道组合维度时,确认仅广东省、渠道 2 组合维度业务量发生突降.最终定位到异常根因是(*;广东;渠道 2)组合维度.




图 1 交易量下降时按维度定位的案例

实际场景中,异常发生的根本原因可以是多维属性值的一个或多个组合,例如(北京;天津和河北;*,*).由于可能存在较多的维度,因此维度组合的数量是巨大的,导致运维人员难以第一时间定位到异常的具体位置并进行处理.

1.2 加性多维KPI模型

本文的实验只处理 KPI 总值发生异常的情况,并定位到根本原因的维度组合,加性多维 KPI 指标可以概括为如下数据模型.

不同属性值组合的向量称为元素,例如元素 $x=(i,e,c,p,l)$,其中, $i \in I$ or $i=*$, $e \in E$ or $e=*$, $c \in C$ or $c=*$, $p \in P$ or $p=*$, $l \in L$ or $l=*$. 实时记录每个元素的 KPI 值,称为 $v(x)$. 所有最细粒度的元素组成的集合,称为叶子 $LEAF=\{x|x=(i,e,c,p,l),i,e,c,p,l \neq *\}$,其他元素可以由叶子集合中元素的 KPI 值求和得到,即:

$$v(x) = \sum_{x'_i \in Desc(x)} v(x'_i) \quad (1)$$

其中, $Desc(x)$ 表示 x 的后代元素.

根据元素聚集程度的不同, 可以将元素划分为不同的集合, 每个集合对应一个长方体, 长方体是数据立方^[14]的子立方体. 如图 2 所示, 叶子集合构成的元素构成了一个多维数据立方体, 由 i 、 c 、 p 维度组合. 那么 B_p 是一个一维的立方体, $B_{i,c,p}$ 则是一个三维立方体, 即:

$$B_p = \{x | x = \{*, *, *, p, *\}, p \neq *\} \tag{2}$$

$$B_{i,c,p} = \{x | x = \{i, *, c, p, *\}, i, c, p \neq *\} \tag{3}$$

$$LEAF = B_{i,c,p,l} \tag{4}$$




图 2 数据立方体结构

此外, 数据立方体可以构造为层次结构, 如图 3 所示. 可以认为 B_i 或 B_E 是 $B_{i,E}$ 的父长方体或父节点; $B_{E,C}$ 或 $B_{C,P}$ 是 B_C 的子长方体或子节点.

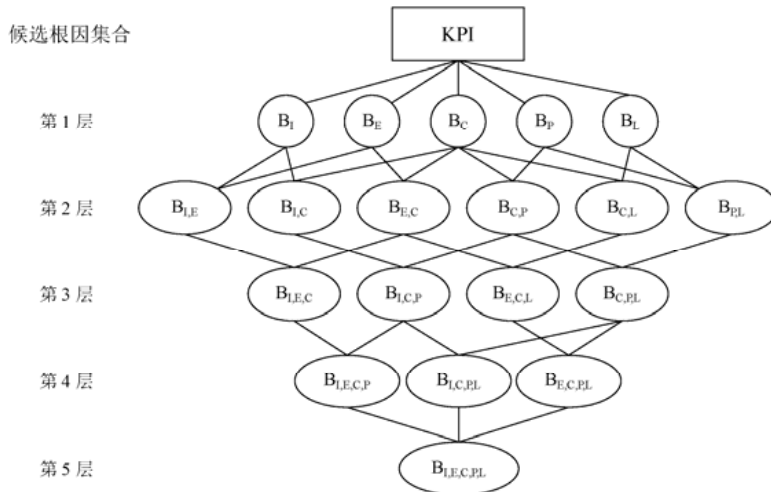


图 3 多维 KPI 层次结构

据此, 加性多维 KPI 的异常定位问题可以描述为: 准确快速地确定 KPI 总值异常的最可能的根本原因, 即一个特定长方体 B 的元素子集. 根因集合定义为 $RSet \in E(B)$.

本文假设一个时刻的异常根因只存在于同一个维度或交叉维度中, 因为异常根因同时存在于多个维度或交叉维度的情况是极为罕见的.

1.3 异常根因定位

在加性多维 KPI 模型中, 当根因集合中的元素的值增加或者减少时, 异常在多维数据中的传播遵循涟漪效应^[14].

- 涟漪效应

令 x 表示一个非叶子节点的元素, x'_i 表示 x 的后代叶子集合, 即 $x'_i \in Desc(x)$. 当 x 的 KPI 值变化了 $h(x)$ 时, 即 $h(x) = f(x) - v(x)$, x'_i 会依照公式(5)共享这种变化:

$$a(x'_i) = f(x'_i) - h(x) \times \frac{f(x'_i)}{f(x)} \quad (f(x) \neq 0) \tag{5}$$

其中, $f(x)$ 是指 $v(x)$ 的预测值, $a(x_i')$ 是指 $v(x_i')$ 的推断值.

所有其他的与 x_i' 含有公共叶子节点的元素都会按照公式(1)受到 x_i' 值变化的影响.

涟漪效应描述了包含一个元素的根因产生的异常如何传播. 当根因是一个集合时, 可以将这种传播特点分别应用于根因集中的每一个元素.

- 根因偏移效应

因为时序预测准确性、随机噪声等因素的影响, 模型有时的输出存在误差或偏移的根因集合, 这种偏移通常具有以下几种情况.

- (1) 根因拆分: 将原本的一个根因拆分为两个或更多的根因(同时伴随根因延展);
 - (2) 根因延展: 将原本较少维度的根因判别为较多维度的根因;
 - (3) 根因紧缩: 将原本较多维度的根因判别为较少维度的根因;
 - (4) 根因横向漂移: 将根因错误判断为具有相同维度数量、但维度组成存在一项或多项差异的根因集合.
- 多维 KPI 下的根因定位问题主要存在以下挑战.

- 如何衡量一个元素成为异常根因的可能性. 为了定位最可能的潜在根因组合, 需要定义一个衡量每个元素潜在可能性的度量函数. 因此, 第 2.3 节提出了潜在分数(potential score, PS)公式来度量一个元素集合的根因可能性大小;
- 搜索空间过大. 如上所述, 根因定位的目的是找出所有维度组合中具有最大潜在分数的集合. 元素的潜在分数是非加性的, 即 $PS(\{x_1, x_2\}) \neq PS(\{x_1\}) + PS(\{x_2\})$, 因此理论上讲, 需要计算所有可能维度组合的潜在分数. 但是这种计算方式会导致指数级别增长的根因集合搜索空间, 因此需要使用合理的搜索方案来降低搜索的时间复杂度.

2 PASER 模型设计

2.1 PASER 整体结构

为了应对第 1.3 节中的挑战, 本文提出了 PASER 模型, 结构如图 4 所示. 模型包括 4 个部分: 数据预处理、叶子元素预测、根因可能性度量与根因搜索、根因决策. 模型的输入数据是大量叶子元素的 KPI 历史数据和异常时间戳数据. 当异常时刻给出时, 根因定位模型进行如下计算: 首先对一段时间内非零数据进行提取, 并对这些有效的叶子元素进行对当前值的预测; 然后, 候选根因集合进行逐层搜索, 依据影响力因子、按层次进行剪枝和筛选, 并依据潜在分数评估数值、保留可能性较高的候选根因集合; 最后, 对搜索得到的候选根因集合进行根因的排序, 保留潜在分数较高的集合, 考虑根因偏移修正方案之后输出最终的根因定位结果.

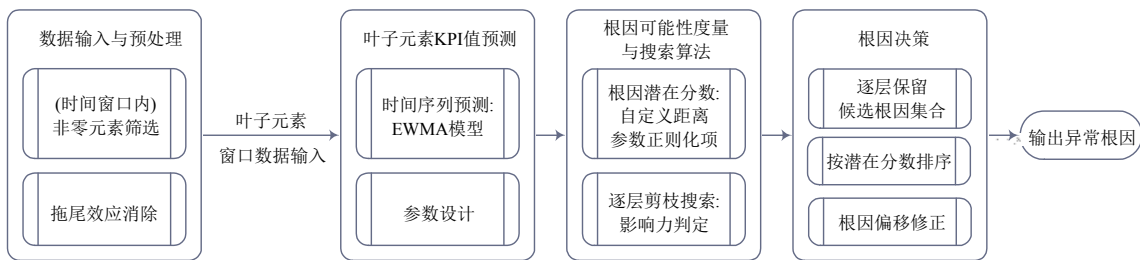


图 4 PASER 模型结构

2.2 KPI 预测模型选择

加性多维 KPI 关于异常时间点的值预测可以概括为: 给定异常时间戳 t 长度为 W 的历史时间窗口内的所有 KPI 叶子元素值 $v_{t,W} = \{v_{t-W}, \dots, v_{t-2}, v_{t-1}\}$, 其中, v_t 表示 t 时刻的所有叶子元素 KPI 实际值, 即 $v_t = \{v(x_1, t), v(x_2, t), \dots, v(x_n, t)\}$, $x_i \in LEAF$, 并计算 t 时刻所有叶子元素的 KPI 预测值 $f_t = \{f(x_1, t), f(x_2, t), \dots, f(x_n, t)\}$, $x_i \in LEAF$.

当预测时间窗口选定之后, 如果两个异常时间戳 t_1 、 t_2 之间的间隔小于预测窗口长度 W , 那么前一个异常

时间点的值 v_{t_1} 由于本身异常, 因此不应该被用于后一个异常时间点的预测值 f_{t_2} 的计算. 除此之外, 根据观察结果, 异常的影响不仅限于标记的异常时间戳, 也同样影响异常时间戳之后的若干个时刻, 即存在拖尾效应. 因此, 这些被拖尾效应影响的时间点的 KPI 值, 也不应当被用于其后的异常点预测值的计算. 即, 在计算 f_{t_2} 时使用的窗口为 $v_{t_2, w} = \{v_{t_2-w-l-1}, \dots, v_{t_1-1}, v_{t_1+l+1}, \dots, v_{t_2-2}, v_{t_2-1}\}$, 其中, l 为拖尾长度.

预测算法的准确性和时间效率是非常重要的评估指标. 一方面, 叶子元素众多的特点限制了预测算法的运行时间上限; 另一方面, 预测算法的准确性对于根因潜在分数的评估有着重要作用. 本文选择 EWMA 作为 PASER 中使用的预测算法, 相关实验见第 3.2.1 节.

2.3 根因可能性评估方案设计

在根因定位的过程中, 需要一种能够全局比较不同元素集合的根因可能性的度量. 即, 任意两个元素集合之间都应该能够比较根因可能性的大小. 当作为根因的元素集合的 KPI 值发生变化时, 其后代的所有叶子元素的 KPI 值也相应发生变化. 因此, 候选集合的潜在分数应该能够反映该集合的后代叶子元素的预期变化和实际变化之间的差异^[15]. 衡量候选集合根因可能性的潜在分数可以按照以下方案进行设计.

- (1) 假设候选集合 S 是异常发生的根因;
- (2) 根据涟漪效应推导出集合 S 的所有后代叶子元素的新 KPI 值;
- (3) 将实际 KPI 值与步骤(2)中推导出的 KPI 值进行比较. 这两种值越接近, S 成为根因集合的可能性就越大.

候选集合的潜在分数取值被设计在 0 到 1 之间. 如果一组候选集合有较高的潜在分数, 它被认为具有更大的可能性成为异常发生的根本原因.

本文提出的潜在分数公式在 HotSpot^[14]基础上做出了改进. HotSpot 在处理不同数量级的叶子元素 KPI 值时有所欠缺, 即: 如果一个很可能属于根因集合的叶子元素的 KPI 值本身数据量级非常大, 远高于其他叶子元素的 KPI 值数据量级, 那么在对包含该叶子元素的集合进行根因潜在分数的计算时, 其他数量级较小的叶子元素的 KPI 值的影响将会变得非常“模糊”, 常常更难以判断这些叶子元素是否应当包含在根因集合之中. 因此, 本文中将欧氏距离改变为具有可变参数的自定义距离. 这种改变减小了叶子元素 KPI 值数量级差异对潜在分数的屏蔽作用, 更多考虑了异常的相似性传播规律, 潜在分数公式为

$$PotentialScore = \max\left(1 - \frac{d'(\bar{v}, \bar{a})}{d'(\bar{v}, \bar{f})} - \beta \cdot (N_{root} - 1), 0\right) \quad (6)$$

其中, \bar{a} 和 \bar{f} 为变量的推断值和预测值^[14]. $d'(\bar{u}, \bar{w})$ 为变量 \bar{u} 和 \bar{w} 之间的自定义距离, 其中, α 为可变常数,

$$d'(\bar{u}, \bar{w}) = \sum_i |u_i - w_i|^\alpha \quad (7)$$

除此之外, 公式(6)中的 β 是正则化系数, 用于抑制根因数量过多的根因拆分现象. β 值的选择取决于预期的根因离散程度, 当多维 KPI 存在较大的噪声时, 选择更大的 β 值.

2.4 多维根因搜索方案设计

在多维加性 KPI 中, 存在一类在预测窗口内值为 0 的叶子元素, 这些元素的有无不影响潜在分数的计算. 因此, 在进行 KPI 预测之前, 需要将所有预测窗口内值为 0 的叶子元素舍去. 零值预处理方案可以减少根因定位算法处理的数据量, 降低计算开销.

对于加性多维 KPI 异常的根因定位, 在确定了任意集合的潜在分数计算方案之后, 对异常根因搜索的过程就是在任意维度组合的所有集合中, 寻找潜在分数最大的候选根因集合的过程. 这个搜索空间是非常巨大的. 考虑根因的数量不确定, 搜索空间的大小可能会扩展到 2^n 数量级.

针对搜索空间爆炸问题, PASER 采取了逐层剪枝搜索的方案进行根因集合的搜索, 并且提出了影响力的概念作为剪枝搜索的依据, 如公式(8)所示:

$$Effect(S) = \frac{h(S)}{\sum_{x \in LEAF} h(x)} \quad (8)$$

$$h(S)=|v(S)-f(S)| \quad (9)$$

其中, $v(S)$ 为集合 S 的 KPI 值, $f(S)$ 为集合 S 的 KPI 预测值.

一个候选集合的影响力因子表示单一维度集合的 KPI 值变化对整体 KPI 值变化可能拥有的影响力, 使用该集合的 KPI 值的变化量占整体变化量的比重计算. 影响力的概念与前述 PS 值的概念存在相似性和差异性. 影响力主要用于粗略地衡量一个候选集合中发生的变化有多“重要”, 但不能给出这种变化是否是导致 KPI 总值变化的根本原因的说明; PS 值则应用多维 KPI 异常传播模型衡量候选集合对异常传播的作用. 相比于 PS 值, 影响力因子运算量更小, 因此在初步过滤候选根因集合时, 能够有效提升算法的效率. 剪枝搜索的过程需要逐层计算候选根因集的潜在分数, 并保留在每层中, 每个维度组合中潜在分数最高的 cut_num 项 ($cut_num=5\sim 10$) 来代表这个维度组合的根因搜索结果. 在计算潜在分数的过程中, 同时计算影响力因子, 剪除影响力过低的元素. 这就极大地缩小了搜索空间, 将根因搜索方案的时间复杂度降低到线性复杂度. 基于影响力的逐层剪枝搜索的流程如算法 1 所示.

算法 1. 基于影响力的逐层剪枝搜索流程.

记维度层级总数为 $layer_num$, 本文实验中共有 5 个维度, 因此 $layer_num=5$

- (1) 初始化 $layer=1$
- (2) 初始化 $Elements[1]$ 为所有维度数量为 1 的元素, 形如 $Elements[1]=\{(i1),(i2),(e1),(c1),\dots\}$
- (3) **while** $layer \leq layer_num$
- (4) **for** $Elements[layer]$ 中的每一个元素 x , 其中, x 根据其维度标题归属于一个特定的候选集合 s , 例如 $x=(i1,e1), x \in s$, 命名 $s=(i,e)$
- (5) 计算 x 的影响力 $Eff(x)$
- (6) **if** $Eff(x) < T_{Eff}$, 其中, T_{Eff} 为元素的影响力阈值
- (7) $PS(x)=0$
- (8) 丢弃 x 及其所有子节点元素
- (9) **Continue while**
- (10) **end if**
- (11) 计算 x 的潜在分数 $PS(x)$, 若步骤(7)中已经赋值则不用再次计算
- (12) **if** $PS(x) < T_{ps}$, 其中, T_{ps} 为元素的潜在分数阈值
- (13) **Continue while**
- (14) **end if**
- (15) **for** $layer$ 层的每个候选集合 s
- (16) s 中仅保留潜在分数前 cut_num 高的元素 x , 丢弃其他元素及其子节点元素, $cut_num=5$
- (17) 计算 s 的潜在分数 $PS(s)$: 使用公式(6)计算 s 中未被丢弃的所有子节点元素构成的集合的潜在分数值
- (18) 将 s 和 $PS(s)$ 加入待定根因集: $Candidate.Add(s)$
- (19) 计算下一层的全部候选元素: $Elements[layer+1]=$ 所有 $Elements[layer]$ 未在步骤(8)中丢弃的子节点组成的集合
- (20) $layer+=1$
- (21) **end while**
- (22) 按照 $PS(s)$ 为待定根因集合排序: $Candidate.SortedDesc(PS(s))$
- (23) 取 $Candidate$ 中 $PS(s)$ 最高的 s , s 中未被丢弃的所有节点为剪枝算法的输出

2.5 根因延展修正方案设计

由于实际的多维 KPI 异常传播存在噪声影响以及预测算法误差等因素, 所以搜索得到的根因组合容易产生根因拆分、根因延展等偏移现象. PASER 模型中提出了以下两种方案来缓解根因偏移的问题.

- (1) 针对根因拆分问题, 潜在分数的计算考虑了根因数量的不利影响, 增加了根因数量的正则化项, 如

公式(6)所示;

- (2) 针对根因延展问题, 在对最后的候选根因集合进行排序和选择时, 按照奥卡姆剃刀原则, 以一定的容忍度将较多维度的根因修正为较少维度的根因. 这一步的问题在于不同维度上的根因集合内部的根因并不是一一对应的, 也就是说, 需要解决多个包含较少叶子元素的根因能否合并成更少量的包含较多叶子元素的根因的问题. 根因修正方案如算法 2 所示, 其中, $\dim(S)$ 表示候选根因集 s 的维度, T_{ocm} 表示根因延展修正的 PS 值容忍度.

算法 2. 根因延展修正方案.

输入逐层剪枝搜索得到的每层若干个候选根因集;

- (1) 将全部候选根因集按照 PS 值从大到小排列, 取得 PS 值最高的根因集 s , s 的维度为 $\dim(s)$
- (2) 取维度为 $\dim(s)-1$ 的候选根因集合 $S'=\{s'|\dim(s')=\dim(s)-1\}$
- (3) **for** S' 中的每个 s'
- (4) **if** s 是 s' 的维度延伸**且 $PS[s]-PS[s']<T_{ocm}$
- (5) $s \leftarrow s'$, 返回步骤(2)
- (6) **end if**
- (7) **end for**

**维度延伸: 若集合 s 是 s' 的维度延伸, 意味着 s 包含的叶子元素是 s' 包含的叶子元素的子集. 从形式上说, s 是在 s' 的表述格式上增加一个维度制约条件组成的. 维度延伸的双方不要求根因的总数相同. 例, $s'=\{(i1, e1)\}$, $s=\{(i1, e1, c2)\}$ 或 $s=\{(i1, e1, c1), (i1, e1, c2)\}$ 都符合维度延伸的概念.

3 性能分析

3.1 数据集选择及实验设置

本文使用第 2 届 AIOps 挑战赛^[16]的数据(多维 KPI 的异常定位测试集 2). 挑战赛发布了互联网公司的脱敏多维度指标数据进行多维度指标的根因定位. 数据集描述如下: 实时给出所有叶子元素(30 011 个)的 KPI 值, 并在异常发生时给出异常时间戳. 根因检测算法应当在异常发生后一定的时间内给出根因集合, 其中包含若干个维度相同的根因元素, 形如 $s=\{(i1, e1), (i1, e2), (i2, e3)\}$. 根因集不应包括形如 $s=\{(i1, e1), (i1, c2)\}$ 等维度不相同的元素.

根因检测的效果使用 F -score 判定, 如公式(12)所示. 其中, 每个异常时刻都有一个真正的根因集合, 记为 S^* , 该集合中包含一个或多个属性值组合, 根因定位算法输出结果记为 S . 对于 S^* 中的每一个元素, S 中包含其中 1 个, 则算 1 次 true positive(TP), 遗漏 1 个算 1 次 false negative(FN), 多出 1 个 S^* 中不存在的, 记 1 次 false positive(FP). 计算出所有异常时刻总的 TP、FP、FN, 最后得出 F -score:

$$precision = \frac{TP}{TP + FP} \tag{10}$$

$$recall = \frac{TP}{TP + FN} \tag{11}$$

$$F\text{-score} = \frac{2 \times precision \times recall}{precision + recall} \tag{12}$$

实验中使用的参数设置见表 2.

表 2 PASER 模型参数

| 实验名称 | 参数名称 | 值 |
|-----------------|------------|---|
| 时间窗口与预测算法(EWMA) | 窗口长度 W | 7 |
| | 异常拖尾数量 l | 2 |
| | 窗口中最小观测数 | 5 |
| | 跨度 N | 5 |

表 2 PASER 模型参数(续)

| 实验名称 | 参数名称 | 值 |
|--------|------------------------|-----------|
| 逐层剪枝搜索 | 影响力阈值 T_{eff} | 0.02 |
| | 潜在分数阈值 T_{ps} | 0.04 |
| | 根因集合保留数量 cut_num | 5 |
| | 潜在分数正则化常数 β | 0.015 |
| 根因延展修正 | 潜在分数自定义距离可变参数 α | 1 |
| | 容忍度 T_{ocm} | 10^{-6} |

3.2 实验流程

3.2.1 时间序列预测算法选择

本小节使用了 WMA, EWMA, RF, LSTM 这几种算法作为对比, 实验异常定位模型中 KPI 值的预测方案. 实验的参数设置见表 3.

表 3 WMA, EWMA, RF, LSTM 预测算法参数设置

| 算法名称 | 参数名称 | 值 | |
|------|--|-------|------|
| WMA | 线性参数 n | 4 | |
| EWMA | 跨度 N | 5 | |
| RF | 决策树数量 | 10 | |
| | 最大特征数/ 最大深度/ 最小叶子抽样数/ 最大叶子节点数 | 自动/不限 | |
| | LSTM | 时间步 | 3 |
| | | 激活函数 | ReLU |
| | 损失函数 | 均方误差 | |
| | Batch Size | 1 | |
| | 迭代次数 | 50 | |

使用以上几种预测模型的根因定位准确性和时效性对比见表 4, 其中, LSTM 模型由于预测时间过长, 所以并未进行全数据集上的结果验证. 该实验证明使用神经网络的时间预测算法由于通常时效性比较差, 而不适用于元素众多的多维 KPI 预测.

表 4 WMA, EWMA, RF, LSTM 预测算法的准确性和时效性对比

| 时间序列预测算法 | F -score | 平均每个异常时刻定位时间(括号内为方差) (s) |
|----------|------------|--------------------------|
| WMA | 0.972 376 | 2.445316(0.753964) |
| EWMA | 0.990 345 | 5.314729(1.031505) |
| RF | 0.913 580 | 74.988737(10.876399) |
| LSTM | - | >1800 |

使用随机森林进行预测的实验, 定位时间约 75s, F -score 达到了 0.91, 在实际场景中不能做到即时定位. 使用 WMA 预测平均耗时约 2.4s, 使用 EWMA 预测平均耗时约 5.3s, 都做到了准即时的根因定位. 而 EWMA 模型由于指数加权方式具有较好的抗噪能力, 因此定位表现更加准确. WMA, EWMA, RF 算法的具体定位时间分布如图 5 所示. 综合以上算法的特点和表现, 最终, 本文选择 EWMA 算法作为时间序列预测的模型.




图 5 WMA, EWMA, RF 算法的具体定位时间分布

3.2.2 潜在分数度量与根因偏移修正实验验证

该部分对加性多维 KPI 异常定位模型中提出的潜在分数公式以及根因偏移方案进行了对比和验证. 实验中出现的定位误差有以下 6 种情况, 其中, $BSet$ 表示决策得到的根因集合, $RSet$ 表示真正的根因集合.

- (1) 仅多根/多根&变维: 例如 $BSet=\{(i1)\}$, $Rset=\{(i1), (i2)\}$ 或 $\{(i1, e1), (i2, e1)\}$;
- (2) 仅少根/少根&变维: 例如 $BSet=\{(i1, e1), (i2, e1)\}$, $Rset=\{(i1, e1)\}$ 或 $\{(i1)\}$;
- (3) 仅根因延展: 例如 $BSet=\{(i1)\}$, $Rset=\{(i1, e1)\}$;
- (4) 根因拆分&延展: 例如 $BSet=\{(i1, e1)\}$, $Rset=\{(i1, e1), (i1, e2)\}$;
- (5) 根因紧缩: 例如 $BSet=\{(i1, e1)\}$, $Rset=\{(i1)\}$;
- (6) 根因横向漂移: 例如 $BSet=\{(i1, e1)\}$, $Rset=\{(i1, c1)\}$.

本文对 Hotspot^[14]改进的自定义可变距离与根因数量正则化项以及根因延展修正的实验效果对比结果如图 6 所示.

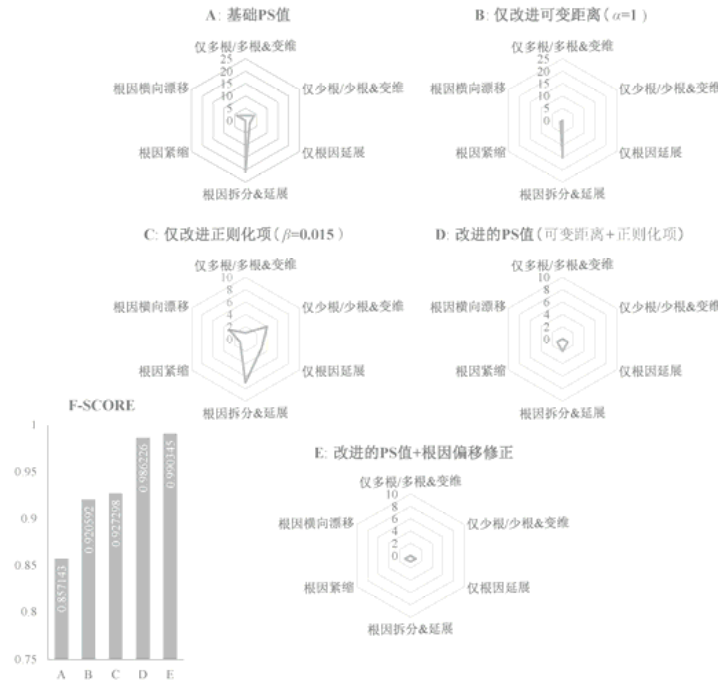


图 6 基础 PS 公式、PS 公式改进的自定义可变距离与根因数量正则化项、根因延展修正的实验效果对比

从实验结果中可以看到: 出现最多的误差类型是根因拆分&延展; 除此之外, 多根、少根、变维、横漂等问题在一定程度上出现. 从图 6 中的实验 B 可以看出: 可变距离参数的出现, 对于这 6 类异常的整体效果均有所改善; 改进之后, 根因拆分&延展仍然是最重要的误差问题. 图 6 实验 C 则表明: 正则化项加入后, 根因拆分&延展类误差大大减少. 而根因偏移修正方案主要对根因延展现象都起到修正作用. 使用改进 PS 值和根因偏移修正的最终结果如图 6 实验 E 所示.

3.2.3 根因定位算法对比实验

本节中, 我们复现了以下 3 种对比算法, 并与 PASER 的准确性和时效性进行了对比实验.

- Adtributor^[12]: 在广告收益发生变化时, Adtributor 定位其根本原因, 结果根因集合为一维根因集合;
- iDice^[13]: 当商业系统出现较多新报告问题(issue), iDice 定义识别新问题的有效组合, 其搜索算法基于 BFS(breadth first search, 广度优先搜索), 结果根因集合不限维度;
- HotSpot^[14]: 具有数据立方体结构的多维 KPI 指标数据的根因定位, 其搜索算法基于 MCTS(Monte

Carlo tree search, 蒙特卡洛树搜索), 结果根因集合属于同一个维度。

其中, PASER 与 HotSpot 算法对场景和结果根因集合的定义是一致的。为了与 Adtributor 对比, 我们将数据集按照标签根因维度进行分组。对于输出根因数量的选择, 我们将 Adtributor 和 iDice 按照标签根因数量取 Top 值。实验结果见表 5。

表 5 Adtributor, iDice, HotSpot 和 PASER 的定位结果对比

| 算法 | 评估指标 | 标签结果维度 | | | | | |
|------------|-----------------|--------|-------|-------|-------|-------|-------|
| | | 1 | 2 | 3 | 4 | 5 | 不限 |
| Adtributor | <i>F</i> -score | 0.758 | — | — | — | — | — |
| | 定位时间(s) | 0.46 | — | — | — | — | — |
| iDice | <i>F</i> -score | 0.628 | 0.424 | 0.47 | 0.5 | 0.531 | 0.534 |
| | 定位时间(s) | 13.9 | 16.1 | 15.69 | 14.14 | 15.23 | 14.87 |
| HotSpot | <i>F</i> -score | 0.785 | 0.922 | 0.92 | 0.75 | 0.823 | 0.845 |
| | 定位时间(s) | 33.84 | 33.23 | 32.71 | 35.17 | 34.1 | 33.52 |
| PASER | <i>F</i> -score | 0.989 | 0.988 | 1 | 1 | 1 | 0.990 |
| | 定位时间(s) | 5.52 | 5.20 | 4.87 | 4.75 | 4.81 | 5.31 |

从实验结果中可以看出: Adtributor 仅适用于获取一维根因的场景, 在一维场景下准确率较高, 定位速度在 4 种算法中是最快的; iDice 在实验数据上准确率不高, 主要原因可能是 iDice 的结果根因不分布在同一维度; HotSpot 和 PASER 在计算中排除了结果根因维度不同的情况, 因为这种情况比较罕见(需要两个或两个以上不同类故障的发生时刻完全一致)。这让结果根因集合具有更好的解释性和维度意义上的准确性, 运维人员在使用定位结果时只需要聚焦同一维度, 但在故障多发时会忽略掉次要根因维度。

PASER 与 HotSpot 相比, 由于评估了预测算法、改进了潜在分数公式, 因此获得了准确度的提升。在搜索算法方面, HotSpot 使用 MCTS 算法, MCTS 是一种基于概率模型的搜索算法, 随着运行时间的增长, 它的定位准确率会逐渐提高, 这让使用者可以自行选择搜索过程消耗时间。图 7 对比了 MCTS 和 PASER 中基于影响力的剪枝搜索消耗的时间, 当定位的运行时间达到 34s 左右时, MCTS 算法达到了最高的 *F*-score。




图 7 MCTS 与 PASER 的基于影响力剪枝搜索的定位时间对比

而基于影响力的逐层搜索算法是一种剪枝方案而非概率模型, 该算法在平均运行时间约为 5.3s 时完成定位。图 7 中, 两者使用相同的预测算法和潜在分数公式, 两种算法最终能够达到基本相同的 *F*-score(接近或等于理论上评估方式决定的准确度上界)。这证明在保证搜索有效性的前提下, PASER 的搜索算法时效性较好, 能够达到准即时的异常定位效果。

3.2.4 自定义可变距离参数 α 的影响

根据加性多维 KPI 的异常传播特点, 自定义可变距离参数 α 将会影响到 KPI 值较小的根因或叶子元素。在本小节的实验通过改变可变距离参数 α , 观察异常根因定位的准确性效果, 实验结果如图 8 所示。

当 α 值取到 1 时, 根因定位的 *F*-score 达到最大值。如图 8(b)所示: 当 α 大于 1 时, 随着 α 值的增加, 各种偏移误差都有所上升, 而当 α 值小于 1 时, 主要产生明显的少根现象。本文使用 $\alpha=1$ 。




图 8 参数 α 对根因定位效果的影响

4 总 结

为满足当前网络应用环境中分布式系统的管理和服务质量保障的需求, 智能运维(AIOps)是下一代运维发展的热点方向. 以大数据为基础进行的 KPI 异常定位, 是智能运维关注的重点领域. 当故障发生时, 迅速定位到根本原因, 对于提高故障处理能力来说非常关键.

针对以上问题, 本文提出了 PASER 模型. 首先, 通过一种有效的衡量候选根因可能性的潜在分数计算方法, 捕捉加性多维 KPI 的异常传播过程, 准确衡量异常的影响范围和变化量; 其次, 为了应对 KPI 叶子元素的多层次场景中候选根因集合的数量巨大的问题, 本文提出了一种高效的逐层剪枝搜索算法, 保证了根因定位的效率; 此外, 针对异常定位产生的根因偏移现象, 本文提出了使用可变 α 值和正则化项的根因偏移修正方案, 有效地弥补了潜在分数评估方式产生的误差. PASER 考虑了异常根因定位算法的实时性、稳定性和准确性要求, 异常定位的 F -score 达到了 0.99. 平均定位时间约为 5.3s.

References:

- [1] Wang J, Jing Y, Qi Q, Feng T, Liao J. ALSR: An adaptive label screening and relearning approach for interval-oriented anomaly detection. *Expert Systems with Applications*, 2019, 136: 94–104. [doi: 10.1016/j.eswa.2019.06.028]
- [2] Qi Q, Shen RY, Wang JY. GAD: Topology-aware time series anomaly detection. *Journal on Communications*, 2020, 41(6): 152–160. [doi: 10.11959/j.issn.1000-436x.2020113]
- [3] Liu D, Zhao Y, Xu H, Sun Y, Pei D, Luo J, Jing X, Feng M. Opprentice: Towards practical and automatic anomaly detection through machine learning. In: *Proc. of the 2015 Internet Measurement Conf.* Tokyo: ACM, 2015. 211–224. [doi: 10.1145/2815675.2815679]
- [4] Chen MY, Kiciman E, Fratkin E, Fox A, Brewer E. Pinpoint: Problem determination in large, dynamic Internet services. In: *Proc. of the Int'l Conf. on Dependable Systems and Networks*. Washington: IEEE Computer Society, 2002. 595–604. [doi: 10.1109/DSN.2002.1029005]
- [5] Kompella RR, Yates J, Greenberg AG, Snoeren AC. Fault localization via risk modeling. *IEEE Trans. on Dependable & Secure Computing*, 2009, 7(4): 396–409. [doi: 10.1109/TDSC.2009.37]
- [6] Kandula S, Katabi D, Vasseur JP. Shrink: A tool for failure diagnosis in IP networks. In: *Proc. of the 1st Annual ACM Workshop on Mining Network Data*. Philadelphia: ACM, 2005. 173–178. [doi: 10.1145/1080173.1080178]
- [7] Kompella RR, Yates J, Greenberg AG, Snoeren AC. Detection and localization of network black holes. In: *Proc. of the 26th IEEE Int'l Conf. on Computer Communications*. Anchorage: IEEE, 2007. 2180–2188. [doi: 10.1109/INFCOM.2007.252]
- [8] Bahl P, Chandra R, Greenberg AG, Kandula S, Maltz DA, Zhang M. Towards highly reliable enterprise network services via inference of multi-level dependencies. In: *Proc. of the ACM SIGCOMM 2007 Conf. on Applications*. Kyoto: ACM, 2007. 13–24. [doi: 10.1145/1282380.1282383]

- [9] Yan H, Flavel A, Ge ZH, Gerber A, Massey D, Papadopoulos C, Shah H, Yates J. Argus: End-to-end service anomaly detection and localization from an ISP's point of view. In: Proc. of the IEEE INFOCOM 2012. Orlando: IEEE, 2012. 2756–2760. [doi: 10.1109/INFOCOM.2012.6195694]
- [10] Nguyen B, Ge Z, Merwe JE, Yan H, Yates J. ABSENCE: Usage-based failure detection in mobile networks. In: Proc. of the 21st Annual Int'l Conf. on Mobile Computing and Networking. Paris: ACM, 2015. 464–476. [doi: 10.1145/2789168.2790127]
- [11] Liu D, Zhao Y, Sui K, Zou L, Pei D, Tao Q, Chen X, Tan D. FOCUS: Shedding light on the high search response time in the wild. In: Proc. of the 35th Annual {IEEE} Int'l Conf. on Computer Communications. San Francisco: IEEE, 2016. 1–9. [doi: 10.1109/INFOCOM.2016.7524413]
- [12] Bhagwan R, Kumar R, Ramjee R, Vatghese G, Mohapatra S, Manoharan H, Shah P. Adtributor: Revenue debugging in advertising systems. In: Proc. of the 11th USENIX Symp. on Networked Systems Design and Implementation. Seattle: USENIX Association, 2014. 43–55.
- [13] Lin Q, Lou JG, Zhang H, Zhang D. iDice: Problem identification for emerging issues. In: Proc. of the 38th Int'l Conf. on Software Engineering. Austin: ACM, 2016. 214–224. [doi: 10.1145/2884781.2884795]
- [14] Sun Y, Zhao Y, Su Y, Liu D, Nie X, Meng Y, Cheng S, Pei D, Zhang S, Qu X, Guo X. HotSpot: Anomaly localization for additive KPIs with multi-dimensional attributes. IEEE Access, 2018, 6: 10909–10923. [doi: 10.1109/ACCESS.2018.2804764]
- [15] Jing YH. Research on multi-stage machine learning based anomaly detection and correlation model of KPI [MS. Thesis]. Beijing University of Posts and Telecommunications, 2020 (in Chinese with English abstract). [doi: 10.26969/d.cnki.gbydu.2020.000373]
- [16] Netman. Anomaly location of multi-dimensional monitoring indicators. 2019. http://iops.ai/competition_detail/?competition_id=8&flag=1

附中文参考文献:

- [15] 靖宇涵. 基于多阶段机器学习的 KPI 异常检测与相关性模型研究 [硕士学位论文]. 北京邮电大学, 2020. [doi: 10.26969/d.cnki.gbydu.2020.000373]



靖宇涵(1995—), 女, 工程师, 主要研究领域为异常检测, 故障定位, 机器学习.



李天星(1996—), 女, 硕士, 主要研究领域为智能运维领域的异常检测和根因定位.



何波(1995—), 男, 博士生, 主要研究领域为网络路由协议, 流量调度, 多路径传输协议, 深度强化学习.



王敬宇(1978—), 男, 博士, 教授, 博士生导师, 主要研究领域为智能网络, 人工智能, 多媒体通信.



张凌昕(1996—), 女, 硕士生, 主要研究领域为智能运维, 强化学习, 任务调度.



刘聪(1980—), 男, 博士, 高级工程师, 主要研究领域为人工智能, 物联网.