

基于 AE-LSTM 的多目标硬盘故障预测方法

王东清, 张炳会, 彭继阳, 艾山彬, 王兵, 姚藩益, 芦飞, 张凯
(浪潮电子信息产业股份有限公司, 北京 100085)

摘要: 硬盘故障预测是在故障发生前发出预警, 避免数据丢失或服务中断, 提高数据中心的可靠性和安全性; 然而, 大多数故障预测模型将硬盘故障问题转化为二分类任务, 忽略了硬盘故障是渐变过程的, 并且缺乏故障诊断功能; 因此, 提出了一种基于 AE-LSTM 的硬盘故障预测框架, 实现多目标任务: 硬盘健康状态分级、硬盘剩余使用寿命预测、硬盘故障诊断; 采用回归决策树模型智能化对硬盘健康状态进行标记, 并通过 AE-LSTM 模型提取鲁棒的隐藏变量, 构建剩余使用寿命预测模型和硬盘健康状态分级模块, 根据 AE 模块的输入输出差异进行硬盘故障诊断; 在 Backblaze 公开数据集上, 对比了 RF、LSTM 和 AE-LSTM 三种算法, 实验结果证实了 AE-LSTM 算法在多目标硬盘故障预测中的有效性和优势。

关键词: 硬盘故障预测; 硬盘故障诊断; 剩余使用寿命; 长短期记忆单元; 自编码器

Multi-objective HDD Failure Prediction Method Based on AE-LSTM

WANG Dongqing, ZHANG Binghui, PENG Jiyang, AI Shanbin,
WANG Bing, YAO Fanyi, LU Fei, ZHANG Kai
(Inspur Electronic Information Industry Co., Ltd., Beijing 100085, China)

Abstract: Hard disk drive (HDD) failure prediction is used to avoid data loss or service interruption, which sends a warning before HDD failures occur, it improves the reliability and security of data center. However, most HDD failure prediction models convert HDD failures into binary classification tasks, ignoring the gradual deterioration of HDD and lacking of fault diagnosis function. Therefore, an HDD failure prediction method based on auto encoder and long short term memory (AE-LSTM) is proposed to achieve the HDD multi-objective tasks of health status multi-classification, remaining useful life (RUL) prediction, and fault diagnosis. The regression decision tree model is used to intelligently label the HDD health status. Then, the robust hidden variables are extracted through the AE-LSTM model, the RUL model and HDD health status classification model are built. The HDD fault diagnosis is implemented by computing the difference between the input and output of the AE module. By evaluating the random forest (RF), LSTM and AE-LSTM algorithms on the Backblaze public dataset, the experimental results show that the AE-LSTM algorithm has the effectiveness and advantages in multi-objective HDD failure prediction.

Keywords: hard drive failure prediction; hard drive fault diagnosis; remaining useful life; LSTM; AE

0 引言

近年来, 随着大数据、云计算、5 G 等技术的快速发展, 数据量呈现爆炸式增长。研究表明^[1], 到 2025 年, 全球数据总量将达到 175 ZB。数据存储需求的增加, 对以硬盘作为主要存储介质的数据中心可靠性提出更高的要求。在数据中心中, CPU、内存、网卡和硬盘等硬件故障较为常见, 其中硬盘的故障率高达 78%, 位居硬件设备故障率第一^[2]。此外, 因硬盘的物理特性, 一旦发生硬盘故障会造成不可预料的后果, 一方面会造成在硬盘上运行的任务或系统崩溃, 导致服务中断; 另一方面可能会导致用户保存数据的永久性丢失。

为了提高数据中心存储系统的可靠性和安全性, 一些

容错机制被采用, 主要分为被动容错和主动容错^[3-5]。被动容错是在硬盘故障发生之后, 以牺牲系统性能为代价, 迅速恢复数据的补救措施, 常用的被动容错机制有备份和纠错两种, 备份机制的典型代表有冗余磁盘阵列 (RAID, redundant arrays of inexpensive disks) 技术和 Hadoop 分布式文件系统^[3]; 纠错机制以 Facebook 公司的 RS 纠错码方式^[6]较为常见。尽管被动容错技术能保证数据的安全可靠, 其存在运行成本高、存储空间利用率低等问题。相比之下, 主动容错机制能提前预测故障硬盘, 及时采取相应措施, 降低运维成本, 提升数据中心的可靠性和用户体验。基于 SMART 数据的主动容错技术, 可检测并记录与驱动可靠性相关的属性, 根据这些属性训练机器学习、深度学习等

收稿日期: 2023-10-23; 修回日期: 2023-12-06。

基金项目: 山东省基金项目 (ZR2019LZH006)。

作者简介: 王东清 (1989-), 男, 博士。

引用格式: 王东清, 张炳会, 彭继阳, 等. 基于 AE-LSTM 的多目标硬盘故障预测方法[J]. 计算机测量与控制, 2024, 32(5): 66-71.

人工智能模型用以预测硬盘故障, 成为研究方向^[7-12, 17-23]。

最初的硬盘故障预测是通过 SMART 技术对硬盘的各个状态属性监控, 当对应状态属性的信息达到设定的故障预警阈值, 发出硬盘故障预警。然而, 该类方法存在故障检测率低、误报率高问题。为提升硬盘故障准确率, 充分挖掘硬盘 SMART 状态属性信息与故障间的关系, 学术界和产业界开始借助机器学习、深度学习等技术手段, 典型的有贝叶斯方法 (Bayes Classifier)^[7-8]、支持向量机 (SVM, support vector machine)^[9-10]、决策树 (Decision Tree)^[11] 和多层感知机 (MLP, multi-layer perceptron)^[12] 等。

HAMERLY 等人^[8]将硬盘故障视为异常检测任务, 建立硬盘健康状态数据的概率模型 (朴素贝叶斯分类器和朴素贝叶斯子模型的混合), 根据概率阈值及硬盘状态信息判断硬盘是否故障。ZHU 等人^[12]提出了两种硬盘故障预测模型 (MLP 和改进的 SVM), 并以无序的序列信息作为模型输入, 实验结果表明, 相比前人的研究, 改进的 SVM 模型能达到最低的故障误报率, MLP 模型在故障检测率指标方面表现最优。XU 等人^[13]认为硬盘的健康状态具有渐变性, 并非正常和故障两种离散状态。因此, 采用循环神经网络模型 (RNN, recurrent neural network) 捕捉 SMART 序列数据的渐变性。相比非序列模型或短时序模型, RNN 模型在硬盘故障率指标上表现更好。SUN 等人^[14]提出使用时间卷积神经网络 (TCNN, temporal convolutional neural network) 捕捉 SMART 序列数据的渐变性、降低数据中的噪声干扰, 提升硬盘故障预测效果。

值得注意的是, 大多数预测模型都是将硬盘故障问题转化为二分类任务, 即区分正常硬盘和故障硬盘。然而, 硬盘故障是一个逐渐变化的过程, 并非由正常状态突变为故障状态, 并且训练数据中故障和正常硬盘存在严重的类别不平衡问题, 上述因素都会很大程度影响模型在实际应用中的效果。此外, 现有的硬盘故障预测模型无法对硬盘故障的原因分析, 准确有效的故障诊断不仅可以帮助运营商降本增效, 还能为模型预测结果的可解释性和可靠性提供支撑。

鉴于人工智能模型在硬盘故障预测应用中存在的上述问题, 本文提出一种融合 LSTM 的 AE 硬盘故障预测框架,

实现多目标任务: 硬盘健康状态分级、硬盘剩余使用寿命 (RUL, remaining useful life) 预测、硬盘故障诊断。首先, 考虑到硬盘故障是一个渐变过程, 在 SMART 属性上表现为复杂多变, 采用回归决策树模型智能划分硬盘健康等级, 用以代替传统基于规则或人工标记的方法^[16], 作为模型训练或预测目标。其次, 探索了一种结合 AE 和 LSTM 各自优势的 AE-LSTM 算法框架, 可从 SMART 属性中提取鲁棒的特征, 表现为 LSTM 单元更适合捕捉具有长短期依赖关系的硬盘 SMART 属性, 而 AE 模块能够降低 SMART 数据中的噪声干扰。因此, 经过 AE-LSTM 提取的高鲁棒隐藏变量为下游任务提供更有效的输入, 如作为下游两个全连接网络的输入, 可更精准预测硬盘剩余使用寿命、硬盘健康状态等级; 故障硬盘的诊断分析可由 AE 模块的输入输出差异判断, 而高鲁棒的 AE-LSTM 隐藏变量降低了噪声干扰、提升准确性。

1 AE-LSTM 多目标硬盘故障预测方法

图 1 展示了基于 AE-LSTM 算法的多目标硬盘故障预测流程图, 整体由离线训练和在线预测两部分构成: 1) 离线训练阶段首先对 SMART 数据进行预处理, 采用回归决策树模型对预处理后的数据划分健康等级, 作为 AE-LSTM 模型的故障检测目标训练, 最终获取多目标硬盘故障预测模型; 2) 在线预测阶段加载预训练模型的加载, 并对实时的 SMART 数据预处理, 模型根据预处理后的数据计算当前硬盘的健康状态等级, 并判断硬盘是否故障。若硬盘被判断将来会发生故障, 故障诊断模块将给出发生故障的原因, 剩余使用寿命模块会预测硬盘还需多久会发生故障。反之, 系统不作任何处理。下文将详细介绍流程中涉及各个模块, 包含数据与数据预处理、硬盘健康状态等级定义、AE-LSTM 多目标模型框架、模型效果评估和实验环境。

1.1 数据与数据预处理

本文实验数据集来自 Backblaze 官网^[15], 用以评估所提方法的效果。需注意的是, 不同厂商提供的 SMART 属性含义可能存在差异。因此, 本文选择数据量较大的希捷 ST4000DM000 建模 (共 29 878 块硬盘, 其中, 29 083 块正常磁盘和 795 块故障磁盘), 数据采样频率为一天一次, 采样的信息包含磁盘时间戳、设备序列号、容量和 SMART 属性

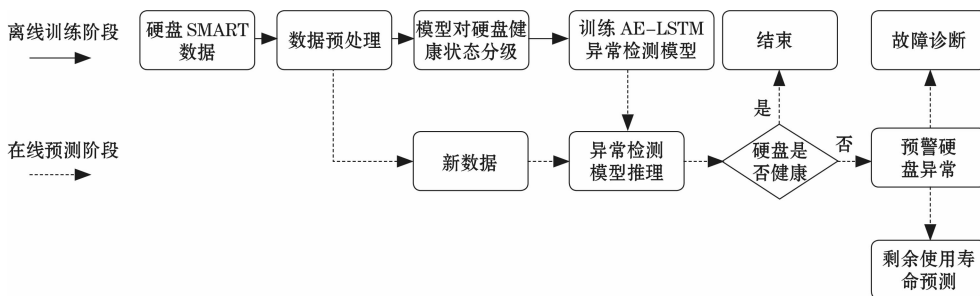


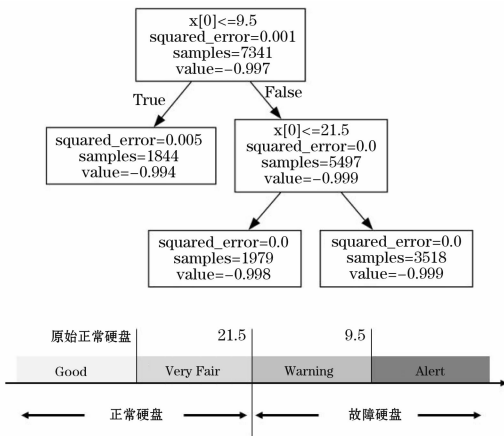
图 1 基于 AE-LSTM 算法的多目标硬盘故障预测流程图

等。此外，对 SMART 原始数据集中空值进行去除处理后，将其归一化至 $[-1, 1]$ 之间。预处理后的数据以 70%、15% 和 15% 的比例被划分为训练集、验证集和测试集。

1.2 硬盘健康等级定义

为了更准确描述硬盘健康等级，结合了硬盘的物理衰变特性进行定义，即距离硬盘发生故障前的时间长短，时间越长，表示硬盘健康程度越好，反之，硬盘处于亚健康甚至故障预警阶段。不同于传统的基于规则方法^[16]，提出一种基于回归决策树的硬盘健康等级定义方法，更智能、更有效的标记硬盘健康等级，用以模型训练或预测目标。

该方法仅对故障硬盘数据建模，以故障硬盘 j 为例，共计有 N_j 个样本，对样本按时间先后顺序分组排序，索引号 $i = 0$ 的样本表示硬盘 j 发生故障当天的采集数据，索引号为 $i = N_j - 1$ 的样本为故障前 $N_j - 1$ 天的采集。回归决策树分别输入不同的 SMART 属性 $f^m, m = 1, 2, \dots, M$ ，以故障发生前的时间（即硬盘 j 的 $0 \sim N_j - 1$ 索引）作为拟合目标，模型损失函数选择平均绝对误差（MSE, mean square error），在所有的回归决策树模型中，筛选 MSE 损失最小的 SMART 属性回归树，并将回归树中的节点时间作为硬盘健康等级的划分标准。图 2 为基于回归决策树方法定义硬盘健康等级，其中，上图表示筛选 MSE 损失最小的 SMART 属性回归树，下图为根据回归决策树的分裂节点定义了 4 个健康程度级别。需注意的是，对于采集数据中的原始正常硬盘直接定义 Good 健康等级。故障硬盘根据距离故障发生时间划分 Very Fair、Warning 和 Alert 三种状态。上述定义的 4 种硬盘健康等级将作为 AE-LSTM 模型的训练或预测目标。



(a) 上图中每个树节点表示某个 SMART 属性下，按 MSE 损失函数得到的硬盘健康状态等级的时间分割点；(b) 下图为根据回归决策树的分裂节点定义的健康程度级别。

图 2 基于回归决策树方法定义硬盘健康等级

1.3 AE-LSTM 多目标模型框架

图 3 展示了基于 AE-LSTM 的多目标模型框架图，包括 5 个部分：模型的输入和输出、基于 LSTM 单元的 AE 编码器和解码器、故障诊断模块、硬盘剩余使用寿命预测模块和硬盘健康状态分级模块。

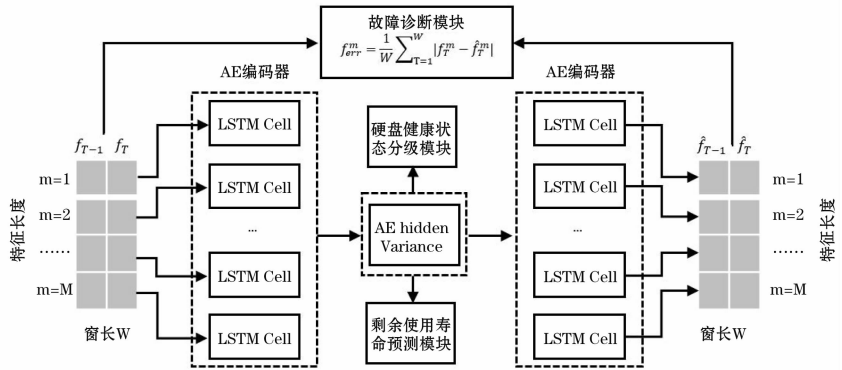


图 3 基于 AE-LSTM 的多目标模型

1.3.1 模型的输入和输出

在所提算法框架中，模型的输入是一个 $B \times W \times M$ 三维数据结构，其中 B 为每次迭代批处理数据大小， W 为时间窗大小， M 表示时间窗中每个时刻的特征总数。模型的输出也是一个 $B \times W \times M$ 三维数据结构，与输入数据存在一一对应关系。此外，输入数据中正常硬盘和故障硬盘存在不平衡问题，通过对样本数较少的类别上采样保证不同类别数量的平衡。

1.3.2 基于 LSTM 单元的 AE 编码器和解码器

LSTM 单元作为 RNN 的变体，通过门控信号对过去信息直接遗忘或按权重融合于当前信息中，用以建立与当前信息的相关性，可更精准捕捉硬盘时序数据的长短期依赖关系。AE 中包含的编码和解码结构，通过对输入数据编码压缩，再通过解码器生成与输入数据相同的分布，获得的中间隐藏单元可降低数据中的噪声干扰。结合 LSTM 和 AE 的各自优势，在 AE 结构中融合 LSTM 单元，既降低数据中的噪声干扰，又能发现硬盘数据中长短期依赖关系。

1.3.3 故障诊断模块

故障诊断模块在离线训练阶段选择的损失函数为 MSE，定义为：

$$\text{loss}_{se} = \frac{1}{M} \sum_{m=1}^M f_{err}^m \quad (1)$$

f_{err}^m 定义见公式 (2)。在线预测阶段，仅适用于被模型判断为故障状态的硬盘，对应图 2 中 Warning 和 Alert 两种状态等级。具体地，AE-LSTM 编码器输入窗长为 W 的时间序列 $\{a_{T-W-1}, \dots, a_{T-1}, a_T\}$, $\{a_T, a_T \in R^m\}$ 为 T 时刻的 SMART 属性，表示为 $\{f_T^m, m = 1, 2, \dots, M\}$, M 为 SMART 属性个数，AE-LSTM 解码器给出对应输入序列的预测 $\{\bar{a}_{T-W-1}, \dots, \bar{a}_{T-1}, \bar{a}_T\}$ ，对每个 SMART 属性计算 AE-LSTM 输入序列与输出序列的 MAE (Mean Absolute Er-

ror, 平均绝对误差), 即:

$$f_{err}^m = \frac{1}{W} \sum_{T=1}^W |f_T^m - \hat{f}_T^m| \quad (2)$$

从中筛选 MAE 误差较大的 Top-K 属性作为硬盘故障的主要原因。

1.3.4 硬盘剩余使用寿命预测模块

硬盘剩余使用寿命预测模块以 AE 模块的隐藏变量作为输入, 经过全连接网络 (FCN, fully connected network) 输出预估的发生故障时间, 损失函数选择 MSE, 定义为:

$$loss_{rul} = \frac{1}{B} \sum_{i=1}^B (rul - \widehat{rul})^2 \quad (3)$$

rul 为硬盘当前的真实剩余使用寿命, \widehat{rul} 为模型预测值。需注意的是, Good 健康等级硬盘的 rul 设定为一个常数, 故障硬盘的 rul 按距离故障时刻的真实时长作为模型训练或预测目标。

算法 1: 基于 AE-LSTM 的多目标硬盘故障预测算法输入: 经预处理后的 $W \times M$ 二维训练数据, 其中 W 为时间窗大小, M 表示时间窗中每个时刻的特征总数; 模型训练阶段迭代次数 N ; 测试数据 $A' = \{a'_{T-W-1}, \dots, a'_{T-1}, a'_T; a' \in R^m\}$ 。

输出: 硬盘所述健康状态分级 (Good、Very Fair、Warning 和 Alert) 和剩余使用寿命; 若硬盘属于 Warning 和 Alert 两者中的任一状态, 需给出硬盘故障诊断。

1: 训练阶段;

2: for $i=0$ to N do;

3: 从训练样本中抽样批次大小为 B 的数据, 构成 $B \times W \times M$ 三维数据结构;

4: 对时间窗内的每个特征 f_T^m 由 AE 计算其预测结果 \hat{f}_T^m , 并根据公式(1) 计算 $loss_{ae}$;

5: 以 AE 模块的隐藏变量作为输入, 预测硬盘发生故障的时间, 并根据公式 (3) 计算 $loss_{rul}$;

6: 以 AE 模块的隐藏变量作为输入, 判断硬盘所述健康状态分级, 并根据公式 (4) 计算 $loss_{entropy}$;

7: 根据公式 (5) 获取模型 $loss$ 总和, 并更新各模型网络参数;

8: 测试阶段;

9: 加载预训练的 AE-LSTM 算法模型, 对输入的测试数据 A' 计算各模块输出结果, 给定硬盘;

10: 当前所属健康状态和剩余使用寿命; 若硬盘当前被模型判定为故障状态, 模型根据公式 (6);

11: 筛选出 Top-K SMART 属性作为故障归因。

1.3.5 硬盘健康状态分级模块

类似地, 硬盘健康分级模块以 AE 模块的隐藏变量作为输入, 经过另一个全连接网络判断当前硬盘属于 4 种健康状态 (Good、Very Fair、Warning 和 Alert) 中的哪一类, 是一种典型的多分类任务, 故采用交叉熵作为模型损失函数, 定义为:

$$loss_{entropy} = \frac{1}{B} \sum_{i=1}^B \sum_{k=1}^K y_i^k \log(\overline{y}_i^k) \quad (4)$$

其中: K 表示 4 种健康状态总数, y_i^k 表示第 i 个样本属于第 k 个健康状态, \overline{y}_i^k 为模型预测的硬盘健康状态。基于 AE-LSTM 多目标模型的最终损失由 $loss_{ae}$ 、 $loss_{rul}$ 和 $loss_{entropy}$ 按加权和给出, 即:

$$loss = \omega_{ae} loss_{ae} + \omega_{rul} loss_{rul} + \omega_{entropy} loss_{entropy} \quad (5)$$

算法 1 总结了基于 AE-LSTM 算法的多目标硬盘故障预测实现步骤。

1.4 模型效果评估

硬盘健康状态分级作为典型的多分类问题, 在效果评估上, 将采用 Accuracy (准确率) 给出, 即正确分类的样本总数在测试样本中的占比。此外, 将 Good 和 Very Fair 两种状态等级硬盘作为正常硬盘, Warning 和 Alert 被视为故障硬盘, 采用 FDR (Failure Detection Rate, 故障检测率) 和 FAR (False Alarm Rate, 误警率) 两种指标, 用于评估不同模型对故障硬盘的预测效果。FDR 定义为被模型正确识别的故障硬盘样本在所有故障样本中的占比, FAR 定义为正常硬盘被模型识别为故障硬盘的样本数在所有正常硬盘中的占比。

剩余使用寿命预测模块直接采用 MSE 作为模型评估指标, MSE 值越小, 代表模型预测的 URL 与真实值越接近, 预测效果越好。反之, 表示模型预测效果越差。

为评估故障诊断方法的有效性, 提出一种 IFC (Internal Feature Consistency, 组内特征一致性) 指标, 通过计算不同特征在时间窗内的余弦相似度给出, 其基本假设为正常硬盘的 SMART 属性值间存在一致的变化趋势, IFC 数值更大。反之, 对于即将发生或已发生故障的硬盘, 因部分硬盘物理特性的改变, 会在 SMART 上呈现出不同的变化趋势, 即 IFC 数值更小。结合 1.3.3 小节故障诊断模块描述, 将一个时间窗内 W 的序列数据视为组内数据, 筛选出的 Top-K 故障原因特征 IFC 值应比 MAE 误差排序靠后的 $M-K$ 个值更小。以筛选的 Top-K 特征, 对应的 IFC 定义如下:

$$IFC = \frac{2}{W * (W - 1)} \sum_{i=2}^W \sum_{j=1}^{W-1} \cos(i, j) \quad (6)$$

K 为筛选出的 Top-K SMART 故障属性, W 为 AE-LSTM 模型的输入序列窗长, $\cos(i, j)$ 为筛选的 Top-K SMART 属性中第 i, j 时刻间的余弦相似度。

为了评估提出的 AE-LSTM 算法有效性, 实验分别对比两种基线算法 LSTM 和随机森林 (RF, random forest)。LSTM 可捕捉 SMART 属性的长短期依赖关系, 由两层 LSTM 堆叠而成, 输出变量接入 FCN 用以硬盘健康状态分级。值得注意的是, LSMT 没有剩余使用寿命预测模块和故障诊断模块。AE-LSTM 和 LSTM 模型均采用 Adam 优化器。RF 对输入的特征不考虑特征中的序列关系, 由分类器投票决定测试样本所属类别。

1.5 实验环境

本实验的硬件配置为 Intel i7 酷睿 CPU 处理器、16 G

内存的台式机，开发语言为 Python3.9，RF 模型是由 scikit-learn 算法库实现的，AE-LSTM 和 LSTM 模型均由 Tensorflow 中的 Keras 算法库完成。

2 实验结果与分析

2.1 输入序列窗长对模型效果的影响

如表 1 所示，随着窗长 W 增加，Accuracy、FDR 和 FAR 指标在 AE-LSTM 和 LSTM 模型上整体呈现先变优再变差的趋势。当窗长由 22 增加至 24，Accuracy 和 FAR 在两种模型上均下降，LSTM 模型降低更为显著，归因于输入序列较长，故障硬盘的属性被淹没，使得 LSTM 无法精准区分正常和故障硬盘模式，而 AE-LSTM 因融入了 AE 模块，获取了鲁棒的隐藏变量信息，提升了模型的抗干扰能力。类似地，AE-LSTM 模型在窗长为 10 时，在 Accuracy、FDR 和 FAR 各项指标上，也显著优于 LSTM 模型。对于 12 至 22 区间内的窗长，LSTM 和 AE-LSTM 模型在 Accuracy 和 FDR 指标上效果相当。在 FAR 指标上，对比 LSTM 模型，AE-LSTM 平均提升 3.47%。鉴于两种模型在 $W=18$ 在各项指标上的效果最优，后续的分析将对此进行。

表 1 输入序列窗长 W 在不同模型的效果

W	AE-LSTM				LSTM		
	Accuracy /%	FDR /%	FAR /%	MSE	Accuracy /%	FDR /%	FAR /%
10	96.47	91.90	1.97	1.22	94.83	86.82	2.97
12	96.49	94.66	2.19	1.14	96.59	88.36	1.96
14	97.94	95.95	1.35	1.03	98.21	91.50	0.83
16	98.14	96.28	1.02	1.09	97.83	90.80	1.11
18	98.45	96.03	1.03	0.96	98.44	94.64	0.77
20	98.44	95.98	0.87	0.99	97.91	94.38	1.11
22	98.08	95.12	1.13	1.22	97.61	95.11	1.54
24	97.38	90.49	1.47	1.19	95.82	86.98	1.85

2.2 不同模型效果对比

如表 2 所示，LSTM 和 AE-LSTM 序列模型在各类指标上显著优于非序列模型 RF。对比 LSTM 和 AE-LSTM 可发现，在 FDR 指标上，AE-LSTM 表现出明显的优势，提升 1.39%，归因于其结合了 AE 和 LSTM 模型各自的优势，即同时兼容了捕捉时间序列中的长短期依赖关系和降低数据中噪声干扰两个特性。表 3 展示了 3 种算法模型在 4 种硬盘健康分级评估上的效果，与表 2 类似，RF 模型在效果上显著劣于 LSTM 和 AE-LSTM 模型。AE-LSTM 模型在 Alter、Warning 和 Very Fair 状态上显著优于 LSTM，分别提升 4.68%、5.15% 和 8.34%。在 Good 状态上，LSMT 与 AE-LSTM 效果相当，与表 2 中 FAR 指标对应。

2.3 剩余使用寿命预测

类似于表 2 中的其他评估指标，剩余使用寿命预测指标 MSE 随着窗长 W 增加呈现先变优再变差的趋势，在窗长 $W=18$ 时达到最优值 0.96。图 4 给出了随机采样的正常和故障硬盘 RUL 数据下，模型对不同硬盘状态等级 RUL 预测效果。从图中可以看出，AE-LSTM 能够较好的预测不同状态下的硬盘 RUL，且预测最大误差为 3 天。

表 2 不同模型在各类指标上的效果

Algorithm	Accuracy/%	FDR /%	FAR/%	MSE
RF	91.24	82.55	5.13	—
LSTM	98.44	94.64	0.77	—
AE-LSTM	98.45	96.03	1.03	0.96

表 3 不同模型在 4 种硬盘健康分级评估上的效果

Algorithm	Alert/%	Good /%	Very Fair/%	Warning
RF	74.28	92.49	73.11	51.18
LSTM	90.30	99.15	84.72	83.15
AE-LSTM	94.98	98.82	93.06	88.30

2.4 硬盘故障诊断分析

为了评估 IFC 指标的合理性，表 4 中给出了 4 种硬盘健康分级下，首先分析了 SMART 属性在训练数据中的变化趋势，从中可以看出，随着硬盘由正常逐渐变为故障状态，IFC 指标值也表现出一致的变化趋势，即由大变小。在故障诊断方面，通过 AE 结构输入与输出间差异的大小，筛选差异最大的 Top-K ($K=3$) SMART 属性作为模型诊断的故障原因。表 4 中的测试数据部分给出了模型正确判断出故障硬盘（对应 Alert、Warning 状态）下，模型诊断出的 Top-3 故障 SMART 属性 IFC 指标（对应表中故障属性）和剩余 SMART 属性 IFC 指标（对应表中非故障属性）。从 IFC 值来看，筛选出的 Top-3 SMART 属性可作为硬盘故障的主要原因，相比非故障属性的 IFC 值更小。此外，图 5 展示了模型筛选出的 Top-3 故障 SMART 属性随时间变化曲线（图 5 上），并对比了正常硬盘（图 5 下）下的 3 种 SMART 属性，从中可以看出，故障硬盘的 SMART 属性间呈现不一致的变化趋势，正常硬盘则表现明显的一致变




图 4 剩余使用寿命预测效果

化趋势, 验证了 IFC 指标的有效性。

表 4 IFC 指标在不同数据集下的效果

训练数据	Alert	Warning	Very Fair	Good
	0.65	0.68	0.75	1.0
测试数据	故障属性		非故障属性	
	0.93		1.0	




图 5 故障硬盘 (上) 和正常硬盘 (下) 3 种 SMART 属性随时间变化曲线

3 结束语

针对硬盘故障预警中的问题定义、故障诊断和硬盘剩余使用寿命等问题, 结合了 LSTM 捕捉长短期依赖关系和 AE 降低噪声干扰的优势, 提出基于 AE-LSTM 的多目标硬盘故障预测框架, 实现了将多个功能集成于同一框架中, 既降低了模型维护成本, 又发挥不同模块的优势和功能。在公开数据集上验证了所提算法, 并对比了几种基线算法, 实验结果证实了 AE-LSTM 算法在多目标硬盘故障预测中的有效性和优势。

参考文献:

[1] DAVID R, JOHN G, JOHN R. 世界的数字化从边缘到核心 [Z]. 2018.
 [2] VISHWANATH K V, NAGAPPAN N. Characterizing cloud computing hardware reliability [C] // Proceedings of the 1st

ACM Symposium on Cloud Computing, ACM, 2010: 193 - 204.
 [3] WANG Y, DONG X, WANG L, et al. Optimizing small-sample disk fault detection based on LSTM-GAN model [J]. ACM Transactions on Architecture and Code Optimization (TACO), 2022, 19 (1): 1 - 24.
 [4] NARAYANAN I, WANG D, JEON M, et al. SSD failures in datacenters: What? when? and why? [C] // Proceedings of the 9th ACM International on Systems and Storage Conference, 2016: 1 - 11.
 [5] XU Y, SUI K, YAO R, et al. Improving service availability of cloud systems by predicting disk error [C] // 2018 USENIX Annual Technical Conference (USENIX ATC 18), 2018: 481 - 494.
 [6] SATHIAMOORTHY M, ASTERIS M, PAPAILIOPOULOS D, et al. Xoring elephants: Novel erasure codes for big data [C] // Proceedings of the VLDB Endowment, VLDB Endowment, 2013, 6 (5): 325 - 336.
 [7] CHAVES I C, PAULA M R P D, LEITE L G M, et al. BaN-HFaP: a bayesian network based failure prediction approach for hard disk drives [C] // 2016 5th Brazilian Conference on Intelligent Systems (BRACIS), IEEE, 2016.
 [8] HAMERLY G, ELKAN C. Bayesian approaches to failure prediction for disk drives [C] // ICML, 2001, 1: 202 - 209.
 [9] 柳永康. 基于机器学习的磁盘故障预测系统 [D]. 武汉: 华中科技大学, 2015.
 [10] 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 (5).
 [11] 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, IEEE, 2014: 383 - 394.
 [12] 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 (MSST), IEEE, 2013: 1 - 5.
 [13] XU C, WANG G, LIU X, et al. Health status assessment and failure prediction for hard drives with recurrent neural networks [J]. IEEE Transactions on Computers, 2016, 65 (11): 3502 - 3508.
 [14] SUN X, CHAKRABARTY K, HUANG R, et al. System-level hardware failure prediction using deep learning [C] // Proceedings of the 56th Annual Design Automation Conference 2019, 2019: 1 - 6.
 [15] Drive Stats Q1 2024 Snapshot [Z/OL]. <https://www.backblaze.com/cloud-storage/resources/hard-drive-test-data>.
 [16] 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 (IWQOS), IEEE, 2021: 1 - 10.

(下转第 79 页)