DOI:10.11918/202205060

基于近邻搜索空间提取的LOF算法

王若雨[1],赵千川[1],杨 文[1,2]

(1.清华大学 自动化系智能与网络化系统研究中心,北京 100084;
2.航天发射场可靠性重点实验室,海口 570100)

摘 要:针对局部异常因子(local outlier factor,LOF)异常检测算法时间空间复杂度高、对交叉异常及低密度簇周围异常点不敏感等局限,提出了基于近邻搜索空间提取的LOF异常检测算法(isolation-based data extracting LOF,iDELOF),将基于隔离思想的近邻搜索空间提取(isolation-based KNN search space extraction,iKSSE)前置于LOF算法,以高效剪切掉大量无用以及干扰数据,获得更加精准的搜索空间。基于此完成了理论以及4组实验分析,每组实验分别进行iDELOF算法与LOF、iForest、iNNE等多种典型算法的对比分析。结果表明:iDELOF算法通过拉大正异常点局部离群因子的差距,增强了对交叉异常以及低密度簇周围异常点的识别能力,提升了LOF的检测效果;iDELOF算法在识别轴平行异常方面与LOF同样具有明显优越性;iDELOF算法通过iKSSE所获数据子集显著小于原数据集,多数子集数据量小于原数据集的1%,因此iDELOF的时间空间复杂度显著降低,且原数据集数据量越大,优越性越明显,当数据量足够大时,iDELOF算法的运行时间将低于IF算法。

关键词:异常检测;iDELOF;iKSSE;局部离群因子;实验分析
中图分类号:TP301.6 **文献标志码**:A **文章编号**:0367-6234(2023)10-0001-09

Isolation-based data extracting LOF

WANG Ruoyu[1], ZHAO Qianchuan[1], YANG Wen[1,2]

(1. Center for Intelligent and Networked Systems, Department of Automation, Tsinghua University, Beijing 100084, China; 2. Key Laboratory of Space Launching Site Reliability Technology, Haikou 570100, China)

Abstract: Addressing the limitations of LOF anomaly detection algorithm, such as with high time and space complexity and insensitivity to cross anomalies and outliers around low-density clusters, this paper proposes isolation-based data extracting LOF (iDELOF) anomaly detection algorithm, which puts the isolation-based K-nearest-neighbor search space extraction (iKSSE) in front of LOF, to efficiently cut out a large amount of useless and interfering data and obtain a more accurate search space. Based on this, the theoretical and four groups of experimental analysis are completed, and in each group of experiments, iDELOF is compared with many typical algorithms such as LOF, iForest and iNNE. The results show that iDELOF improves the detection capabilities of LOF by widening the gap between the local outlier factor of normal and abnormal points, and enhancing the ability to identify cross anomalies and abnormal points around low-density clusters. Additionally, iDELOF has the same obvious superiority as LOF in identifying axis-parallel anomalies. The data subset obtained by iDELOF through iKSSE is significantly smaller than the original dataset and the data volume of most subsets is less than 1% of the original dataset. Therefore, the time and space complexity of iDELOF is significantly reduced, and the larger the amount of data in the original dataset, the more obvious the superiority is. When the amount of data is large enough, the running time of iDELOF will be lower than that of the IF algorithm.

Keywords: abnormal detection; iDELOF; iKSSE; local outlier factor; experimental analysis

异常检测是数据挖掘领域一项非常重要的技术,广泛应用于金融、网络、保险、股票等多个领域[1]。基于相对密度的局部异常因子(local outlier factor,LOF)[2]算法是目前应用最广泛且最有效的无参数异常检测算法之一,尤其是对于呈偏态分布的数据集。有鉴于此,相关文献[3-12]开展了大量基于LOF的研究,但对于LOF的局限性,人们依然没有找到较好的改进方法,这使得该算法无法拓展到数据规模更大以及检测精度需求更高的应用场景中。第一,其时间复杂度较高,由于LOF要分别对n个样本点进行k近邻搜索,因此使用线性扫描方法的时间复杂度为$O(n^2)$。第二,其空间复杂度较高,

收稿日期:2022-05-18;**录用日期**:2022-10-12;**网络首发日期**:2023-04-27
网络首发地址:http://kns.cnki.net/kcms/detail/23.1235.T.20230427.1122.004.html
作者简介:王若雨(2000—),女,硕士研究生;赵千川(1969—),男,教授,博士生导师
通信作者:杨 文,whutyw@126.com

由于LOF算法需要存储每对数据点的距离信息,因此其空间复杂度也为$O(n^2)$。这使得该算法无法应用于数据流处理中,因为随着数据源源不断的到达,LOF所需内存将持续增大,直到无法处理[8]。第三,LOF对交叉异常以及低密度簇周围异常点识别不敏感。在真实场景中,正异常点通常不是泾渭分明而是交错在一起的,LOF对这种紧邻正常数据簇且与其存在一定交叉的异常点的识别不敏感,最差情况下LOF将退化为随机检测器。同时在真实数据集中,正常数据的分布不会只集中在一个区域,而是分布在多个密度不同的簇中,虽然与多数算法相比,LOF可以较为有效地检测出这种存在于非均匀密度数据中的异常点,但其仍存在局限性,即相比于高密度簇,低密度簇正常点周围的异常点更容易被LOF算法忽略。

1 理论基础

LOF算法通过计算局部离群因子来衡量每个数据点的异常程度,数据点a局部离群因子的计算以及分析需要以下定义以及定理,其中定理1的具体证明过程参见文献[2]。

定义1 点a与其第k邻域点之间的欧氏距离为$d_k(a)$。

定义2 点o到点a的可达距离为

$$d_{\text{reach},k}(a,o)=\max\{d_k(o),d(a,o)\} \tag{1}$$

式中$d(a,o)$为点a和点o之间的欧氏距离。

定义3 点a的局部可达密度为

$$d_{\text{lr},k}(a)=\frac{1}{\left[\dfrac{\sum_{o\in N_k(a)}d_{\text{reach},k}(a,o)}{|N_k(a)|}\right]} \tag{2}$$

式中$N_k(a)$为a点k近邻数据点的集合。

定义4 点a的局部离群因子为

$$F_{\text{lo},k}(a)=\frac{\sum_{o\in N_k(a)}\dfrac{d_{\text{lr},k}(o)}{d_{\text{lr},k}(a)}}{|N_k(a)|} \tag{3}$$

定义5 点a第k邻域中一点到点a可达距离的最小值以及最大值为

$$F_{\min}(a)=\min\{d_{\text{reach},k}(a,b)\mid b\in N_k(a)\} \tag{4}$$

$$F_{\max}(a)=\max\{d_{\text{reach},k}(a,b)\mid b\in N_k(a)\} \tag{5}$$

定义6 点a第k邻域中一点b的第k邻域中一点到点b可达距离的最小值以及最大值为

$$S_{\min}(a)=\min\{d_{\text{reach},k}(b,o)\mid b\in N_k(a)\text{且}\ o\in N_k(b)\} \tag{6}$$

$$S_{\max}(a)=\max\{d_{\text{reach},k}(b,o)\mid b\in N_k(a)\text{且}\ o\in N_k(b)\} \tag{7}$$

定理1 假设a为数据集D中的一个样本点,并且$1\leqslant k\leqslant|D|$,则点a局部离群因子的范围为

$$\frac{F_{\min}(a)}{S_{\max}(a)}\leqslant F_{\text{lo},k}(a)\leqslant\frac{F_{\max}(a)}{S_{\min}(a)} \tag{8}$$

2 iDELOF算法

iDELOF异常检测算法,将iKSSE前置于LOF算法,高效剪切掉大量无用及干扰数据,获得更加精准的搜索空间,极大提升LOF异常检测算法的效率及效果。算法分为近邻搜索空间提取(iKSSE)、异常分数计算(anomaly score calculation,ASC)两个阶段,每个阶段又分为两步。

2.1 第一阶段iKSSE

iKSSE分为构造数据提取森林、提取近邻搜索空间两步。

第一步,构造数据提取森林。利用孤立森林[13]提出的隔离思想对数据随机选择属性、随机设定阈值分隔为左右叶子节点,不断迭代重复,直到叶子节点中只有一个样本点或所有样本点取值相同,或者提取树到达最大设定阈值l。与IF算法建立的隔离树一样,提取树也为二叉树,其中每个节点又分为拥有两个叶子节点的内部节点以及没有叶子节点的外部节点两种类型;与隔离树的区别在于,提取树中每个外部节点的存储内容不再是数据点的数量,而是所有被分割到此节点的数据点以及数据点在树中对应的深度,即数据点被分割的次数。按上述方法,在多个随机抽取的样本子集上建立t棵提取树,组合成为数据提取森林。构建数据提取森林的具体细节见算法1、2。

算法1 iDETree(X,c,l)

Input: X-input data, c-current tree depth, l-depth limit

Output: an *iDETree*

1: if $c\geqslant l$ or $|X|\leqslant 1$ then

2: return *exNode*{*data*←X, *depth*←c}

3: else

4: let A be a list of attributes in X

5: randomly choose an attribute $a\in A$

6: randomly choose a divide point b from *min* and *max* value of attribute a in X

7: X_l←*filter*($X,a\leqslant b$)

8: X_r←*filter*($X,a>b$)

9: return *inNode*{*Left*←*iDETree*($X_l,c+1,l$); *Right*←*iDETree*($X_r,c+1,l$)}

10: end if

算法 2　iDEForest(X,t,φ)

Input：X-input data，t-number of trees，φ-subsample size
Output：a group of *iDETrees*
1：Initialize　*iDEForest*
2：set depth limit $l = ceiling(\log_2 \varphi)$
3：for　$i = 1 : t$ do
4：　$\hat{X} \leftarrow sample(X, \varphi)$
5：　$iDEForest = iDEForest \cup iDETree(\hat{X}, 0, l)$
6：end for
7：return　*iDEForest*

第二步，提取近邻搜索空间。遍历提取森林中的所有外部节点，取出每棵树中深度位于设定的深度阈值 C_t 以下的外部节点中的所有样本，即位于数据集全局较中心的数据，并且将在所有树中提取到的数据合并得到候选数据。最后根据设定的次数阈值 N，在候选数据中筛选出提取次数超过 N 的所有数据，作为第二阶段近邻数据的搜索空间。从构建好的森林中提取近邻数据搜索空间的具体细节见算法 3、4。

算法 3　DataExtraction(T,C_t)

Input：T-an iDETree，C_t-depth threshold
Output：*candidate_data* from an iDETree
1：if T is an external node
2：　if　T. depth > C_t then
3：　　return T. *data*
4：　end if
5：else
6：　return *combine* (*DataExtraction* (T. *left*, C_t), *DataExtraction*(T. *right*, C_t))
7：end if

算法 4　DataFilter(F,C_t,N)

Input：F-an iDEForest，C_t-depth threshold，N-filter threshold
Output：*KNN search_space*
1：Initialize　*candidate_data*，*search_space*
2：for　T in F　do
3：　*candidate_data* = *candidate_data* ∪ *DataExtraction* (T,C_t)
4：end for
5：(*value*,*counts*) ← *count*(*condidate_data*)
6：if　*counts* ≥ N then
7：　*search_space* = *search_space* ∪ *value*
8：end if
9：return　*KNN search_space*

2.2　第二阶段 ASC

根据 LOF 的思想，计算每个测试点的局部利群因子，其中 k 近邻的搜索空间不再是全部数据集而是由 iKSSE 提取所得的子集。异常分数计算分为两步：

第一步，在 iKSSE 提取所得搜索空间中实例化每个样本点的 k 近邻数据，以及他们到样本点的距离，将所得结果保存在数据库 M 中；

第二步，根据第一步所得数据库 M，计算每个样本点的局部离群因子作为异常分数，并且据此对所有样本进行排序，挑选出异常点。

3　前置 iKSSE 的优越性

相对于 LOF 算法，iDELOF 算法前置 iKSSE，借助隔离的思想快速提取位于簇中心的子集作为 ASC 近邻数据搜索空间，具有以下优越性。

3.1　拉大正异常点局部离群因子之间的差距

对位于簇周围的异常点 p，其 $F_{min}(p)$、$F_{max}(p)$ 增大，而 $S_{min}(p)$、$S_{max}(p)$ 不变，因此异常点的 LOF 值增大；而对位于簇深处的正常点 o，即其所有 k 近邻都在簇中，并且其 k 近邻的所有 k 近邻点也都在簇中的点，其 $F_{min}(o)$、$F_{max}(o)$ 和 $S_{min}(o)$、$S_{max}(o)$ 均改变不大，因此正常点的 LOF 值也变化不大。因此 iDELOF 算法拉大了正异常点 LOF 值之间的差距，使异常检测变得更容易。为进一步说明，图 1 和图 2列举了一个简单的例子，其中 k 取 2。

3.2　增强对交叉异常的识别能力

对于 LOF 算法，簇中心与边缘样本点的 LOF 值相差不大，因此该算法无法有效识别此类交叉异常，当簇的密度变化不大时，LOF 将退化为随机检测器。对于 iDELOF 算法，只有位于簇深处样本点 o 的 LOF 值是相同的，而簇内其余点 p 的 $S_{min}(p)$、$S_{max}(p)$ 虽然变化不大，但 $F_{min}(p)$、$F_{max}(p)$ 随着与中心距离由近至远逐渐增加，因此 LOF 值也随之增加，呈阶梯分布，这使得算法更有可能将位于数据集边缘的样本点识别为交叉异常，而不是盲目地从整个数据集中随机识别。为进一步说明，图 3 和图 4 列举了一个简单的例子，其中 k 取 2，红色点为交叉异常点，黑色点为正常点。

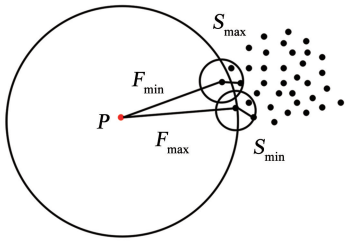

(a) 加入前

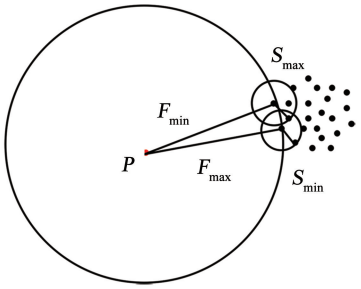

(b) 加入后

图 1 加入 iKSSE 前后 p 点 LOF 的取值范围

Fig. 1 LOF value range of p before and after adding iKSSE

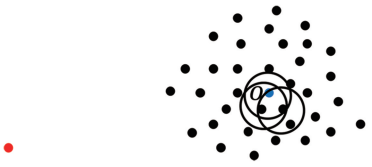

(a) 加入前

(b) 加入后

图 2 加入 iKSSE 前后 o 点 LOF 的取值范围

Fig. 2 LOF value range of o before and after adding iKSSE

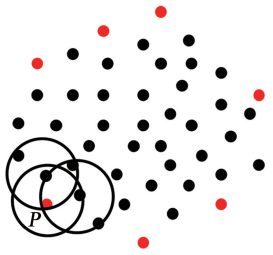

(a) 加入前

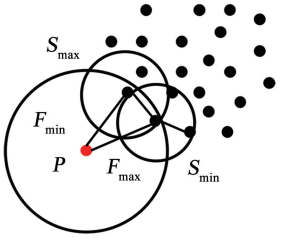

(b) 加入后

图 3 加入 iKSSE 前后 p 点 LOF 的取值范围

Fig. 3 LOF value range of p before and after adding iKSSE

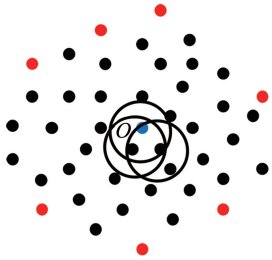

(a) 加入前

(b) 加入后

图 4 加入 iKSSE 前后 o 点 LOF 的取值范围

Fig. 4 LOF value range of o before and after adding iKSSE

3.3 增强低密度簇周围异常点的识别能力

对于 LOF 算法,在 $F_{min}(a)$、$F_{max}(a)$ 相同的前提下,显然低密度簇周围异常点比高密度簇周围异常点的 $S_{min}(a)$、$S_{max}(a)$ 更高,其 LOF 值相应的更小,因此也更容易被 LOF 忽略。对于 iDELOF 算法,图 5 为数据提取森林中深度的等高线图,从图中可以看出当深度阈值 C_t 固定时,加入 iKSSE 后,对于近邻数据的搜索空间,其低密度簇半径的缩减量大于高密度簇,也就是说在 $S_{min}(a)$、$S_{max}(a)$ 不变的情况下,显然低密度簇周围异常点比高密度簇周围的异常点的 $F_{min}(a)$、$F_{max}(a)$ 增加的更多,因此两者 LOF 值之间的差距减小,改善了 LOF 对存在于不同密度簇周围异常点的识别偏差。

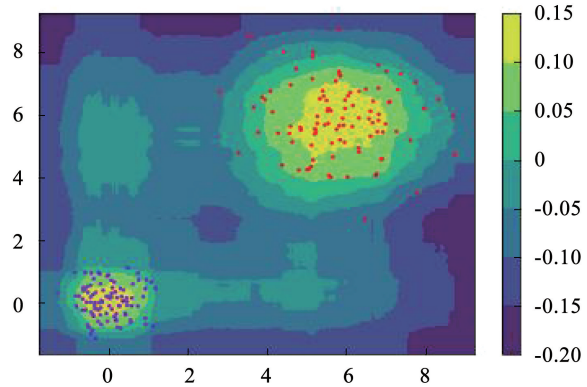

图 5 各数据点在数据提取森林中的深度等高线

Fig. 5 Depth contour plot of each datapoint in iDEForest

3.4 降低时间和空间复杂度

3.4.1 时间复杂度

对于 iKSSE 阶段:假设建立 t 棵树,每棵树的采样大小为 ψ,则时间复杂度为 $O(t\psi\log\psi)$,独立于样本大小以及空间维度,只在模型训练时提取一次。

对于 ASC 阶段:不同于 LOF 算法,iDELOF 算法

是在 iKSSE 提取到的子集上进行 k 近邻搜索，因此每个估计器的时间成本是 $O(n\cdot m)$，并且 iDELOF 只有一个基估计器，因此算法的时间成本就是 $O(n\cdot m)$，其中 n 为数据集大小，m 为 iKSSE 提取到的子集的大小（$0<m<n$）。通过实验可知 m 的取值独立于样本大小及空间维度，取决于数据集的分布特征，并且 m 通常远远小于 n，从多数数据集提取到的最优子集的大小还不到整个数据集的 1%。因此该阶段的时间复杂度与样本大小呈线性关系，且该线性关系的斜率 m 很小，也就是算法的运行时间随着样本数量的增加而上涨缓慢。

综上算法的整体时间复杂度为 $O(t\psi\log\psi)+O(n\cdot m)$，可以看出 iDELOF 有效地将 LOF 的时间复杂度降低到与样本数量呈线性关系且该线性关系的斜率很小，并且样本数量越大，iKSSE 的时间耗费相较于其他算法就变得越微不足道，整个算法在时间复杂度上的优越性也就越明显。因此本文算法更适合应用于超大规模的数据中。

3.4.2　空间复杂度

对于 iKSSE 阶段：假设建立 t 棵树，每棵树的采样大小为 $\psi=2^a$，则每棵树最大的节点数为 $N_{\text{node}}=2^a+2^{a-1}+\cdots+2^0$，因此所需内存为 $O(t\cdot N_{\text{node}})$，独立于样本数量，对于计算机来说微不足道。对于 ASC 阶段：iDELOF 算法是在 iKSSE 提取到的样本子集上进行 k 近邻搜索，因此可以有效地将所需内存减小到 $O(m^2)$。

综上，算法整体的空间复杂度为 $O(t\cdot N_{\text{node}})+O(m^2)$，远小于 LOF，且不会随着样本数量的增加而持续上涨，因此算法可以很容易加入在线学习的模块，应用于数据流中。

4　实验验证

进行了 4 组实验，每组实验分别进行 iDELOF 算法与 LOF、IF、iNNE（isolatin using nearest neighbour ensemble）[14] 3 种典型算法的对比分析，以验证 iDELOF 算法的优越性及其应对真实数据集的能力。其中前 2 组实验采用合成数据集，验证 iDELOF 算法在识别交叉异常以及轴平行异常方面的优越性；第 3 组实验采用 Backblaze 上公开的磁盘数据集，验证当数据集规模不断增大时 iDELOF 算法在时间复杂度上的优越性；第 4 组实验采用 Backblaze 和 UCI 上多个公开数据集，测试 iDELOF 应对不同维度、异常比例及数量级的真实数据集的能力。各种算法的超参数均根据数据集调整到最佳组合，其中 iDELOF、IF 以及 iNNE 为随机算法，他们的 AUC 值（A_{AUC}）均采用 10 次不同的随机数种子计算所得平均值。

4.1　交叉异常的识别

主要测试各种算法对交叉异常的识别能力。采用合成数据集，包括 2 个密度不同的正常数据簇，异常数据分布在正常簇周围并且存在一定交叉。其中低密度簇包含 200 个样本点，周围存在 20 个异常点；高密度簇包含 500 个样本点，周围存在 40 个异常点。异常点在固定环宽的圆环中随机生成，根据圆环边界与正常数据边界圆环交叉程度的不同，生成 5 组不同的数据集，分别表示不同的正异常数据交叉比例，见图 6。

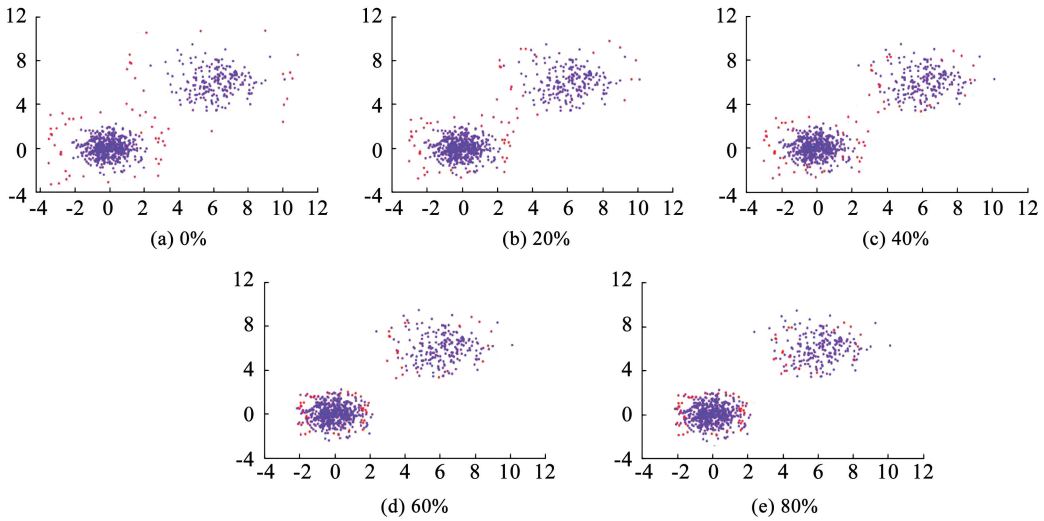

图 6　不同交叉比例的测试数据集

Fig. 6　Test datasets with different crossover ratios

图 7 为 4 种算法的 A_{AUC} 随着交叉比例的变化趋势。从图中可以看出随着交叉比例的增大,各个算法的识别能力都有所下降,其中 iDELOF 一直拥有着最高的 A_{AUC},且随着交叉比例越大,iDELOF 与其他算法之间的差距也越大,识别优越性越明显。

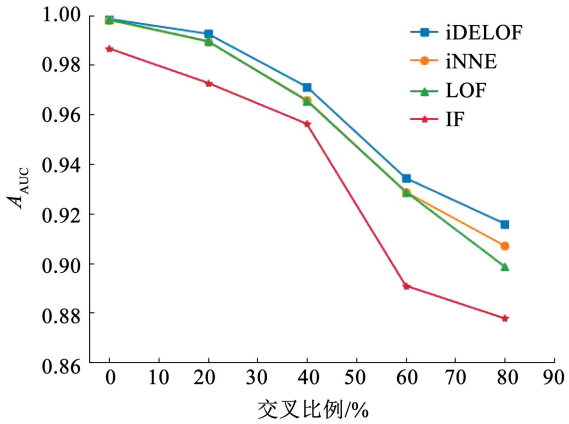

图 7　各算法在不同交叉比例下的 A_{AUC}

Fig. 7　A_{AUC} of each algorithm under different crossover ratios

4.2　轴平行异常的识别

主要测试各种算法对轴平行异常的识别能力。实验采用 2 组轴平行异常的数据集,数据集 1 见图 8(a),正常数据呈螺旋形分布,其中隐藏着 6 个异常点,数据集2见图3(b),图中左下和右上角为 2 个呈高斯分布的密度不同的正常数据簇,左上和右下角为 2 个异常数据簇。

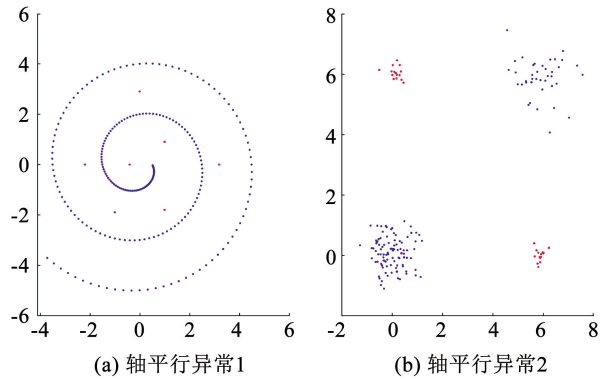

图 8　轴平行异常测试数据

Fig. 8　Test datasets of axis parallel anomaly

图 9 为各数据点在不同算法下所得 LOF 值的等高线图。从图中可以看出,RC(robust covariance)及 IF 算法的识别效果非常差,这是由于 IF 基于正常数据点的投影进行分割,因此对此类隐藏在轴平行中的异常点无能为力,iNNE 的识别效果也不理想。而对于 iDELOF 以及 LOF 算法,只要调整好近邻数据 k 的大小便可以很好刻画出正异常点的分界。因此虽然加入 iKSSE,iDELOF 本质上依然为基于相对密度的算法,与 LOF 算法一样在识别轴平行异常方面具有明显优越性。

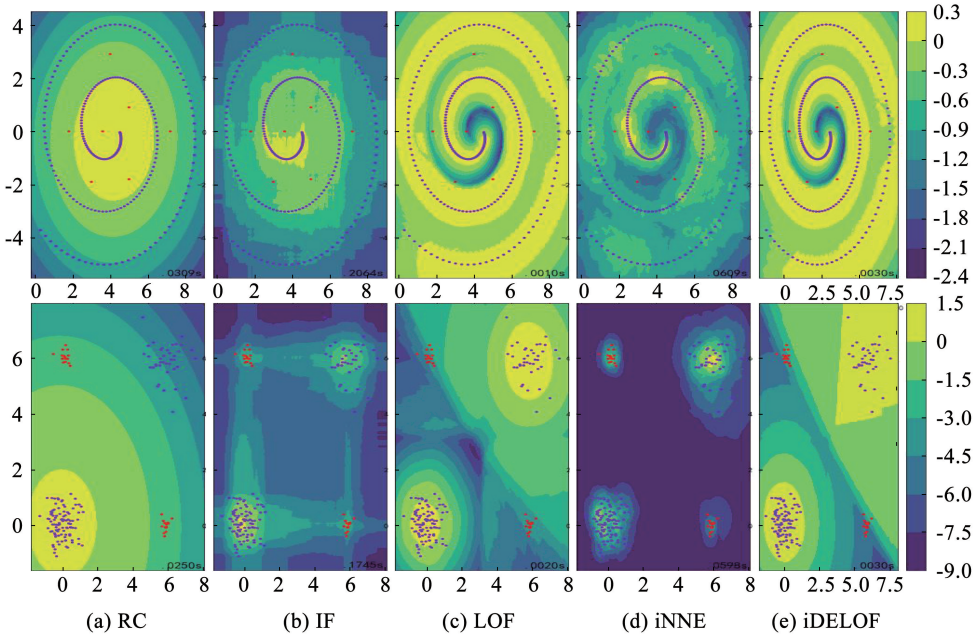

图 9　各数据点在不同算法下 LOF 值的等高线

Fig. 9　LOF values contour map of each datapoint under different algorithms

4.3　时间复杂度测试

主要验证 iDELOF 算法在时间复杂度方面优越性。采用的数据集为 Backblaze 2015 年 ST4000DM000 型号的磁盘数据,数据集规模为 1 000 ~ 250 000。采用的方法为对比各算法检测磁盘异常所需运行时间随样本数量的变化情况,其中 LOF 算法根据是否使用 R_tree[15] 分为 LOFIndexed 以及 LOF 算法。

图 10 记录了各算法的运行时间随数据集规模

的变化趋势，图 11 记录了 iKSSE 在不同规模磁盘数据集下提取到的子集的大小。从图 10 可以看出 IF、iNNE 以及 iDELOF 算法的时间复杂度与数据集大小呈线性关系，LOF 算法的时间复杂度则与数据集大小的二次方成正比，而 LOFIndexed 算法利用 R_tree对 k 近邻进行快速检索，时间复杂度相比线性扫描方法有所降低，但当样本数据量增大时，运行时间依然很大。从图 11 可以看出随着磁盘数据集规模的扩大，iKSSE 提取到的子集的大小 m 不会随之增加，而是稳定在 100 附近。因此虽然在数据量较小时，iDELOF 由于加入 iKSSE 步骤，运行时间比其他几个算法略长，但是当样本数量逐渐增多时，算法在时间复杂度上的优越性就体现出来了：iDELOF 的运行时间随着样本规模增大而增加缓慢，其时间曲线的斜率 m 比最有效率的 IF 算法都要小。当样本的数量达到 25 000 时，iDELOF 算法的运行时间已经远远小于 LOF 算法；当样本数量达到 250 000 时，iDELOF 算法的运算速度已经逼近 IF 算法，并且可以预测随着样本规模的进一步扩大，iDELOF 算法在时间复杂度上的优越性也会体现得越明显，成为最有效率的算法。

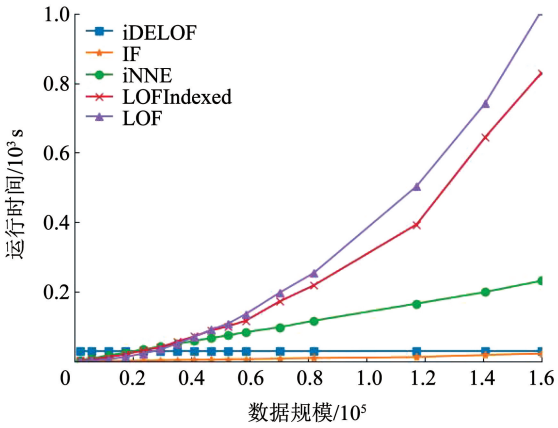

图 10　各算法在不同规模数据集下的运行时间

Fig. 10　Running time of each algorithm on different scale datasets

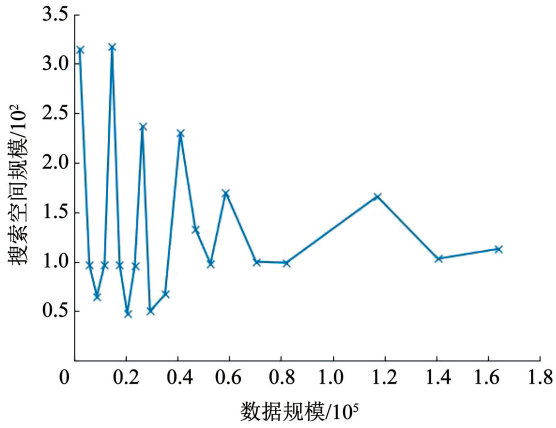

图 11　iKSSE 在不同规模数据集下获得子集的大小

Fig. 11　Size of subsets extracted by iKSSE under different scale datasets

4.4　真实数据集测试

主要验证 iDELOF 算法应对真实数据集的能力。采用包括 Backblaze 和 UCI 上不同维度、异常比例及数量级共 5 个公开数据集。每个数据集的大小、纬度、处理方式以及异常比例见表 1。各个算法的超参数采用网格搜索法得到最佳组合见表 2。不同算法在不同数据集上的 A_{AUC} 值以及对应的运行时间记录见表 3 和表 4。iKSSE 在不同数据集上提取到的子集大小记录见表 4。

表 1　实验数据集信息

Tab. 1　Experimental dataset information

名称	数量	维数	异常 vs 正常数据标签	异常比例/%
ST4000DM000	140 640	5	“1” vs “0”	0.417
Skin	55 057	3	“1” vs “2”	26.000
Occupancy	8 143	5	“1” vs “0”	27.000
Isolate	6 237	618	“9”、”15” vs 其他	7.690
Waveform	4 999	22	“0” vs “1”、”2”	49.500

表 2　各算法在不同数据集上的最佳参数

Tab. 2　Optimal parameters of each algorithm on different datasets

数据集	iDELOF				LOF	IF		iNNE	
	t	ψ	C_t	k	N	k	t	ψ	φ
ST4000DM000	400	800	8	5	65	1 000	200	256	75
Skin	100	400	8	1	38	4 900	230	256	23
Occupancy	50	400	5	3	35	6 800	120	256	22
Isolate	50	200	7	5	6	3 240	150	256	23
Waveform	50	300	5	1	9	4 800	210	256	33

表3 各算法在不同数据集上的 A_{AUC}

Tab.3 A_{AUC} of each algorithm on different datasets

数据集	iDELOF	LOF	IF	iNNE
ST4000DM000	0.850 5	0.833 4	0.833 0	0.838 8
Skin	0.940 2	0.701 7	0.706 0	0.753 3
Occupancy	0.979 7	0.977 9	0.900 0	0.880 3
Isolate	0.799 8	0.711 4	0.665 0	0.700 1
Waveform	0.743 0	0.693 0	0.555 2	0.553 3

表4 各算法的运行时间以及 iKSSE 提取到的子集大小

Tab.4 Running time of each algorithm and size of subsets extracted by iKSSE

数据集	运行时间/s				iKSSE 提取到的子集大小
	iDELOF	LOF	IF	iNNE	
ST4000DM000	11.780	633.810	18.475	199.010	270(0.2%)
Skin	5.490	126.357	7.220	79.023	96(0.17%)
Occupancy	2.250	15.175	1.710	10.040	83(1.02%)
Isolate	4.356	106.683	4.224	69.410	10(0.16%)
Waveform	2.188	7.186	1.610	8.840	19(0.38%)

对于检测精度,从表3中可以看出 iDELOF 在多个不同真实数据集上均被证实拥有最优的 A_{AUC},在离群点检测精度方面优越性明显。对于运行效率,从表2中可以看出 LOF 算法在多数大规模数据集上都需要很大 k 值才可以达到较好的检测效果,因此该算法的时间复杂度是所有算法中最高的。iDELOF 算法由于前置了 iKSSE,从各个数据集中提取到的子集的大小只占整个数据集的1%左右(见表4),这使得算法仅需要个位数的 k 值(见表2)就可以达到很好的效果。因此 iDELOF 在多数数据集上都保持着较小的时间复杂度(见表4),只在最后3个数据集上运行时间比 IF 算法稍慢,这主要是数据集规模较小,算法的优越性没有完全体现的原因。

5 结 论

iDELOF 异常检测算法将基于隔离思想的近邻搜索空间提取前置于 LOF 算法,高效剪切掉大量无用及干扰数据,获得更加精准的搜索空间。研究表明:

1)iDELOF 异常检测算法拉大了正异常点局部利群因子的差距,增强了对交叉异常及低密度簇周围异常点的识别能力,提升了检测效果。

2)iDELOF 异常检测算法在识别轴平行异常方面,与 LOF 一致,具有明显的优越性。

3)iDELOF 异常检测算法通过 iKSSE 获得的子集显著小于原数据集,且多数子集数据量小于原数据集的1%,因此 iDELOF 的时间空间复杂度显著降低。

4)原数据集数据量越大,iDELOF 异常检测算法在时间复杂度上的优越性越明显;当样本数量达到一定数值时,iDELOF 算法的运行时效将高于 IF 算法。

5)不同纬度、规模、异常比例真实数据集实验表明:iDELOF 算法在异常点检测精度及运行效率方面显著优于其他先进算法。

参考文献

[1] KELLER F, MULLER E, BOHM K. HiCS: High contrast subspaces for density-based outlier ranking [C]//2012 IEEE 28th International Conference on Data Engineering. Arlington: IEEE, 2012: 1037. DOI: 10.1109/ICDE.2012.88

[2] BREUNIG M M, KRIEGEL H P, NG R T, et al. LOF: Identifying density – based local outliers [C]//Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. New York: Association for Computing Machinery, 2000: 93. DOI: 10.1145/335191

[3] SHARFY R, GHARAEI R H, TAHERI S M. Improved LOF algorithm using random point[C]//2022 9th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS). Bam: IEEE, 2022: 1. DOI: 10.1109/CFIS54774.2022.9756488

[4] XU Siying, LIU Huiyi, DUAN Liting, et al. An improved LOF outlier detection algorithm[C]//2021 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA). Dalian: IEEE, 2021: 113. DOI: 10.1109/ICAICA52286.2021.9498181

[5] FAN Linchang, MA Jinqiang, TIAN Junjing, et al. Comparative study of isolation forest and LOF algorithm in anomaly detection of data mining [C]//2021 International Conference on Big Data, Artificial Intelligence and Risk Management (ICBAR). Shanghai:

IEEE，2021：1. DOI：10.1109/ICBAR55169.2021.00008

[6]CHENG Geyao，GUO Deke，LUO Lailong，et al. Lofs：A lightweight online file storage strategy for effective data deduplication at network edge[J]. IEEE Transactions on Parallel and Distributed Systems，2021，33(10)：2263. DOI：10.1109/TPDS.2021.3133098

[7]ZIMEK A，GAUDET M，CAMPELLO R J G B，et al. Subsampling for efficient and effective unsupervised outlier detection ensembles[C]//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York：Association for Computing Machinery，2013：428. DOI：10.1145/2487575

[8]NA G S，KIM D，YU H. Dilof：Effective and memory efficient local outlier detection in data streams[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York：Association for Computing Machinery，2018：1993. DOI：10.1145/3219819

[9]SALEHI M，LECKIE C，BEZDEK J C，et al. Fast memory efficient local outlier detection in data streams[J]. IEEE Transactions on Knowledge and Data Engineering，2016，28(12)：3246. DOI：10.1109/TKDE.2016.2597833

[10]PAPADIMITRIOU S，KITAGAWA H，GIBBONS P B，et al. Loci：Fast outlier detection using the local correlation integral[C]//Proceedings 19th International Conference on Data Engineering. Bangalore：IEEE，2003：315. DOI：10.1109/ICDE.2003.1260802

[11]ANGIULLI F，FASSETTI F. Dolphin：An efficient algorithm for mining distance-based outliers in very large datasets[J]. ACM Transactions on Knowledge Discovery from Data (TKDD)，2009，3(1)：1. DOI：10.1145/1497577

[12]LAZAREVIC A，KUMAR V. Feature bagging for outlier detection[C]//Proceedings of the Eleventh ACM SIGKDD International Conference on Knowledge Discovery in Data Mining. New York：Association for Computing Machinery，2005：157. DOI：10.1145/1081870.1081891

[13]LIU F，TING Kaiming，ZHOU Zhihua. Isolation forest[C]//2008 Eighth IEEE International Conference on Data Mining. Pisa：IEEE，2008：413. DOI：10.1109/ICDM.2008.17

[14]BANDARAGODA T R，TING K M，ALBRECHT D，et al. Efficient anomaly detection by isolation using nearest neighbour ensemble[C]//2014 IEEE International Conference on Data Mining Workshop. Shenzhen：IEEE，2014：698. DOI：10.1109/ICDMW.2014.70

[15]BECKMANN N，KRIEGEL H P，SCHNEIDER R，et al. The R* - tree：An efficient and robust access method for points and rectangles[C]//Proceedings of the 1990 ACM SIGMOD International Conference on Management of Data. New York：Association for Computing Machinery，1990：322. DOI：10.1145/93605

[16]NA G S，KIM D，YU H. Dilof：Effective and memory efficient local outlier detection in data streams[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York：Association for Computing Machinery，2018：1993. DOI：10.1145/3219819.3220022

[17]SALEHI M，LECKIE C，BEZDEK J C，et al. Fast memory efficient local outlier detection in data streams[J]. IEEE Transactions on Knowledge and Data Engineering，2016，28(12)：3246. DOI：10.1109/ICDE.2017.32

[18]ZHAO Jian，HE Yongzhan，LIU Hongmei，et al. Disk failure early warning based on the characteristics of customized smart[C]//2020 19th IEEE Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems (ITherm). Orlando：IEEE，2020：1282. DOI：10.1109/ITherm45881.2020.9190324

（编辑　苗秀芝）