



计算机科学

COMPUTER SCIENCE

融合AP聚类算法和宽度学习系统的分布外硬盘故障预测

王屹阳, 刘发贵, 彭玲霞, 钟国祥

引用本文

王屹阳, 刘发贵, 彭玲霞, 钟国祥. [融合AP聚类算法和宽度学习系统的分布外硬盘故障预测](#)[J]. 计算机科学, 2024, 51(8): 63-74.

WANG Yiyang, LIU Fagui, PENG Lingxia, ZHONG Guoxiang. [Out-of-Distribution Hard Disk Failure Prediction with Affinity Propagation Clustering and Broad Learning Systems](#) [J]. Computer Science, 2024, 51(8): 63-74.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[基于对偶流形重排序的无监督特征选择算法](#)

Unsupervised Feature Selection Algorithm Based on Dual Manifold Re-ranking

计算机科学, 2023, 50(7): 72-81. <https://doi.org/10.11896/jsjcx.221000143>

[基于局部加权表示的线性回归分类器及人脸识别](#)

Local Weighted Representation Based Linear Regression Classifier and Face Recognition

计算机科学, 2021, 48(11A): 351-359. <https://doi.org/10.11896/jsjcx.210100173>

[快速局部协同表示分类器及其在人脸识别中的应用](#)

Fast Local Collaborative Representation Based Classifier and Its Applications in Face Recognition

计算机科学, 2021, 48(9): 208-215. <https://doi.org/10.11896/jsjcx.200800155>

[视频人脸识别进展综述](#)

Survey on Video-based Face Recognition

计算机科学, 2021, 48(3): 50-59. <https://doi.org/10.11896/jsjcx.210100210>

融合 AP 聚类算法和宽度学习系统的分布外硬盘故障预测

王屹阳¹ 刘发贵^{1,2} 彭玲霞¹ 钟国祥¹

¹ 华南理工大学计算机科学与工程学院 广州 510006

² 鹏城实验室 广东 深圳 518066

(202220143286@mail.scut.edu.cn)

摘要 硬盘是云数据中心最主要的存储设备,硬盘故障预测是保障数据安全的重要手段。但是,硬盘的故障与健康样本之间存在着极端的数量不平衡问题,这会导致模型偏差;此外,不同型号的硬盘数据分布存在一定的差异,在特定硬盘数据上训练的模型往往不适用于其他硬盘。对于这两个问题,文中提出了一种融合 AP 聚类算法和宽度学习系统的分布外硬盘故障预测方法。针对样本不平衡问题,文中使用 AP 聚类算法对硬盘故障出现前一阶段的样本集进行聚类,将与故障样本处于同一聚类簇的样本扩充为故障样本。针对不同型号硬盘分布存在差异的问题,文中结合流形正则化框架和宽度学习系统来学习硬盘数据的低维结构,提高模型对未知分布数据的泛化能力。实验结果表明,在 AP 聚类算法重采样的样本集上,相较于用于对比的重采样方法得到的样本集,多种故障预测方法的 F1_Score 取得了平均 0.2 的提升。此外,在分布外硬盘故障预测任务上,所提模型的 F1_Score 相比对比方法提升了 0.1~0.2。

关键词: 硬盘故障预测;类不平衡;分布外泛化;AP 聚类;宽度学习系统;流形学习

中图分类号 TP302

Out-of-Distribution Hard Disk Failure Prediction with Affinity Propagation Clustering and Broad Learning Systems

WANG Yiyang¹, LIU Fagui^{1,2}, PENG Lingxia¹ and ZHONG Guoxiang¹

¹ School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China

² Peng Cheng Laboratory, Shenzhen, Guangdong 518066, China

Abstract Hard disk is the primary storage device in cloud data centers, and hard disk failure prediction is crucial for ensuring data security. However, there is a significant imbalance between failure and healthy SMART samples, which can lead to model bias. Moreover, hard disk models exhibit varying data distributions. Prediction models trained on specific hard disk data may not be suitable for other hard disks. To address these issues, this paper proposes a method for out-of-distribution hard disk failure prediction by combining the AP clustering algorithm and the broad learning system. To tackle the sample imbalance problem, this paper uses the AP clustering algorithm to cluster samples close to failure and treats all samples in the cluster containing determined failure instances as additional failure samples. To address the distribution differences of hard disk models, this paper combines the manifold regularization framework and the broad learning system to learn the low-dimensional structure of hard disk data, thereby improving the model's generalization ability to unknown data. Experimental results show that, on the dataset resampled by the AP clustering algorithm, the F1_Score of multiple methods increases by an average of 0.2 compared to the datasets resampled by comparative methods. Additionally, in the task of predicting out-of-distribution hard disk failures, the F1_Score of the proposed model increases by 0.1~0.2 compared to other methods.

Keywords Hard disk failure prediction, Class imbalance, Out-of-distribution generalization, Affinity propagation clustering, Broad learning system, Manifold learning

到稿日期:2023-06-12 返修日期:2023-11-28

基金项目:鹏城实验室重大项目(PCL2023A09);广东省基础与应用基础研究重大项目(2019B030302002);广州市重点领域研发计划项目(202007030006);广东省省级科技计划项目(2021B1111600001)

This work was supported by the Major Key Project of PCL, China(PCL2023A09), Guangdong Major Project of Basic and Applied Basic Research(2019B030302002), Science and Technology Major Project of Guangzhou(202007030006) and Science and Technology Project of Guangdong Province(2021B1111600001).

通信作者:钟国祥(cszhongguoxiang111@mail.scut.edu.cn)

1 引言

被动式硬盘容错方案,如数据备份^[1]和纠错码^[2]等,能够在故障发生后采取相应措施恢复或重构故障硬盘中丢失或受损的数据。但是,备份无法覆盖所有硬盘,仍有一定的风险,而且大规模数据备份的开销非常大。提前预测硬盘故障的发生,对可能出现故障的硬盘进行检修或备份等处理,不仅可以降低数据丢失的风险,而且可以缩小备份范围,减小开销。因此,硬盘故障预测方法受到了广泛关注。

近年来,通过采集硬盘的自我监测、分析及报告(S. M. A. R. T.)历史数据来训练机器学习模型,对硬盘的健康状态进行预测,已逐渐成为硬盘故障预测研究中的主流方法^[3-4]。但是,基于机器学习的硬盘预测方法还存在以下问题:

1)机器学习模型需要合适的数据集进行训练,但硬盘的SMART样本数据存在着正负样本极端不平衡的现象^[5]。根据BackBlaze数据中心的统计,不同型号的硬盘平均故障率仅有1.39%^[6]。不仅如此,硬盘在故障发生后通常会立即下线,无法继续采集其故障样本。这两点因素导致故障样本远少于健康样本。

2)机器学习模型往往假设训练数据和测试数据同分布,但不同硬盘的SMART数据分布存在差异。由于数据中心需要不断添加硬盘进行扩容,硬盘故障预测模型往往需要对训练集分布外的新硬盘进行预测^[7-8]。目前的一些机器学习方法在特定型号硬盘数据集上训练得到的模型仅适用于同一厂商硬盘的故障预测任务,甚至仅适用于同一型号硬盘的预测任务^[9]。

对此,本文提出了一种融合AP聚类算法和宽度学习系统的分布外硬盘故障预测方法。

针对正负样本极端不平衡现象,使用聚类方法对样本重采样能够在保证样本质量的同时缓解不平衡问题。而在聚类方法选择方面,硬盘状态较多,无法简单分为固定几类,不同硬盘的类别分布也存在一定差异。AP聚类方法无需指定聚类簇数目,对初始值不敏感,稳定性较高,因此适用于对类别数不确定的多种硬盘进行聚类。本文根据硬盘故障率遵循的浴盆曲线,将硬盘故障前的一段时间划分为半健康阶段。在该阶段的样本中使用AP聚类算法,将与故障样本处于同一聚类簇的样本也扩充为故障样本;对健康硬盘也进行类似操作,选取采样时间次新的聚类簇作为可靠健康样本,实现数据集的再平衡。

云数据中心内的硬盘数量庞大,迭代较快,且SMART数据是一种简单的表格型数据。相比深度学习模型,宽度学习处理这类数据的开销较小,同时也能保证精度;相比简单模型,宽度学习可以结合一些迁移学习方法提高其泛化能力。因此,本文通过在宽度学习的损失函数上加入流形正则化项的方式,帮助模型学习不同硬盘在低维上的相似特征,从而提高其泛化能力,解决分布外硬盘故障预测问题。

本文的贡献主要有以下3点:

1)针对正负样本极端不平衡现象,本文根据硬盘故障浴盆曲线划定半健康阶段,使用AP聚类方法对样本重采样。相比常用的回溯法,该方案能够在保证样本质量的同时平衡

正负样本比例,从而提高模型的训练效果。

2)为了解决硬盘故障预测分布外问题,本文采用了结合流形正则化框架的宽度学习方法。该模型速度快,泛化能力强,面对新硬盘型号时能够及时给出较好的预测效果。在获取足够的标记样本后,该模型也可以快速重新进行训练。

3)实验结果表明,本文提出的AP聚类重采样方案将多种模型的F1_Score平均提升了0.2。同时,本文提出的分布外硬盘故障预测方法相比其他轻量级模型的泛化能力优势明显,在同品牌不同型号的硬盘预测任务上,F1_Score提升了0.1,在不同品牌的硬盘预测任务上,F1_Score提升了0.2。

2 相关工作

2.1 样本不平衡

机器学习方法首先需要数据样本进行训练,但在硬盘故障预测任务中,存在着严重的样本不平衡问题^[5]。样本不平衡问题指在数据集中某一类的样本数量远远少于其他类的样本数量,导致模型更偏向于数量较多类的问题^[10]。正负样本极端不平衡会严重影响模型的预测效果。

硬盘属于硬件设备,可以借助浴盆曲线(Bathtub Curve)^[11]理解硬盘故障规律,从而更好地处理样本。硬盘的故障率浴盆曲线^[12]如图1所示。硬盘在初期的故障率较高,这类故障大多是硬盘厂商固件设计缺陷以及人为操作失误导致的,这部分样本在硬盘故障研究中价值不高。在稳定期,硬盘长期保持稳定,该阶段健康样本冗余较多。在损耗期,硬盘故障率随时间不断提高,直至硬盘彻底故障停用。在这一阶段一般只有硬盘停用前采集到的最后一个样本会被标记为故障样本。有一些研究认为,故障硬盘在停用前一段时间就已经处于不良状态^[13-14],将这段时间内的样本视为健康样本是不准确的。




图1 硬盘故障率浴盆曲线

Fig. 1 Bathtub curve for hard disk failure rate

现有的硬盘样本不平衡处理方法主要从数据集和模型两个角度入手。

1)处理数据集类方法可以分为过采样和欠采样两种。过采样即通过重采样、合成样本等手段增加少数类样本;欠采样则是筛选多数类样本,减少冗余。在过采样方法中,回溯法,即将故障前若干天的样本全部视为故障样本,是一种简单且被广泛使用的方法^[9,15-16]。回溯考虑到了硬盘的故障特性,并且简单高效,但每一块硬盘的情况都不尽相同,固定的时间窗口并不能恰好覆盖所有的故障样本。另一类过采样方法是合成故障样本,如SMOTE(Synthetic Minority Oversampling Technique)^[17],ESPO(Enhanced Structure Preserving Over-

sampling)^[18],CTGAN(Condition Tabular Generative Adversarial Networks)^[19]等方法。这类方法主要关注如何扩展确定的故障样本,而没有考虑到硬盘故障前的不准确样本,这对模型的性能和提前预测故障的能力都会造成一定影响。在欠采样方面,可以采用回溯法^[20]、K-means 聚类^[21]、OSS(One Side Selection)^[22]等方法减少健康样本的冗余。由于稳定期的样本冗余较多,简单的欠采样策略就可以达到较好的效果。

2)在模型方面,可以从调整训练方式和目标函数的角度改善不平衡问题,如在训练过程中给予故障样本更高的权重^[23]、构造代价敏感损失函数^[16,24]。此外,一些研究者构建了针对不平衡问题的特殊模型,Zhang 等^[9]使用孪生 LSTM 网络,将故障样本和健康样本成对训练。Zhou 等^[13]采用主动学习策略筛选稳定期样本,同时采用协同训练策略重新确定损耗期样本标签。上述方法虽然能够在不平衡数据集上取得较好的效果,但大多存在着和生成样本方法同样的问题,即没有考虑到损耗期样本的不准确性。

综上所述,目前的硬盘样本不平衡处理方法大多没有充分考虑损耗期的标记不准确问题。如何合理且高效地利用这一部分样本以缓解样本不平衡问题仍需进一步研究。

2.2 分布外硬盘故障预测

随着数据量的不断增大,越来越多新的磁盘型号逐渐进入数据中心以替换老化的磁盘或增加存储系统容量,导致数据中心的存储系统中不可避免地存在数据不足的新硬盘型号,而不同型号硬盘间的数据分布存在一定差异。目前,各类机器学习模型,如决策树^[25]、随机森林^[20]、神经网络^[15]等已被广泛应用到硬盘故障预测任务中^[3-4],但这些模型往往仅能预测训练时出现过的特定型号,在预测未见过的新磁盘型号数据时则无法取得令人满意的结果^[7-9]。

目前已经有一些研究使用迁移学习等方法改善该问题。将训练时的硬盘数据称为源域,将待测试的未知硬盘称为目标域,则这些方法按是否需要目标域数据可以分为两类。

1)在需要目标域数据类方法中,一些方法使用目标域的有标签数据对微调模型,如通过参数迁移方法微调贝叶斯网络^[26]、固定神经网络的部分参数再训练模型^[16]。然而,目标域的标签难以获得,一些方法尝试从无标签数据迁移知识,如筛选分布相近的源域样本训练模型^[21,27]、采用域对抗神经网络(Domain Adversarial Neural Networks, DANN)学习域间共同特征^[7]等。

上述需要目标域数据的方法仅适用于有一定数据积累的硬盘,无法被应用到没有足够数据的新加入硬盘。同时,这类方法对每种硬盘都需要重新训练一个新模型,这对于大规模数据中心而言开销非常大。

2)无需目标域数据的方法则有更好的泛用性。Zhang 等^[9]在分析了硬盘数据的特征后认为基于距离的方法不容易被硬盘型号限制,设计了一种孪生 LSTM 网络以学习健康样本与故障样本之间的差异,在未知硬盘上也取得了较好的效果。Wang 等^[8]将不变风险最小化(Invariant Risk Minimization, IRM)损失加入深度学习方法中,以提取与环境无关的数据特征,改善了模型在未知域上的泛化能力。

这类无需目标域数据的方法在迁移学习中被称为分布外

泛化(Out-of-Distribution Generalization, OODG)或领域泛化(Domain Generalization, DG)。分布外泛化的目标是从一个或多个不同但相关的训练领域中学习一个能够在未见过的测试领域中性能较好的模型^[28]。需要目标域无标记数据的方法则属于领域适应(Domain Adaption, DA),在领域适应问题中可以使用目标域数据帮助训练,但在分布外泛化问题中没有可用的目标域数据。

目前,对于分布外硬盘预测任务的研究还较少,本文旨在针对该任务提出一种新的可行方案。

2.3 近邻传播聚类算法

为了解决 2.1 节中提出的标记不准确问题,本文对损耗期内的样本进行聚类,将与故障样本相似的不确定样本也划归为故障样本,以充分利用损耗期样本。相比回溯法,这种方法更加灵活,能够获取更高质量的故障样本,从而提升模型效果。

在常用的聚类方法中,划分式聚类方法,如文献^[21]采用的 K-means 方法,需要事先指定聚类簇的数目。但在损耗期样本中除了故障外可能还存在着高负载等其他状态,无法直接确定聚类簇数目。

基于密度的聚类方法和层次聚类方法虽然不需要指定聚类簇数目,但对参数和初值的选取以及噪声点较为敏感,而在处理训练集的过程中需要对每块硬盘分别进行聚类操作,针对上千块硬盘分别定制参数较为困难。

相比之下,近邻传播聚类^[29](Affinity Propagation Clustering),即 AP 聚类方法的核心思想是通过在不同的样本点之间不断地传递信息来选择最终的聚类中心,完成聚类过程。该方法无需指定聚类簇数目,对数据的初始值不敏感,平方误差较小。尽管其复杂度较高,但在本文的背景下,仅需在训练模型前进行一次聚类。综合考虑,本文选择了 AP 聚类方法。

2.4 宽度学习系统

宽度学习系统(Broad Learning System, BLS)由 Chen 等^[30]基于随机向量函数链接神经网络(Random Vector Functional Link Neural Network, RVFLNN)^[31]改进而来。BLS 的网络结构如图 2 所示,输入数据首先通过特征映射层进行特征变换;接着,这些被映射的特征被连接到增强层作为增强节点保存在其中;最后,特征节点和增强节点被连接到输出层,通过快速伪逆算法求出输出。如今,越来越多的研究将宽度学习系统与其他神经网络相结合,提出了许多不同的宽度学习系统的变体^[32],也有研究将其用于迁移学习问题^[33-34]。




图 2 宽度学习系统网络结构示意图

Fig. 2 Structure of broad learning system

目前云数据中心的硬盘数量较大,需要模型有较快的运行速度,硬盘迭代较快,即便模型有较强的泛化能力,也需要在新硬盘收集到足够的数量后重新训练。而硬盘的SMART数据采样粒度较大,是一种表格型数据,复杂程度较低。在此背景下,本文基于以下两方面理由选择了宽度学习方法:

1)相比深度学习方法,宽度学习方法在保持训练和预测开销较少的时候,能够保证较高的预测精度^[30]。使用宽度学习能够及时从大量硬盘中检测出故障硬盘,并节约数据中心的算力,需要重新训练时也能快速完成。

2)相比基于树的方法等简单模型,宽度学习存在着类似于深度学习的特征提取过程,能够结合目前迁移学习中的一些分布外泛化方法,提高其对未知数据的泛化能力。

2.5 流形正则化框架

Mikhail等^[35]于2006年提出了一种基于流形学习的正则化框架(Manifold Regularization Framework),其已被广泛应用于无监督和半监督学习中的分类问题。流形正则化框架利用数据边缘分布的几何结构特性,从已标记和未标记数据中挖掘数据的内部流形结构,并将其应用于传统的优化问题中,对问题的解进行进一步约束。

在2.2节中已经提出,不同硬盘之间的数据分布存在差异。这种数据分布的不平滑性可能会导致模型过拟合,降低模型的泛化能力和鲁棒性。流形正则化方法通过惩罚模型在流形上的不平滑性,来提高模型的泛化能力和鲁棒性。在不同硬盘的混合数据集上使用流形正则化,可以帮助模型更好地学习数据分布的流形结构,提高模型对不同硬盘之间数据分布差异的适应能力^[36],缓解硬盘数据集的分布外泛化问题。

3 融合 AP 聚类算法和宽度学习系统的硬盘故障预测模型

3.1 基于 AP 聚类算法的重采样策略

在2.1节中已经提出,故障硬盘在故障发生前就已经处于不良状态,即采集的样本中某些指标可能已经超出正常范围,因此将故障硬盘在损耗期采集的全部样本都视为健康样本是不准确的。重新标记这部分样本不仅可以缓解样本不平衡问题,还能提高模型提前预测故障的能力。

针对上述问题,本文提出了基于 AP 聚类算法的重采样策略。本策略包含两个子策略:1)基于 AP 聚类算法的故障盘样本标记策略,在该子策略中对故障硬盘半健康阶段中的样本进行 AP 聚类,将与故障样本在同一簇内的全部样本设为故障样本,实现正样本过采样;2)基于 AP 聚类算法的健康盘样本筛选策略,在该子策略中对健康硬盘半健康阶段中的样本进行 AP 聚类,取次新聚类簇中的样本作为健康样本,实现负样本欠采样。

总体框架如图3所示,主要包含预处理模块、欠采样模块以及过采样模块。其中,预处理模块用于对原始数据集进行健康盘和故障盘样本划分以及数据预处理;过采样和欠采样模块对应上文提出的两个子策略。

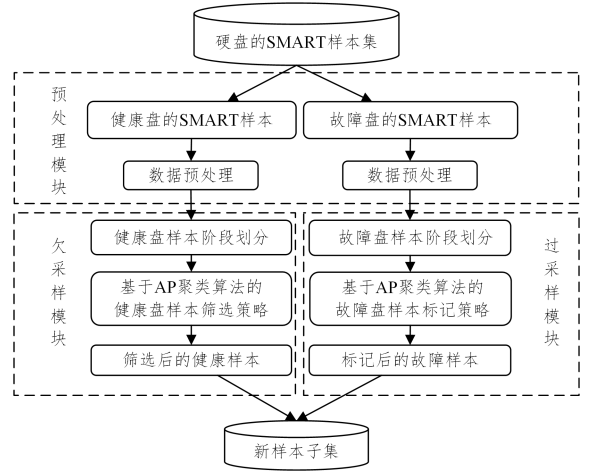


图3 基于 AP 聚类算法的重采样策略

Fig. 3 Resampling strategy based on AP clustering

3.1.1 故障盘样本过采样策略

1)故障盘样本的阶段划分

目前已有一些研究对硬盘划分健康阶段^[13-14],本文基于2.1节中的硬盘故障曲线将故障盘在其生命周期内的全部样本划分为4个阶段,分别为部署、健康、半健康以及故障,如图4所示。其中,部署对应早期故障,健康对应稳定期,半健康对应损耗期,故障为硬盘被诊断为故障后采集的样本。在健康和故障阶段采集的样本的标签是可信的,而半健康状态下采集的样本的标签是不可信的。




图4 故障盘样本的阶段划分

Fig. 4 Stage division of faulty disk samples

2)设定半健康状态窗口 SHW(Semi Healthy Window)

将故障样本以及位于半健康状态窗口内的健康样本作为 AP 算法的输入进行聚类,用 N 表示用于聚类的样本总量。

3)设置 AP 聚类算法参数

AP 聚类算法把样本点之间的相似度作为算法的输入矩阵,并通过测量不同样本点之间的欧氏距离来衡量样本点之间的相似性。位于相似度矩阵 s 对角线上的元素 $s(k, k)$ 为参考度 $preference$,它表示点 k 作为聚类中心的可能程度。参考度的初始值会影响最终形成的聚类簇数目。位于非对角线上的元素 $s(i, k)$ 描述了点 i 与点 k 之间的相似性,表示点 k 作为点 i 的聚类中心的适合程度。本文设定参考度的过程如下:

首先,为所有故障盘设定一个统一参考度初始值 $pref_{raw}$,且 $pref_{raw} > 0$,根据式(1)计算健康样本和故障样本的初始参考度的参考值 $pref'$,当不同故障硬盘的样本量差异较大时,也能够得到适量的聚类簇数目。

$$pref' = \frac{pref_{raw}}{N} \quad (1)$$

其次,根据式(2)一式(4),计算健康样本和故障样本的实际参考度初始值 $pref$,并使用 $pref$ 对 AP 算法进行初始化,完成聚类。

$$pref = \alpha * pref' \tag{2}$$

$$\alpha = Y - 2 \tag{3}$$

$$Y = \begin{cases} 0, & \text{if healthy} \\ 1, & \text{if failure} \end{cases} \tag{4}$$

其中, Y 为样本标签,健康样本标签为 0,故障样本标签为 1, α 为影响因子。由于 AP 聚类算法中采用负的欧氏距离作为样本间的相似性度量,因此 $\alpha < 0$ 。根据式(7)可知,该策略根据影响因子 α 来为故障样本和健康样本设置不同的参考度初始值 $pref$,且 $pref_{failure} > pref_{healthy}$ 。

4)重新标记样本

聚类完成后,将与故障样本处于同一个簇中的全部样本视为故障样本,将这些样本的标签 Y 变更为 1。

5)小结

故障盘样本过采样策略聚焦于半健康阶段样本不可信问题,通过 AP 聚类算法将与故障样本相似性更高的样本标记为故障样本,在扩充了故障样本集的同时保证了故障样本的质量。

3.1.2 健康盘样本欠采样策略

1)健康盘样本的阶段划分

与故障盘不同的是,被视为健康的硬盘中可能存在一部分将会发生故障的硬盘,由于在故障实际发生前还未采集到任何故障样本,它们被错误地归为了健康盘。即健康盘共包含两类:(1)状态良好且能长时间稳定运行的健康盘;(2)状态欠佳,无法长时间稳定运行,即将故障的硬盘。在对健康盘的样本进行划分时,如果是前者,则只包含部署和健康阶段,如图 5 所示;如果是后者,则应该将其划分为部署、健康和半健康阶段,如图 6 所示。




图 5 健康盘样本的阶段划分

Fig. 5 Stage division of healthy disk samples




图 6 即将发生故障的硬盘样本阶段划分

Fig. 6 Stage division of soon-to-fail disk samples

为了保证在进行故障预测时所使用的均为健康样本,其标签是充分可信任的,在健康盘的阶段划分中,假设所有健康盘都是即将发生故障的并为其划分半健康阶段。

2)设定半健康状态窗口 SHW

将处于半健康状态窗口中的所有健康样本作为 AP 算法的输入进行聚类,用 N 表示样本量。

3)设置 AP 聚类算法参数

为所有健康盘设定一个统一参考度初始值 $pref_{raw}$,且 $pref_{raw} > 0$,根据式(5)计算健康样本的参考度的初始值 $pref$,并且每次聚类时只包含健康样本,无需设定不同的参考度初始值,将所有样本一视同仁即可。

$$pref = \frac{pref_{raw}}{N} \tag{5}$$

4)筛选样本

聚类完成后,将成为聚类中心的健康样本按照采样日期排序。最新的聚类中心所在簇中的健康样本可能是在半健康状态下采集的,其标签不可信任,丢弃该部分样本。取次新的聚类中心所在簇中的全部健康样本作为训练样本。

5)小结

根据聚类前的假设,欠采样策略在舍弃一部分标签不可信的最新样本时,也可能舍弃真健康盘中的一些可信的样本。但是,在健康阶段采集的样本呈现出相似的特征,因此即使不是最新的样本,依然可以保留其健康特征。而对于即将发生故障的硬盘,通过舍弃不可信的最新样本的方法可以保留更可信的样本,提高故障预测的准确性。因此,基于 AP 聚类算法的健康盘样本筛选策略可以为硬盘的故障预测挑选更合适、更可信的样本。

3.2 分布外硬盘故障预测模型 MR-BLS

在大多数硬盘故障预测模型中,往往假设测试集和训练集均为同型号或同品牌的硬盘,但在实际场景中,经常需要处理没有训练过的不同型号或品牌的硬盘,并且这些硬盘的 SMART 属性数据都服从不一样的分布,这就要求构建的故障预测模型必须具备跨领域的学习能力。本文在原宽度学习系统的目标优化问题上,利用流形正则化框架帮助模型更好地学习数据分布的流形结构,提高宽度学习系统的跨领域学习能力。

基于流形正则化宽度学习系统的异构硬盘故障预测模型的算法框架如图 7 所示,以下简称 MR-BLS 模型。MR-BLS 包括两个模块:1)不平衡样本集处理模块,通过 3.1 节中提出的基于 AP 聚类算法的重采样策略对原始的不平衡样本集进行重采样以及数据预处理;2)流形正则化宽度学习系统预测模块,硬盘数据经过不平衡样本集处理模块被处理完后,输入宽度学习模型中进行训练。

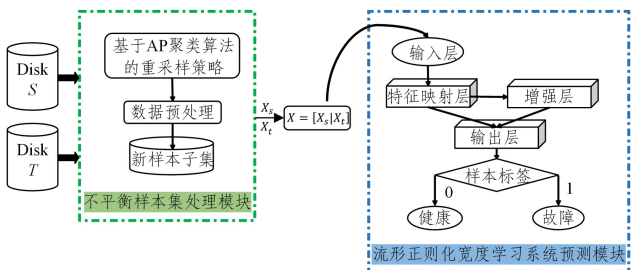


图 7 MR-BLS 模型

Fig. 7 MR-BLS model

为了扩充训练样本数量并学习不同硬盘领域间的不变

特征^[37], MR-BLS 模型可以将多种不同硬盘混合作为训练数据。本文中, 输入数据被限定为两种不同型号硬盘的 SMART 样本 S 和 T 。用 \mathbf{X}_i 和 \mathbf{X}_j 分别表示对这两种型号硬盘样本重采样后的新样本子集, 用 \mathbf{X}_{s_i} 表示预测模型的输入数据, 即 $\mathbf{X}_{s_i} = [\mathbf{X}_i | \mathbf{X}_j]$ 。

MR-BLS 的优化目标和求解过程如下:

1) 对于一个特征层包括 n 组特征节点以及增强层包括 m 组增强节点的 BLS 模型, 其训练过程如下:

根据输入数据 \mathbf{X} , 计算每组特征节点的输出和特征层的输出:

$$\mathbf{Z}_p = \varphi(\mathbf{X}\mathbf{W}_{e_p} + \boldsymbol{\beta}_{e_p}), p = 1, 2, \dots, n \quad (6)$$

$$\mathbf{Z}^n = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n] \quad (7)$$

其中, \mathbf{W}_{e_p} 和 $\boldsymbol{\beta}_{e_p}$ 分别是随机生成的权重矩阵和偏置项, $\varphi(\cdot)$ 为激活函数, \mathbf{Z}_p 为第 p 组特征节点的输出, \mathbf{Z}^n 为特征层的输出。

根据 \mathbf{Z}^n , 计算每组增强节点的输出和增强层的输出:

$$\mathbf{H}_q = \xi(\mathbf{Z}^n \mathbf{W}_{h_q} + \boldsymbol{\beta}_{h_q}), q = 1, 2, \dots, m \quad (8)$$

$$\mathbf{H}^m = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_m] \quad (9)$$

其中, \mathbf{W}_{h_q} 和 $\boldsymbol{\beta}_{h_q}$ 分别是随机生成的权重矩阵和偏置项, $\xi(\cdot)$ 为激活函数, \mathbf{H}_q 为第 q 组增强节点的输出, \mathbf{H}^m 为增强层的输出。

根据 \mathbf{Z}^n 和 \mathbf{H}^m , 计算特征层和增强层的联合输出矩阵 \mathbf{A} :

$$\mathbf{A} = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n | \mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_m] = [\mathbf{Z}^n | \mathbf{H}^m] \quad (10)$$

最后, BLS 的优化目标可以表示为:

$$\arg \min_{\mathbf{W}} \frac{1}{2} \|\mathbf{A}\mathbf{W} - \mathbf{Y}\|^2 + \frac{\theta}{2} \|\mathbf{W}\|^2 \quad (11)$$

其中, \mathbf{W} 为输出层的权重矩阵, \mathbf{Y} 为样本标签, θ 为正则化系数。

2) 若将输入数据 \mathbf{X}_{s_i} 看作一个无向图 $G = (V, E)$, 其中 V 表示图的顶点集合, E 表示图的边集合, 则流形正则化损失的定义如下:

$$\arg \min_{\mathbf{y}} \sum_{\substack{y_i, y_j \\ y_i \neq y_j}} \|y_i - y_j\|^2 \omega_{ij} \quad (12)$$

其中, y_i 表示 x_i 通过 BLS 映射后的低维嵌入, ω_{ij} 表示根据热核函数计算的两点间的相似度。

上述损失函数可以进一步转化为矩阵形式:

$$\text{tr}(\mathbf{W}^T \mathbf{A}^T \mathbf{L} \mathbf{A} \mathbf{W}) \quad (13)$$

其中, $\text{tr}(\cdot)$ 表示矩阵的迹运算, \mathbf{L} 为无向图 G 的拉普拉斯矩阵。 \mathbf{L} 的定义如下:

$$\mathbf{L}(G) = \mathbf{D}(G) - \mathbf{S}(G) \quad (14)$$

其中, $\mathbf{D}(G)$ 被称为无向图 G 的度矩阵, $\mathbf{S}(G)$ 被称为该图的权重邻接矩阵。 $\mathbf{S}(G)$ 以及 $\mathbf{D}(G)$ 可以由以下计算式计算得到:

$$\mathbf{S}(G)_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right), & x_i \in N_k(x_j) \text{ or } x_j \in N_i(x_i) \\ 0, & \text{else} \end{cases} \quad (15)$$

$$\mathbf{D}(G)_{ii} = \sum_j \mathbf{S}(G)_{ij} \quad (16)$$

其中, $N_k(x)$ 表示点 x 的 k 个最近邻点集合。

3) 将上述损失加入到宽度学习的优化目标中, 得到 MR-BLS 的优化目标。

$$\arg \min_{\mathbf{W}} \frac{1}{2} \|\mathbf{A}\mathbf{W} - \mathbf{Y}\|^2 + \frac{\theta}{2} \|\mathbf{W}\|^2 + \frac{\lambda}{2} \text{tr}(\mathbf{W}^T \mathbf{A}^T \mathbf{L} \mathbf{A} \mathbf{W}) \quad (17)$$

其中, λ 为流形正则化系数。

4) 该目标优化问题的解 \mathbf{W} 可根据以下计算式得出:

$$\mathbf{W} = \begin{cases} (\theta \mathbf{I}_{\text{nodes}} + \mathbf{A}^T \mathbf{A} + \lambda \mathbf{A}^T \mathbf{L} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}, & \text{nodes} \leq N \\ \mathbf{A}^T (\theta \mathbf{I}_N + \mathbf{A} \mathbf{A}^T + \lambda \mathbf{L} \mathbf{A} \mathbf{A}^T)^{-1} \mathbf{Y}, & \text{nodes} > N \end{cases} \quad (18)$$

其中, nodes 表示构建的宽度学习系统中所包含的特征节点和增强节点的总数; N 表示输入数据的总样本量; \mathbf{I} 为单位矩阵, 其维度由节点数 nodes 或样本量 N 决定。

4 实验与分析

4.1 数据集

自 2013 年以来, 为用户提供云备份服务的 Backblaze 公司每年都会发布来自其云数据中心的硬盘统计数据和分析报告^[6]。 本文的实验数据选取了 Backblaze 统计的硬盘数据中故障样本较多的 5 种硬盘, 这 5 块硬盘来自希捷、东芝、日立 3 家品牌, 而西部数据品牌的硬盘数量较少, 仅有几十块故障盘, 因此没有选择。 采样时间为 2019 年 1 月—2021 年 12 月, 采集粒度以天为单位。 除了各硬盘的型号、序列号、采样日期、样本标签等基本信息外, 采集的数据还包括各种 SMART 属性的原始值和规范化值。

表 1 列出了所选 5 种型号硬盘的详细信息和数量统计。 分析表中的统计信息可知, 这 5 种硬盘的健康盘都远远多于故障盘, 正负样本之间存在着极端的失衡现象。 实验中为了平衡硬盘在数量上的差异, 从 5 种硬盘的全部健康盘中随机挑选了与它们各自故障盘等数量的健康盘, 将全部故障盘的样本以及被挑选的部分健康盘的样本作为研究对象。

表 1 所选硬盘的详细信息

Table 1 Details of the selected hard disks

硬盘型号	品牌	容量/TB	盘片数	转速	缓存/MB	总硬盘	故障硬盘	健康硬盘
ST12000NM0007	希捷	12	8	7 200	256	38 539	1 639	36 900
ST4000DM000	希捷	4	4	5 900	64	23 396	1 009	22 387
ST8000NM0055	希捷	8	6	7 200	256	14 997	609	14 388
HMS5C4040BLE640	日立	14	9	7 200	256	14 664	130	14 534
MG07ACA14TA	东芝	14	9	7 200	256	38 574	355	38 219

4.2 评估指标

对于故障预测的提前时长, 本文参考了阿里巴巴 PA-KDD2020 智能运维大赛^[38] 的评估标准, 以 30 天内硬盘是否会出现故障为准。 本文使用以下 6 个指标评估硬盘故障预测方法的性能。

1) 精确度 (Accuracy): 表示预测结果为正确的样本数占总样本数的比例。 该指标适用于类别平衡的数据集, 当数据集类别不平衡时该指标会变得不可靠。

2) 查准率 (Precision): 在所有被预测为正例的样本中, 真实为正例的样本所占的比例。

3)查全率(Recall):在所有真实为正例的样本中,被模型正确预测为正例的样本所占的比例。

4)F1_Score:查准率和查全率是一对矛盾的指标,当查准率高时查全率往往偏低,相反,当查准率低时查全率往往偏高。使用查准率和查全率的调和平均值构成的指标被称为F1_Score,该指标可以更全面地评估模型对正例的综合性能。

5)G_Mean:为正样本查全率和负样本查全率的几何平均数,该指标同时考虑了正样本和负样本的查全效果,更能衡量模型在不平衡数据集上的性能。

6)MCC:全称为马修相关系数(Matthews Correlation Coefficient),该指标综合考虑了预测结果的真阳性(TP)、真阴性(TN)、假阳性(FP)以及假阴性(FN),通常被认为是一个较为全面的衡量指标,当两种类别的样本量相差较大时也能很好地进行评估^[39],其计算式如下:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (19)$$

4.3 不平衡数据集重采样实验结果和分析

4.3.1 重采样对比方法

为了验证基于 AP 聚类算法的重采样策略的有效性,重采样部分对比了稳健健康度采样方法^[14]和回溯法^[9,15-16]。稳健健康度采样方法采用与本文相似的硬盘样本阶段划分策略,基于 PCA 方法计算同一硬盘各样本的异常度,剔除异常样本获得稳定的健康样本。原方法仅用于对健康样本下采样,为了进行对比,本文将该方法扩展到故障样本和健康样本的重采样。回溯法指根据采集的最后一條样本,按照指定

天数回溯之前的采集样本,如果是故障盘,则将回溯的健康样本进行重新标记并作为实验数据中的正样本;如果是健康盘,则将回溯的健康样本作为实验数据中的负样本。为了方便表述,实验中将基于 AP 聚类算法的重采样策略简称为 AP 法,将基于稳健健康度采样方法简称为 PCA 法,将回溯法简称为 BT 法。

4.3.2 参数设定

AP 法的统一参考度初始值 $pref_{raw}$ 的取值范围设定为 [50,500],以 50 为步长进行搜索,通过比较方差比准则筛选最优值。AP 法和 PCA 法的半健康状态窗口 SHW 以及 BT 法的回溯天数均设为 45 和 60。

4.3.3 测试方法

为了评估不同数据集的采样质量,本文选取了 BLS, KNN^[40],GBDT^[41]和 XGBoost^[42],LGBM^[43]模型在各个数据集上进行实验,模型的关键参数均通过网格搜索调整。以 5 种模型在不同数据集上得到的评估指标的平均值作为评价数据集的标准。

4.3.4 实验数据

本节实验采用数据量最大的硬盘 ST4000DM000。通过 AP,BT,PCA 方法重采样后的 6 个样本子集分别用 DM000-AP-45, DM000-AP-60, DM000-PCA-45, DM000-PCA-60, DM000-BT-45,DM000-BT-60 来表示,并分别称为 AP 数据集、PCA 数据集、BT 数据集。重采样后的健康样本量和故障样本量如表 2 所列。其中,“窗口”值在 AP 法和 PCA 法中表示半健康状态窗口 SHW,在 BT 法中表示指定的回溯天数。

表 2 ST4000DM000 硬盘重采样后样本数和保留的 SMART 特征

Table 2 Sample size and retained SMART features after resampling on ST4000DM000

采样方法	窗口	故障样本	健康样本	Normalized	Raw
AP	45	5 874	5 360	188,193,197	4,9,12,188,193,198,240,241,242
	60	9 178	9 749	188,193,197	4,9,12,190,193,197,198,240,241
PCA	45	5 178	6 031	188,193	4,9,12,188,192,193,197,198,241,242
	60	6 136	8 929	188,193	4,9,12,188,193,197,198,240,241,242
BT	45	45 149	45 139	188,190,193	4,9,12,188,190,193,240,241,242
	60	59 318	59 666	188,190,193	4,9,12,188,190,193,240,241,242

将上述样本子集分别划分为训练集和测试集。例如,使用样本子集 DM000-AP-45 时,首先将全部故障硬盘按 7:3 的比例随机进行划分,然后将前者的全部故障样本作为训练集中的正样本,将后者的故障发生后 30 天内的样本作为测试集中的正样本。类似地,将全部健康盘也按 7:3 的比例随机进行划分,然后将前者的全部健康样本作为训练集中的负样本,将后者的全部健康样本作为测试集中的负样本。

4.3.5 特征选择

不平衡数据集在重采样后还需要进一步的数据预处理步骤,主要包括缺失值填补、归一化以及特征选择。

在特征选择阶段中使用递归消除法对数据进行降维,关于保留特征数,本文通过对比 LGBM 模型在不同保留特征数的 AP 数据集上的 F1_score 来确定。

从图 8 中可以看出,保留特征维度的变化对模型效果的影响并不大,在从 20 维降至 5 维的过程中,仅有约 0.02 的变化,这说明 SMART 特征存在一定的冗余。在保留特征数从

20 降至 11 的过程中,模型效果有一定的波动,但基本保持平稳,在从 11 降至 10 时出现了一定的下降,此后再次保持稳定。可以认为,保留 11 个特征时模型能够兼顾效率和性能,考虑到不同的样本子集可能存在一定差异,本文选择多保留一个冗余特征,即保留 12 个特征,各个样本集选择的特征如表 2 所列。

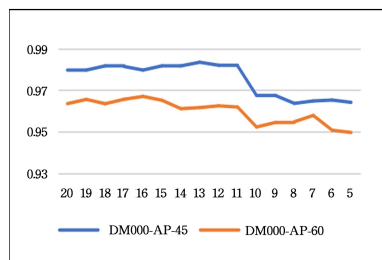


图 8 LGBM 在不同保留特征数的 AP 数据集上的 F1_score
Fig. 8 F1_score of LGBM on AP subsets with different numbers of retained features

4.3.6 不同样本子集上的实验结果与分析

将5种模型分别在上述6个样本子集上进行实验后,各样本子集上的5种模型的评估指标的平均结果如图9所示。可以看出,AP数据集在各项指标上均优于PCA数据集和BT数据集。其中,Accuracy和Precision指标的优势明显,这说明在AP数据集上训练得到的模型检出故障的精确度很高。但较高的精确度导致模型会漏检部分故障样本,这导致在Recall指标上的优势较小。而从F1_Score来看,AP数据集上Precision和Recall综合性能仍有很大优势。最后,从综合指标MCC来看,AP数据集的效果优于PCA和BT数据集。

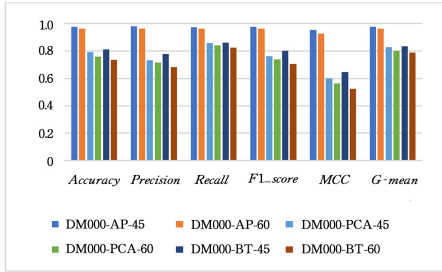


图9 5种模型在各样本子集上的平均结果

Fig. 9 Average results of five models on each subset

从另一角度,对比各种方法在45和60两种窗口大小下的实验结果可以发现,尽管样本数量有一定的增加,但各项指标均有一定的下降,而AP方法的下降较小。对此,本文对AP法进一步扩大窗口到100,200进行实验,实验结果如图10所示。可以看出,在时间窗口进一步扩大的情况下,AP法的各项指标依然能够保持稳定,降幅均在0.04以内。




图10 半健康状态窗口对AP法的影响

Fig. 10 Impact of semi healthy window on AP

上述现象说明样本量越多并不表示模型能够学习到的信息就越多,模型最终效果与训练样本的质量也存在一定的关联。在窗口增大的过程中,PCA和BT方法引入了不可靠的故障样本,导致模型性能下降。而AP数据集在窗口增大的过程中,模型性能基本保持稳定,这说明AP法能够稳健地获取可靠的故障样本,不会受到样本在时间跨度上的干扰,对半健康窗口的设定没有严格要求。总体而言,基于AP聚类算法

的重采样策略所选的样本质量比PCA法和BT法选择的样本质量更高。

从方法机理上分析,BT法简单引入故障前样本,虽然大大扩充了样本量,但没有对样本进行筛选,导致非故障样本也被引入,对模型性能造成了一定影响。PCA方法在获取健康样本上比较有效,但在获取故障样本方面,该方法仅关注样本的异常程度,而没有利用故障后样本这一关键信息,包括正常运行过程中的硬盘高负载等特殊样本也会被判定为异常样本,导致得到的样本并不全是故障样本,干扰了模型的判别。而AP法则充分利用了故障后样本,聚类得到的样本保持了与故障后样本的相似性,因此AP法更加稳健。

4.4 分布外硬盘故障预测实验结果与分析

从4.3节中的实验结果可以看出,同分布的硬盘故障预测实际上是一个较为简单的任务,主要的困难在于对样本的合理重采样,即不同的采样方法是影响模型性能的主要因素。图11给出了各种方法在DM000-AP-100上的对比结果。可以看出,在AP样本集质量较高的情况下,所有方法已经能够达到非常高的精度。在此基础上,BLS模型在Recall,F1_Score,MCC,G-mean这4项指标上有较好的表现,这说明BLS模型在正样本和负样本的查全性能上均有较好的表现,而准确率稍有欠缺。总体而言,BLS在简单的同构硬盘故障检测任务中尽管在一些指标上能够取得最优,但优势并不明显。而本文选取BLS的原因主要在于其拥有较快的速度,同时有更强的泛化能力和可扩展性,这将在本节中进行分析。

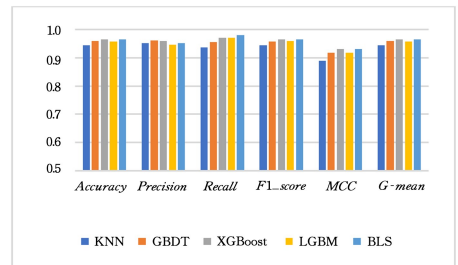


图11 5种方法在DM000-AP-100上的结果对比

Fig. 11 Result comparison of five methods on DM000-AP-100

4.4.1 实验数据与参数设定

在异构硬盘的故障预测实验中,选取故障样本数量最多的希捷ST12000NM0007和希捷ST4000DM000两种硬盘作为训练集,选取样本数量较少的ST8000NM0055,HMS5C4040BLE640和MG07ACA14TA作为测试集,以评估模型在不同型号和不同品牌硬盘上的领域泛化能力。以上样本均使用AP法以100为半健康状态窗口进行重采样。重采样后的样本数和保留的SMART特征如表3所列,由于测试硬盘在训练过程中不可见,因此没有筛选特征的过程。

表3 各硬盘重采样后样本数和保留的SMART特征

Table 3 Sample size and retained SMART features after resampling on each disk

硬盘型号	品牌	故障样本	健康样本	Normalized	Raw
ST12000NM0007	希捷	10225	9697	5,187,188,190,195,198	4,9,12,192,241,242
ST4000DM000	希捷	6286	6068	188,193,197	4,9,12,188,193,197,198,240,241
ST8000NM0055	希捷	3834	3234	—	—
HMS5C4040BLE640	日立	845	933	—	—
MG07ACA14TA	东芝	2148	2574	—	—

各个样本子集的特征选择方法与同构硬盘故障预测实验中描述的一致,由于使用了两块不同型号硬盘进行训练,因此将两块硬盘分别进行特征降维后,选取其并集作为最终特征。

MR-BLS的各项参数如特征层节点、增强层节点都需要

手动确定,不同的参数设定可能会对模型产生较大影响。得益于 MR-BLS 较快的训练速度,本节实验中对 MR-BLS 模型中的重要参数使用网格搜索进行调整,具体的搜索范围如表 4 所列。

表 4 MR-BLS 参数设定
Table 4 MR-BLS parameter settings

参数	设置	
拉普拉斯矩阵	$N_k(x)$ $k=10$	
流形正则化系数	θ [10-10,10]范围内对指数以 1 为步长搜索 λ [10-5,10]范围内对指数以 1 为步长搜索	
宽度学习系数	收缩参数 s	[0.5,1.5]范围内以 0.1 为步长搜索
	特征层窗口数 $N1$	[10,100]范围内以 10 为步长进行搜索
	特征节点数 $N2$	[50,500]范围内以 10 为步长进行搜索
	增强层窗口数 $N3$	[10,20]范围内以 5 为步长进行搜索
	增强节点数 $N4$	[50,500]范围内以 50 为步长进行搜索

对比方法同样选取了能够快速完成训练过程的 KNN^[40],GBDT^[41]和 XGBoost^[42]和 LGBM^[43]模型。

4.4.2 同品牌不同型号硬盘实验

该组实验选取同为希捷品牌的 ST8000NM0055 硬盘作为测试集,以测试模型在同品牌不同型号硬盘上的领域泛化能力。从表 1 中可以看出,3 块硬盘在容量、盘片、转速、缓存上均有异构之处。实验结果如表 5 所列。

表 5 希捷 ST8000NM0055 硬盘的实验结果

Table 5 Experimental results on Seagate ST8000NM0055

模型	Accuracy	Precision	Recall	F1_Score	G_mean	MCC
MR-BLS	0.958	0.979	0.935	0.956	0.957	0.917
BLS	0.951	0.927	0.971	0.949	0.953	0.903
KNN	0.900	0.940	0.854	0.895	0.899	0.804
GBDT	0.777	0.702	0.967	0.813	0.752	0.599
XGBoost	0.884	0.836	0.957	0.892	0.881	0.776
LGBM	0.894	0.854	0.951	0.900	0.892	0.793

KNN 方法在 Precision 指标上超过了 BLS 方法,但落后于 MR-BLS 方法,GBDT,XGBoost,LGBM 方法则是在 Recall 指标上超过了 MR-BLS 方法,但落后于 BLS 方法。但是,这些方法兼顾这两个指标的性能较差。从综合指标 F1_Score 来看,BLS 系列方法明显领先于对比方法有至少 0.05 的优势。而在 Accuracy,G-Mean,MCC 指标上,BLS 系列方法也明显优于对比方法。这充分说明了 BLS 系列方法在该任务上的优越性。

具体到 BLS 和 MR-BLS 这两种方法,可以看到 BLS 本身就取得了非常好的效果,而 MR-BLS 也有一定的提升。其中,MR-BLS 的 Accuracy 和 Precision 指标最优,这说明在 MR-BLS 检出故障的精确度很高。相对地,Recall 指标弱于其他模型,但差距较小。从 F1_Score 来看,MR-BLS 的预测故障的综合性能仍然更高。

综合而言,非神经网络方法的泛化能力较弱,而 BLS 方法在同品牌不同型号硬盘的任务上拥有较强的分布外泛化能力,加入流形正则化的 MR-BLS 的泛化能力得到进一步提升。

4.4.3 不同品牌硬盘实验

该组实验选取日立品牌的 HMS5C4040BLE640 硬盘和东芝品牌的 MG07ACA14TA 硬盘分别作为测试集,以测试模型在不同品牌硬盘上的领域泛化能力。

在 HMS5C4040BLE640 硬盘上的实验结果如表 6 所列。在该任务中,由于数据集的差异增大,各模型的性能都出现了一定程度的退化。在此基础上,BLS 系列方法相比对比方法的优势更加明显。在各项指标中,仅有 GBDT 方法在 Recall 指标上接近 MR-BLS 方法,但仍落后于 MR-BLS 约 0.01,在其他指标上,BLS 系列方法均大幅领先于对比方法。

表 6 日立 HMS5C4040BLE640 硬盘的实验结果

Table 6 Experimental results on HGST HMS5C4040BLE640

模型	Accuracy	Precision	Recall	F1_Score	G_mean	MCC
MR-BLS	0.832	0.932	0.796	0.859	0.845	0.668
BLS	0.779	0.761	0.867	0.811	0.764	0.554
KNN	0.628	0.648	0.699	0.673	0.616	0.245
GBDT	0.612	0.551	0.781	0.646	0.607	0.262
XGBoost	0.768	0.851	0.594	0.699	0.736	0.543
LGBM	0.768	0.763	0.708	0.734	0.761	0.530

具体到 BLS 和 MR-BLS 这两种方法,MR-BLS 的性能优势相比同品牌实验更加明显。其中,MR-BLS 的 Accuracy 和 Precision 指标优势显著,Precision 更是超过了 0.9。与上组实验类似,Recall 指标弱于其他模型,但从 F1_Score 来看,MR-BLS 的预测故障的综合性能仍然更高。

在 MG07ACA14TA 硬盘上的实验结果如表 7 所列。该硬盘相比 HMS5C4040BLE640 的泛化难度更高,各个模型的性能均出现了下降,特别是 KNN 和 LGBM 出现了明显的退化。与前几组实验类似的是,MR-BLS 取得了超过 0.9 的 Precision,但 Recall 指标弱于 GBDT 和 XGBoost 方法,综合的 F1_Score 指标则更优。

表 7 东芝 MG07ACA14TA 硬盘的实验结果

Table 7 Experimental results on Toshiba MG07ACA14TA

模型	Accuracy	Precision	Recall	F1_Score	G_mean	MCC
MR-BLS	0.654	0.914	0.628	0.744	0.691	0.310
BLS	0.670	0.649	0.877	0.746	0.605	0.335
KNN	0.437	0.468	0.156	0.234	0.350	-0.080
GBDT	0.544	0.495	0.769	0.602	0.527	0.140
XGBoost	0.590	0.533	0.709	0.608	0.591	0.205
LGBM	0.584	0.584	0.256	0.356	0.467	0.135

与在 HMS5C4040BLE640 上的实验不同的是,MR-BLS 在该任务中相比 BLS 尽管取得了超过 0.9 的 Precision,但其他指标弱于 BLS,从 F1_Score 和 MCC 来看,MR-BLS 的整体

性能稍弱于 BLS。

综合本节的两个实验来看,由于不同品牌的 SMART 数据差异较大,各种方法的性能均出现了一定程度的下降,这说明不同品牌硬盘的领域泛化任务确实存在较大的挑战,而 BLS 和 MR-BLS 方法相比对比方法均有一定的优势。

在日立品牌的实验中,MR-BLS 比 BLS 的效果更好,这说明流形正则化能够强化 BLS 模型面对分布外数据的泛化能力。但是,在东芝品牌实验中,尽管 MR-BLS 在 Precision 指标上取得了非常好的效果,但其整体性能并没有取得提升,这说明并不是在所有硬盘型号上都能通过流形学习提取通用特征,提高泛化能力。

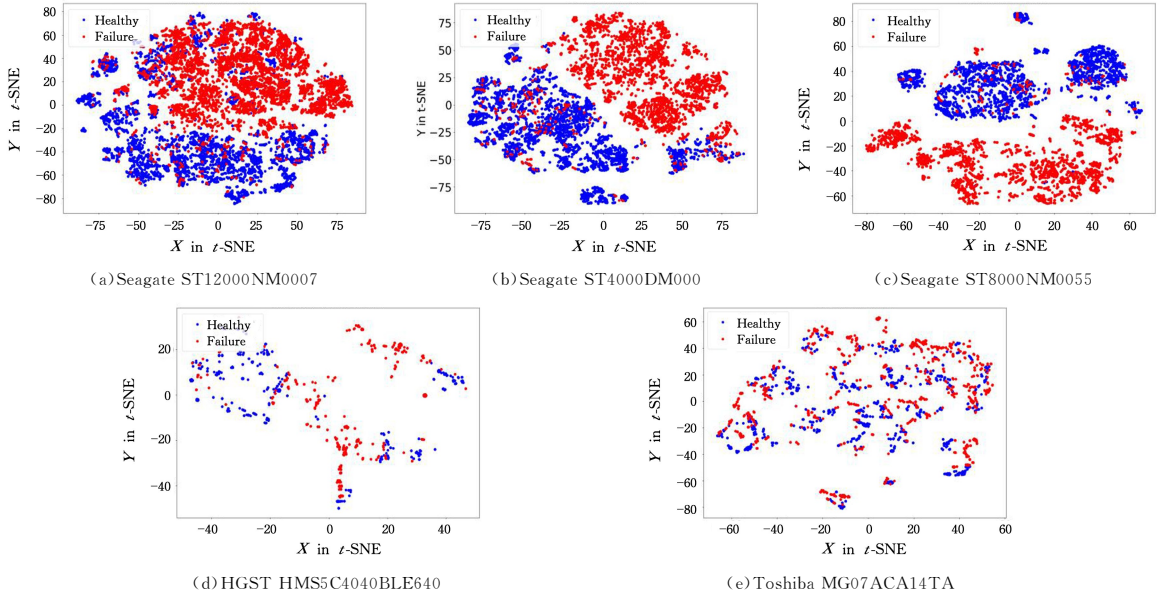


图 12 5 块硬盘样本经 T-SNE 降维后的分布情况

Fig. 12 Distribution of five hard disk samples after T-SNE dimensionality reduction

日立品牌的 HMS5C4040BLE640 与希捷品牌的 3 块硬盘相比表现出了一定的流形差异,这就要求模型有更强的泛化能力。BLS 不足以胜任该任务,而加入了流形正则化的 MR-BLS 能更好地学习到不同硬盘间的相似流形结构,从而提升其泛化能力,在该任务中表现出了最佳的性能。

而东芝品牌的 MG07ACA14TA 分布与其他品牌的硬盘明显存在非常大的差异,这解释了在表 7 的实验结果中所有模型效果均出现了较大幅度下降的原因。同时,较大的流形差异也意味着没有通用特征可以学习,导致 MR-BLS 相比 BLS 在整体性能上没有取得提升。

结束语 本文针对硬盘故障预测任务,使用 AP 聚类算法解决了正负样本的不平衡问题,使用宽度学习和流行正则化解决了分布外硬盘故障预测问题。

本文提出的基于 AP 聚类算法的重采样策略在不平衡数据集重采样实验中验证了其有效性。该方案充分利用硬盘的历史数据,考虑了不同阶段中硬盘的状态,通过聚类算法自适应地筛选合适的故障样本与健康样本。与“一刀切”的回溯法相比,本策略更加灵活;与稳健健康度采样法相比,它更适用于故障样本的重采样。

本文提出的分布外硬盘故障预测模型 MR-BLS 通过流形正则化进一步增强了 BLS 模型的泛化能力。实验结果

4.4.4 实验结果分析

图 12 给出了本章实验所用的 5 块硬盘的样本经 T-SNE 降至二维后的分布情况,可以在一定程度上反映数据的流形结构。可以看到,5 块硬盘的样本分布均有一定程度的差异。同为希捷品牌的 ST12000NM0007, ST4000DM000, ST8000NM0055 这 3 块硬盘的流形结构尽管不完全相同,但均有一条弧形分界线,有一定的相似性,因此对泛化能力的要求相对较低。BLS 在该问题上取得了较好的效果,说明 BLS 相对于非神经网络方法有更强的泛化能力,而 MR-BLS 相对 BLS 提升较小,说明 BLS 的泛化能力基本已经能够满足这种具有类似分布的领域泛化问题。

表明,MR-BLS 在处理训练数据中未出现的同品牌 and 不同品牌硬盘时均有明显的优势。

本文的研究还存在着以下不足和挑战:

1) 尽管 AP 法对半健康窗口的大小不敏感,但半健康窗口的确定仍需要明确的标准。针对硬盘在彻底故障前多久会出现故障特征,还需要对其样本进行进一步分析。

2) 在构建 MR-BLS 的过程中,对其重要参数采用了网格搜索的方式确定。但在实验过程中发现,不同的参数组合有时会对模型产生较大的影响。如何提高模型的稳定性或使用自适应的方式确定参数仍需进一步研究。

3) 结合 4.4.3 节的实验可以看出,并不是所有的硬盘型号都能使用流形学习来提升预测效果,面对一些数据分布差异极大的硬盘数据,流形学习也不能取得很好的泛化效果。针对此类硬盘如何提高泛化能力还需进一步尝试。


总而言之,MR-BLS 为分布外故障检测提供了一种新的思路。能否将 BLS 更换成深度学习等模型,或将流形学习更换为其他领域的泛化策略仍需进一步探索。

参考文献

- [1] GHEMAWAT S, GOBIOFF H, LEUNG S T. The Google file system[C]//Proceedings of the Nineteenth ACM Symposium on

- Operating Systems Principles. New York: Association for Computing Machinery, 2003: 29-43.
- [2] ZHANG H, TANG D, CAI H L. Study on Predictive Erasure Codes in Distributed Storage System[J]. Computer Science, 2021, 48(5): 130-139.
- [3] MURRAY J F, HUGHES G F, KREUTZ-DELGADO K, et al. Machine Learning Methods for Predicting Failures in Hard Drives; A Multiple-Instance Application[J]. Journal of Machine Learning Research, 2005, 6(27): 783-816.
- [4] TOMER V, SHARMA V, GUPTA S, et al. Hard disk drive failure prediction using SMART attribute[J]. Materials Today: Proceedings, 2021, 46(20): 11258-11262.
- [5] GAO X, ZHA S, LI X, et al. Incremental Prediction Model of Disk Failures Based on the Density Metric of Edge Samples[J]. IEEE Access, 2019, 7: 114285-114296.
- [6] BACKBLAZE. Backblaze Hard Drive Data and Stats[EB/OL]. <https://www.backblaze.com/b2/hard-drive-test-data.html>.
- [7] ZHAO R, GUAN D, JIN Y, et al. Hard Disk Failure Prediction via Transfer Learning[C]// Big Data and Security. Singapore: Springer, 2021: 522-536.
- [8] WANG J, ZHANG R, QI G, et al. A Heuristic-IRM Method on Hard Disk Failure Prediction in Out-of-distribution Environments[C]// 2021 IEEE International Conference on Industrial Engineering and Engineering Management. Singapore: IEEE, 2021: 1661-1664.
- [9] ZHANG J, HUANG P, ZHOU K, et al. Hddse: Enabling high-dimensional disk state embedding for generic failure detection system of heterogeneous disks in large data centers[C]// Proceedings of the 2020 USENIX Conference on Usenix Annual Technical Conference. USA: USENIX Association, 2020: 111-126.
- [10] ZHAO N, ZHANG X F, ZHANG L J. Overview of Imbalanced Data Classification[J]. Computer Science, 2018, 45(6A): 22-27.
- [11] SMITH R W, DIETRICH D L. The bathtub curve: an alternative explanation[C]// Proceedings of Annual Reliability and Maintainability Symposium. USA: IEEE, 1994: 241-247.
- [12] SCHROEDER B, GIBSON G A. Understanding disk failure rates[J]. ACM Transactions on Storage, 2007, 3(3): 8.
- [13] ZHOU Y, WANG F, FENG D. ASLDP: An Active Semi-supervised Learning method for Disk Failure Prediction[C]// 50th International Conference on Parallel Processing. New York: Association for Computing Machinery, 2021: 1-11.
- [14] ZHOU H, NIU Z, WANG G, et al. A Proactive Failure Tolerant Mechanism for SSDs Storage Systems based on Unsupervised Learning[C]// 2021 IEEE/ACM 29th International Symposium on Quality of Service. Tokyo: IEEE, 2021: 1-10.
- [15] ZHU B, WANG G, LIU X, et al. Proactive drive failure prediction for large scale storage systems[C]// 2013 IEEE 29th Symposium on Mass Storage Systems and Technologies. Long Beach: IEEE, 2013: 1-5.
- [16] SUN X, CHAKRABARTY K, HUANG R, et al. System-level hardware failure prediction using deep learning[C]// 2019 56th ACM/IEEE Design Automation Conference. Las Vegas: IEEE, 2019: 1-6.
- [17] BURRELLO A, PAGLIARI D J, BARTOLINI A, et al. Predicting Hard Disk Failures in Data Centers Using Temporal Convolutional Neural Networks[C]// Euro-Par 2020: Parallel Processing Workshops. Cham: Springer, 2021: 277-289.
- [18] ZÜFLE M, KRUPITZER C, ERHARD F, et al. To fail or not to fail: Predicting hard disk drive failure time windows[C]// Measurement, Modelling and Evaluation of Computing Systems. Cham: Springer, 2020: 19-36.
- [19] JIA J, WU P, ZHANG K, et al. Imbalanced Disk Failure Data Processing Method Based on CTGAN[C]// Intelligent Computing Theories and Application. Cham: Springer, 2022: 638-649.
- [20] SHEN J, WAN J, LIM S J, et al. Random-forest-based failure prediction for hard disk drives[J]. International Journal of Distributed Sensor Networks, 2018, 14(11): 1-15.
- [21] BOTEZATU M, GIURGIU I, BOGOJESKA J, et al. Predicting disk replacement towards reliable data centers[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2016: 39-48.
- [22] RINCÓN C A C, PARIS J F, VILALTA R, et al. Disk failure prediction in heterogeneous environments[C]// 2017 International Symposium on Performance Evaluation of Computer and Telecommunication Systems. Seattle: IEEE, 2017: 113-119.
- [23] XIAO J, YI Y, XIONG Z, et al. Disk failure prediction in data centers via online learning[C]// Proceedings of the 47th International Conference on Parallel Processing. New York: Association for Computing Machinery, 2018: 1-10.
- [24] XU Y, SUI K, YAO R, et al. Improving service availability of cloud systems by predicting disk error[C]// Proceedings of the 2018 USENIX Conference on Usenix Annual Technical Conference. USA: USENIX Association, 2018: 481-494.
- [25] LI J, JI X, JIA Y, et al. Hard drive failure prediction using classification and regression trees[C]// 2014 44th Annual IEEE/IFIP International Conference on Dependable Systems and Networks. Atlanta: IEEE, 2014: 383-394.
- [26] PEREIRA F L F, DOS SANTOS LIMA F D, DE MOURA LEITE L G, et al. Transfer learning for Bayesian networks with application on hard disk drives failure prediction[C]// 2017 Brazilian Conference on Intelligent Systems. Uberlandia: IEEE, 2017: 228-233.
- [27] XIE Y, FENG D, WANG F, et al. OME: An Optimized Modeling Engine for Disk Failure Prediction in Heterogeneous Data Center[C]// 2018 IEEE 36th International Conference on Computer Design. Orlando: IEEE, 2019: 561-564.
- [28] WANG J, LAN C, LIU C, et al. Generalizing to Unseen Domains: A Survey on Domain Generalization[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 8052-8072.
- [29] FREY B J, DUECK D. Clustering by Passing Messages Between Data Points[J]. Science, 2007, 315(5814): 972-976.
- [30] CHEN C L P, LIU Z. Broad Learning System: An Effective and Efficient Incremental Learning System Without the Need for Deep Architecture[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.

- [31] PAO Y H, PARK G H, SOBAJIC D J. Learning and generalization characteristics of the random vector functional-link net[J]. *Neurocomputing*, 1994, 6(2): 163-180.
- [32] CAI X Y, FENG X, YU H Q. Adaptive Weight Based Broad Learning Algorithm for Cascaded Enhanced Nodes[J]. *Computer Science*, 2022, 49(6): 134-141.
- [33] PENG C, CHUNHAO D. Monitoring multi-domain batch process state based on fuzzy broad learning system[J]. *Expert Systems with Applications*, 2022, 187: 115851.
- [34] LIU B, ZENG X, TIAN F, et al. Domain Transfer Broad Learning System for Long-Term Drift Compensation in Electronic Nose Systems[J]. *IEEE Access*, 2019, 7: 143947-143959.
- [35] BELKIN M, NIYOGI P, SINDHWANI V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples[J]. *The Journal of Machine Learning Research*, 2006, 7: 2399-2434.
- [36] NG N, HULKUND N, CHO K, et al. Predicting Out-of-Domain Generalization with Local Manifold Smoothness [J]. *arXiv: 2207. 02093*, 2022.
- [37] LU W, WANG J, SUN X, et al. Out-of-distribution Representation Learning for Time Series Classification[C]// *The Eleventh International Conference on Learning Representations*. Kigali: OpenReview. net, 2023; 1-21.
- [38] PENG Y, XU J, ZHAO N. Noise Feature Selection Method in PAKDD 2020 Alibaba AI Ops Competition: Large-Scale Disk Failure Prediction[C]// *Large-Scale Disk Failure Prediction*. Singapore: Springer, 2020: 109-118.
- [39] CAHYADI, FORSHAW M. Hard Disk Failure Prediction on Highly Imbalanced Data using LSTMNetwork[C]// *2021 IEEE International Conference on Big Data*. Orlando: IEEE, 2021: 3985-3991.
- [40] PITAKRAT T, VAN HOORN A, GRUNSKÉ L. A comparison of machine learning algorithms for proactive hard disk drive failure detection[C]// *Proceedings of the 4th International ACM Sigsoft Symposium on Architecting Critical Systems*. New York: Association for Computing Machinery, 2013: 1-10.
- [41] FRIEDMAN J H. Greedy function approximation : a gradient boosting machine[J]. *Annals of Statistics*, 2001, 29(5): 1189-1232.
- [42] CHEN T, GUESTRIN C. XGBoost: A scalable tree boosting system[C]// *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: Association for Computing Machinery, 2016: 785-794.
- [43] KE G, MENG Q, FINLEY T, et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree[C]// *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach: Curran Associates Inc, 2017: 30.



WANG Yiyang, born in 1999, postgraduate. His main research interest is cloud computing.



ZHONG Guoxiang, born in 1994, Ph.D. His main research interests include cloud computing, AIOps and machine learning.

(责任编辑:喻藜)