

基于 VMD-LSTM-VAE 的渗流监测数据异常值检测模型

李梦华^{1,2}, 钱胥安^{1,2}, 傅蜀燕^{1,2,3}, 赵晗坤^{1,2}, 金思彤^{1,2}, 欧 斌^{1,2,3,4}

(1. 云南农业大学水利学院; 2. 云南省水利水电工程安全重点实验室; 3. 云南省中小型水利工程智慧管养工程研究中心;
4. 云南省水安全保障重点实验室)

摘要:针对传统渗流监测数据异常值检测方法在处理非线性、非平稳水位监测数据时的不足,提出了一种基于变分模态分解(VMD)、长短期记忆网络(LSTM)和变分自编码器(VAE)的组合模型。该模型利用 VMD 对水位时间序列进行多尺度分解,获得具有不同频率特征的本征模态函数;通过双层 LSTM 捕捉各模态分量的时序依赖特征;利用 VAE 进行特征压缩与重构,并基于重构误差实现异常值的检测。实例验证结果表明,该组合模型能够有效识别孤立异常点和连续异常值序列;在测试集中分别按 1%、2% 和 3% 的比例随机添加异常值的场景下,模型均表现出良好的检测性能,验证了其在渗流监测数据异常值检测中的有效性。

关键词:大坝渗流监测;异常值检测;变分模态分解;长短期记忆网络;变分自编码器

An outlier detection model for seepage monitoring data based on VMD-LSTM-VAE//Li Menghua^{1,2}, Qian Xu'an^{1,2}, Fu Shuyan^{1,2,3}, Zhao Hankun^{1,2}, Jin Sitong^{1,2}, Ou Bin^{1,2,3,4} (1. College of Water Conservancy, Yunnan Agricultural University; 2. Yunnan Key Laboratory of Hydraulic and Hydropower Engineering Safety; 3. Yunnan Engineering Research Center for Intelligent Management and Maintenance of Small and Medium-sized Water Conservancy Projects; 4. Yunnan Key Laboratory of Water Security)

Abstract: To address the limitations of traditional outlier detection methods for seepage monitoring data in processing nonlinear and nonstationary water level monitoring data, a hybrid model based on variational mode decomposition (VMD), long short-term memory network (LSTM), and variational autoencoder (VAE) is proposed. In the proposed model, VMD is used to perform multiscale decomposition of the water level time series and obtain intrinsic mode functions with different frequency characteristics. A two-layer LSTM is then employed to capture the temporal dependencies of each modal component. VAE is used for feature compression and reconstruction, and outlier detection is achieved based on the reconstruction error. Case validation results show that the hybrid model can effectively identify isolated outliers and continuous outlier sequences. In scenarios where outliers were randomly added to the test set at proportions of 1%, 2%, and 3%, the model exhibited good detection performance, verifying its effectiveness in outlier detection for seepage monitoring data.

Key words: dam seepage monitoring; outlier detection; variational mode decomposition; long short-term memory network; variational autoencoder

大坝渗流监测数据能够实时反映渗流状态,是评估大坝安全性的重要依据。然而,由于仪器设备故障、外部环境干扰以及数据采集与传输过程中不可避免的误差,监测数据中常常混杂着异常值^[1]。若未能及时识别并妥善处理这些异常值,将影响大

坝渗流性态的精确分析,进而导致安全评估结果出现偏差,最终影响大坝运行安全性的准确评估。

传统的异常值检测方法主要包括统计分析法和经验阈值法。然而,统计分析法在处理数据的时序相关性及非线性特征方面效果有限;经验阈值法则

基金项目:国家自然科学基金项目(52369026,52069029);水灾害防御全国重点实验室 2023 年度“一带一路”水与可持续发展科技项目(2023490411);云南省农业基础研究联合专项面上项目(202401BD070001-071);云南省水安全保障重点实验室建设项目(20254916CE340051)

作者简介:李梦华(2000—),女,硕士研究生,主要从事大坝安全监测研究。E-mail:2024240069@stu.ynau.edu.cn

通信作者:欧斌(1983—),男,副教授,博士,主要从事水工结构安全监控与病害诊断研究。E-mail:oubin418@126.com

高度依赖专家主观经验,难以适应监测环境中复杂多变的情况及多样化工况条件。随着机器学习技术的发展,深度学习方法^[2-4]在异常值检测领域展现出显著优势。长短期记忆网络(LSTM)因其特殊的门控机制,能够有效捕捉时间序列数据的长期依赖关系,在监测数据分析中得到广泛应用。例如:叶斌^[5]利用 LSTM 对大坝安全监测数据进行了异常值检测,通过与逐步回归模型和 3σ 准则对比,验证了 LSTM 在多数情况下能较好地拟合实测数据,具有较强的预测能力;余红玲等^[6]提出了基于改进深度稀疏自编码器(DSAE)的大坝渗流监测数据异常值检测模型,采用基于混沌初始化和非线性飞行速率改进的天鹰优化(IAO)算法对 DSAE 的超参数进行优化,并利用逆向云算法拟定异常阈值,提高了异常值检测的准确性和可靠性;熊敏等^[7]提出了多维度 LSTM 异常值检测与恢复方法,利用多个测点的监测数据对单测点进行预测,有效利用了不同测点间的相关信息,相比单维度 LSTM 方法,在异常值检测和数据恢复方面表现更优。在时间序列异常值检测的相关研究中,Lin 等^[8]结合变分自编码器(VAE)提取局部特征和 LSTM 捕捉长期依赖关系的优势提出了 VAE-LSTM 混合模型,取得了良好的异常值检测效果。此外,变分模态分解(VMD)技术在信号处理领域展现出独特优势。例如:Ou 等^[9]将 VMD 与分形理论、鲸鱼优化算法-深度极限学习机(WOA-DELM)相结合用于大坝变形分析,有效提高了数据处理和预测精度;岳明昊等^[10]运用时空相关性原理对缺失的监测数据进行了插补处理,结合小波去噪与格拉布斯检验的组合方法,实现了对异常值的有效识别与处理,从而提升了监测数据的可靠性。

然而,面对复杂工况下多尺度特征提取不足、时空关联挖掘不充分及阈值设定理论基础薄弱等局限问题,现有方法的检测稳定性及准确性亟待提升。为此,本文创新性地融合了 VMD、LSTM 与 VAE,构建了 VMD-LSTM-VAE 组合模型。该模型通过 VMD 技术分解渗流序列获取多尺度本征模态函数(IMFs),利用 LSTM 深度挖掘各 IMF 分量的时序依赖规律,并基于 VAE 的特征压缩-重构机制建立异常判据。为系统验证模型性能,进一步设计随机异常值嵌入测试框架,通过多场景异常工况模拟评估其泛化能力。

1 模型构建

1.1 VMD 信号分解及特征提取

变分模态分解(VMD)是一种自适应信号分解方法,可将非线性、非平稳时间序列分解为若干具有

不同中心频率和时间尺度特征的 IMF 分量^[11-12]。各 IMF 分量能够反映原始序列中不同频段的波动成分,有助于表征监测数据中的长期趋势、周期变化和短期扰动等多尺度特征。大坝渗流监测数据受库水位、降雨、温度、运行工况及仪器误差等多种因素影响,通常具有明显的非线性和非平稳特征。若直接利用原始监测序列进行建模,噪声扰动和多尺度成分耦合可能影响模型对异常值的识别效果。因此,本文在 LSTM-VAE 建模前引入 VMD,对测压管水位监测序列进行多尺度分解,以提高输入数据的稳定性和特征表达能力。

本文中的 VMD 处理流程如下:①对预处理后的测压管水位时间序列进行 VMD 分解,得到 3 个 IMF 分量;②结合各 IMF 分量的频率特征、能量占比及变化形态,分析其所表征的渗流变化信息;③筛选能够反映主要渗流变化过程的有效模态分量,削弱高频噪声和局部随机扰动对后续建模的影响;④对筛选后的有效模态分量进行重构,并将重构后的序列作为 LSTM-VAE 模型的输入。通过上述处理,可在保留渗流监测数据主要时序特征的同时降低噪声干扰,为后续基于重构误差的异常值检测提供更稳定的数据基础。

1.2 LSTM-VAE 模型构建

LSTM 可用于提取 VMD 技术分解后各模态分量的时序依赖关系^[13],而 VAE 能在无监督框架下学习数据的潜在分布^[14],二者协同作用,使模型兼具时序特征学习与特征压缩的双重能力。由于大坝渗流数据的非平稳特性(如季节更替、设备漂移等导致的统计特性时变),传统固定阈值易在异常边界模糊时失效,本文提出动态阈值机制,基于实时重构误差的统计分布自适应调整判别标准,能降低背景波动引起的误报与漏报风险。该机制的实现步骤如下:

a. 数据预处理。对渗流监测数据进行预处理,包括缺失值处理、异常值初筛、平滑与降噪。

b. 信号分解与特征提取。采用 VMD 将预处理后的渗流监测序列分解为若干具有不同频率特征的 IMF 分量,并根据频率特征和能量占比筛选有效模态分量并进行重构。该过程可提取信号的主要多尺度特征,并削弱高频噪声及局部随机扰动的影响,为后续 LSTM-VAE 建模提供输入数据。

c. LSTM-VAE 模型训练。采用 LSTM-VAE 模型对训练集数据进行无监督训练^[15-16],其中训练集为预处理后数据的 70%。LSTM 网络用于捕捉渗流监测时间序列中的长期依赖特征^[17-18],VAE 则通过特征压缩与重构学习数据的潜在分布,并以重构结

果与原始输入之间的差异作为后续异常值判别的重要依据。模型输入为由滑动窗口构造的时间序列子样本。首先,编码器中的堆叠 LSTM 网络提取输入样本的时序特征,并映射得到潜变量分布的均值和方差参数;随后,通过重参数化采样获得潜变量 z ;最后,由对称的 LSTM 解码器根据潜变量对输入序列进行重构。模型训练目标为最小化由重构误差项和潜变量分布约束项共同构成的损失函数:

$$L_{\text{LSTM-VAE}} = 0.8 \| \mathbf{X} - \hat{\mathbf{X}} \|_2^2 + 0.2 D_{\text{KL}}[q(z|\mathbf{X}) \| p(z)] \quad (1)$$

式中: $L_{\text{LSTM-VAE}}$ 为 LSTM-VAE 模型的损失函数; $\mathbf{X}$ 为滑动窗口构造的输入时间序列样本向量, $\mathbf{X} = (x_1, x_2, \dots, x_T)^T$; T 为滑动窗口长度; $\hat{\mathbf{X}}$ 为模型重构输出的时间序列样本向量, $\hat{\mathbf{X}} = (\hat{x}_1, \hat{x}_2, \dots, \hat{x}_T)^T$; $q(z|\mathbf{X})$ 为编码器学习得到的潜变量的后验分布; $p(z)$ 为潜变量的先验分布,通常设为标准正态分布; $D_{\text{KL}}[\cdot \| \cdot]$ 为 Kullback-Leibler (KL) 散度,衡量后验分布 $q(z|\mathbf{X})$ 与先验分布 $p(z)$ 之间的差异。重构误差项和 KL 散度项的权重分别设为 0.8 和 0.2。该损失函数由两部分组成:第一部分为重构误差项,用于衡量模型重构输出与输入样本之间的差异,使模型学习正常渗流监测序列的主要时序变化特征;第二部分为 KL 散度项,用于约束潜变量的后验分布接近先验分布,增强潜在空间表示的稳定性。通过联合最小化上述两项,模型能够兼顾输入序列重构与潜在分布建模,为后续基于重构误差的异常值判别提供依据。

d. 异常值检测与重构误差计算。模型训练完成后,将新的测试数据输入 LSTM-VAE 模型进行重构,并计算其重构误差。该误差即为实际输入值与模型重构输出值之间的偏差:

$$E_R = \| x - \hat{x} \|_2^2 \quad (2)$$

式中: x 为原始输入样本; $\hat{x}$ 为模型输出的重构结果。

模型训练完成后,将测试样本输入 LSTM-VAE 模型进行重构,并计算输入样本与重构输出之间的重构误差。重构误差反映了模型对测试样本时序特征的复原能力。若某一测试样本的重构误差显著高于训练集中正常样本的重构误差水平,说明该样本难以被模型有效重构,可能存在异常。后续基于重构误差构建动态阈值机制,实现异常值识别。

e. 动态阈值计算与异常识别。为实现异常样本与正常样本的有效区分,本文利用训练阶段正常样本的重构误差分布特征构建动态判别阈值。考虑到正常样本的重构误差通常集中在一定范围内,而异常样本往往会产生较大的重构误差,因此采用均

值与标准差相结合的方式确定异常值判别阈值。测试样本的重构误差为 E_R ,异常值判别阈值为 τ ,则其计算公式为:

$$\tau = \mu(E_R) + \alpha\sigma(E_R) \quad (3)$$

式中: τ 为异常值判别阈值; μ 表示均值运算; σ 表示标准差运算; α 为阈值灵敏度系数,用于调节异常值判别的严格程度。

当 $E_R > \tau$ 时,表明该样本难以被模型有效重构,将其判定为异常值;当 $E_R \leq \tau$ 时,则判定为正常样本。通过基于重构误差统计分布设置判别阈值,模型能够在一定程度上适应渗流监测数据的波动特征,降低固定阈值带来的误报或漏报风险。LSTM-VAE 由编码器、潜变量采样模块和解码器构成。编码器采用双层 LSTM 提取渗流监测序列的长期依赖特征,并映射得到潜变量分布参数;潜变量采样模块通过重参数化采样获得潜变量 z ;解码器采用与编码器相对应的 LSTM 结构,将潜变量 z 映射回数据空间,实现输入序列重构。模型通过时间维度扩展操作保持输入与输出序列长度一致,并在无监督训练过程中联合优化重构误差项与 KL 散度项。重构误差可反映样本与正常数据分布之间的偏离程度,为后续动态阈值判别提供依据。

1.3 VMD-LSTM-VAE 模型结构

为充分发挥 VMD 在非平稳渗流信号降噪与特征提取方面的优势,同时结合 LSTM 与 VAE 对时序数据潜在结构的建模能力,提出了一种融合 VMD、LSTM 与 VAE 的异常值检测模型,即 VMD-LSTM-VAE 模型。图 1 展示了从数据预处理、模态分解到 LSTM-VAE 模型构建,再到动态阈值检测的完整模型架构及其核心流程,涵盖信号分解、特征重构、模型训练以及异常值检测环节。通过这一综合性模型结构,异常值的识别与处理得以实现。该模型内部整合了多个关键组件,包括 LSTM 编码器、隐变量采样机制以及 LSTM 解码器。此外,模型还包含一个以重构误差为核心的异常值识别模块,驱动异常值的精准检测。

2 实例验证

2.1 工程概况与模型参数设置

云南某土石坝位于昆明市盘龙江中游,为大(2)型水利工程。主坝坝长 201 m,坝高 62 m,副坝坝长 354.6 m,坝高 34.5 m。为监测坝身渗流及心墙渗透压力,在主坝河床断面布设 ZU1 ~ ZU5 共 5 个测压管,形成桩号为 0+082 的顺河向监测断面。本文选取逐日采集的 ZU1 测压管水位监测数据作为研究对象,进行异常值检测分析。ZU1 ~ ZU5 测压




图1 VMD-LSTM-VAE 模型结构与异常值检测流程
管在主坝平面上的布置位置见图2。

在明确监测对象和数据来源的基础上,对模型主要参数进行统一设置。VMD 分解模态数设为 3,用于表征测压管水位序列中的长期趋势、年周期变化和短期波动特征;惩罚因子设为 2000,最大迭代次数设为 500,中心频率采用线性方式初始化。LSTM-VAE 模型采用编码器-潜变量采样-解码器结构,其中编码器和解码器均采用双层 LSTM。第一层和第二层 LSTM 的隐藏单元数分别设为 64 和 32,滑动窗口长度设为 60 个时间步。由于本文采用逐

日采集的渗流监测数据,60 个时间步对应连续 60 d 的监测序列。模型采用修正线性单元(ReLU)激活函数,随机失活率设为 0.2,潜变量维度设为 16。损失函数中,重构误差项权重设为 0.8,KL 散度项权重设为 0.2。上述参数在不同异常值添加比例测试和模型对比实验中保持一致。

2.2 随机异常值添加

为评估模型在不同异常形态和不同异常值添加比例下的识别性能,本文在保持训练集数据不变的基础上,仅对测试集进行人工异常值嵌入。实验共选取 1557 组 ZU1 测压管水位监测数据。首先对原始数据进行预处理,包括缺失值处理、明显异常值初筛、平滑与降噪;随后按照时间顺序将预处理后的数据划分为训练集和测试集,其中 70%作为训练集,30%作为测试集。训练集用于 LSTM-VAE 模型训练,测试集用于随机异常值添加和检测性能评价。

为模拟实际工程监测中可能出现的异常情况,本文在测试集中构造孤立异常、连续异常和混合异常 3 类典型异常模式。随机异常值添加^[19]时,以被替换位置的原始观测值为基准,并以正常水位监测序列的标准差作为扰动幅度尺度,具体设置如下:

a. 孤立异常。在测试集中随机选取单个时间点,将该点原始观测值替换为叠加 2~3 倍标准差扰动后的值。扰动方向随机确定,使异常值相对于原始观测值表现为偏高或偏低。

b. 连续异常。在测试集中随机选取起始位置,插入长度为 5~10 个时间点的连续异常序列。连续异常序列以对应位置的原始观测值为基准,叠加 1.8~2.2 倍标准差的平滑扰动,并采用正弦函数控制扰动幅值变化,以模拟传感器短时漂移或连续测量偏差过程。




图2 主坝测压管平面布置示意图

c. 混合异常。首先生成长度为 5~10 个时间点的连续异常序列,随后在该连续异常序列中随机插入 1~2 个孤立异常点,以模拟连续异常与局部突变同时存在的复合异常场景。

在异常值数量设置方面,本文将异常值添加比例分别设为约 1%、2%和 3%。该比例指人工添加的异常值样本数占测试集样本总数的比例。具体添加情况见图 3,其中混合连续点和混合孤立点分别表示混合异常模式中的连续异常点和孤立异常点。




图 3 随机异常值添加

对测试集添加异常值后,用 VMD 对时间序列数据进行分解,分解效果见图 4,图中显示了 3 个 IMF 组件,分别为 IMF1、IMF2 和 IMF3。基于时域能量积分法计算各模态能量占比,该方法可量化不同时间尺度特征在原始信号中的贡献。分析结果表明,测压管水位变化的多年趋势(能量占比 76.64%)、年周期变化(能量占比 20.29%)和短期波动特征(能量占比 2.71%),在测试集中得到了有效分离。




图 4 测试集时间序列分解的分量

通过 VMD 进行分解,测试集中的时间序列被有效分解为多个模态分量,每个模态分量均具备明

确的物理意义以及独特的时间尺度特征。这一分解过程为后续的异常值检测与模式识别奠定了坚实的数据基础,同时有利于深入探究渗流监测数据中所蕴含的多尺度动力学特性。

选择能量占比较高的 IMF1、IMF2 与残差进行重构之后,用 VMD-LSTM-VAE 模型对其进行异常值检测,结果如图 5 所示,




图 5 异常值识别结果

由图 5 可知,VMD-LSTM-VAE 模型在异常值检测任务中表现出优异的性能,能够在有效保持数据内在特征的同时,准确识别多种异常模式,具有较强的工程应用价值。然而,该模型在少量特殊工况下仍存在误判现象,这也为进一步提升异常识别的精确度提供了优化方向。

2.3 结果分析

为了评估 VMD-LSTM-VAE 模型在大坝渗流监测数据异常值检测中的性能情况,构建了包含多个指标的评价体系,选取精确率 P 、召回率 R 、F1 分数及 ROC 曲线下面积 (AUC) [20] 作为评判的关键指标,从不同维度对检测结果进行定量分析。其中,精确率反映了判定为异常的样本中实际异常的比例,衡量了模型的误报水平;召回率表示识别出的异常样本在所有实际异常样本中的占比,衡量了模型的漏报风险;F1 分数作为精确率与召回率的调和均值,可综合评价模型检测性能;AUC 则反映模型在不同判别阈值下区分正常样本与异常值样本的整体能力,AUC 值越接近 1,表示模型分类性能越好。

由 ROC 曲线(图 6)可知,VMD-LSTM-VAE 模型在渗流监测数据异常值检测任务中的 AUC 值为 0.899,明显高于随机分类基准线对应的 AUC 值 0.5,说明该模型具有较好的整体分类能力。具体而言,该模型在区分正常渗流状态与异常状态时,表现出了较强的识别能力,能够有效识别异常状态。图中,假阳性率 (FPR) 表示正常样本被误判为异常值的比例,真阳性率 (TPR) 表示实际异常值样本被正确识别出的比例。

在低误报区间(FPR 小于 0.2),模型的 TPR 迅速上升至 0.6,可见其在控制虚警的同时,能有效捕




图 6 ROC 曲线

捉关键的渗流异常信号;当 FPR 介于 0.2~0.4 之间时,ROC 曲线呈现出阶梯式上升的形态,说明随着判别阈值变化,模型对异常值样本的识别能力进一步提高;进入高误报区间(FPR 大于 0.4)后,TPR 逐渐趋于稳定并逼近 1.0,意味着模型在追求高召回率时仍能维持可接受的精度,这对降低渗流监测中的漏报风险尤为重要。相比于随机猜测(图 6 中蓝色虚线,AUC 值为 0.5),该模型显著提升了异常值检测的准确性,能够为大坝安全监测提供可靠的异常预警依据。

针对工程实践中异常形态复杂多样的特点,单一依赖整体 AUC 值评估难以全面反映模型性能。因此,本文进一步对孤立异常、连续异常与混合异常 3 类典型异常场景进行独立测试。如表 1 所示,VMD-LSTM-VAE 模型在各类异常场景下均表现出较高的识别精度,尤其在孤立与连续异常场景下保持了 100%的精确率,表明该模型具有良好的泛化能力和实际应用潜力。然而,在混合异常等复杂场景下,其检测效果略有下降,表明该模型仍有改进空间。

表 1 不同类型异常场景的检测效果

异常类型	精确率/%	召回率/%	F1 分数/%	AUC
孤立异常	100	90.1	94.8	0.908
连续异常	100	88.9	94.1	0.899
混合异常	90	83.9	86.8	0.890

从量化指标看,模型在 3 种典型异常场景下均取得了优良效果。其精确率始终保持在 90%以上,展现出优异的异常识别能力,有效降低了误报风险;召回率与 F1 分数虽在不同场景下存在波动,但整体保持稳定,体现了良好的鲁棒性,具备较强的工程适应性。

为验证模型的有效性,选取 LSTM、VAE、Z-score 及 K 近邻(KNN)4 种方法进行对比,并采用精确率、召回率、F1 分数和 AUC 4 项指标开展全面评估。这些指标分别从检测精度、异常覆盖率、整体平衡性和多阈值分类能力等维度衡量性能。具体对比结果见表 2。

表 2 不同方法的评价指标对比

方法	精确率/%	召回率/%	F1 分数/%	AUC
LSTM	86.9	88.8	87.8	0.805
VAE	85.3	89.4	87.3	0.794
Z-score	81.1	84.1	82.6	0.766
KNN	83.4	83.8	83.6	0.778
VMD-LSTM-VAE	96.7	87.6	91.9	0.899

由表 2 可知,深度学习模型(LSTM 和 VAE)在异常值检测任务中的整体表现优于传统方法(Z-score 和 KNN),表明深度学习方法在处理非线性时间序列监测数据方面具有一定优势。相比之下,本文提出的 VMD-LSTM-VAE 模型在精确率、F1 分数和 AUC 等指标上均取得较优结果,其中精确率为 96.7%,F1 分数为 91.9%,AUC 为 0.899,说明该组合模型在复杂异常值识别中具有较好的检测性能和稳定性。本文提出的 VMD-LSTM-VAE 模型融合了多种算法优势,构建了性能较优的异常值检测方案。VMD 模块通过自适应信号分解提取多尺度特征,为后续建模提供了具有物理意义的输入表示;LSTM 模块用于捕捉时间序列中的长期依赖关系,增强了模型对渗流监测序列时序特征的学习能力;VAE 模块通过特征压缩与重构,在低维潜变量空间中学习数据的潜在分布,提高了模型对异常值样本的识别能力。

具体而言,VMD-LSTM-VAE 模型在以下 3 个关键指标上表现出明显优势:①在精确率方面,该模型表现出较高的异常值判别准确性,有效降低了误报风险;②在 F1 分数方面,该模型在精确率和召回率之间取得了较好的平衡,综合检测性能较优;③在 AUC 指标方面,该模型在不同判别阈值下均具有较稳定的分类性能。

此外,模型在不同测试场景下表现出的稳定性,进一步表明了其良好的鲁棒性,为工程实践中的渗流异常值检测提供了新的解决方案,对于实际工程应用具有重要意义。

3 结 语

针对大坝渗流监测数据异常值检测面临的挑战,提出了 VMD-LSTM-VAE 组合模型。该模型有效整合了多尺度特征提取与深度时序学习能力。VMD 成功地将原始渗流序列分解为反映不同时间尺度动态的本征模态函数。双层 LSTM 网络深度捕获了各模态分量的复杂时序依赖特征。VAE 模块则通过特征空间的压缩与重构,建立了鲁棒的重构误差基准,为异常值检测提供了核心判据。该融合架构为处理非线性、非平稳渗流监测数据的异常值检测提供了一种新的解决方法。实例验证结果表

明,所提模型在孤立异常、连续异常及混合异常场景的检测中均表现出较好的识别效果,F1 分数分别为 94.8%、94.1%和 86.8%,AUC 值分别为 0.908、0.899 和 0.890。与 LSTM、VAE、Z-score 和 KNN 等方法相比,VMD-LSTM-VAE 模型在精确率、F1 分数和 AUC 等综合评价指标上表现更优,这说明基于重构造误差的动态阈值机制能够有效提升模型对复杂异常模式的识别敏感性与时效性。

参考文献:

[1] 郑霞忠,陈国梁,邹韬.考虑时间序列关联的大坝监测异常数据清洗[J].水力发电,2020,46(4):111-114. (Zheng Xiazhong, Chen Guoliang, Zou Tao. Cleaning of abnormal dam monitoring data considering time series association[J]. Water Power, 2020, 46(4): 111-114. (in Chinese))

[2] 宋锦焄,葛佳豪,杨杰,等.基于时空聚类和深度学习的混凝土坝变形异常值识别方法[J].水利水电科技进展,2024,44(4):65-71. (Song Jintao, Ge Jiahao, Yang Jie, et al. A method for identifying deformation outliers in concrete dams based on spatio-temporal clustering and deep learning[J]. Advances in Science and Technology of Water Resources, 2024, 44(4): 65-71. (in Chinese))

[3] 廖攀,李晓庆,顾昊,等.耦合 GAT 和 TCN 的土石坝渗流监测数据异常检测模型[J].水利水电科技进展,2025,45(6):85-90. (Liao Pan, Li Xiaoqing, Gu Hao, et al. Anomaly detection model for seepage monitoring data of earth-rock dams based on coupled GAT and TCN[J]. Advances in Science and Technology of Water Resources, 2025, 45(6): 85-90. (in Chinese))

[4] Audibert J, Michiardi P, Guyard F, et al. Do deep neural networks contribute to multivariate time series anomaly detection? [J]. Pattern Recognition, 2022, 132: 108945.

[5] 叶斌.基于 LSTM 模型的大坝安全监测数据异常值检测[D].武汉:长江科学院,2020.

[6] 余红玲,王晓玲,程正飞,等.大坝渗流安全监测数据异常检测的改进 DSAE 模型[J].水力发电学报,2023,42(10):128-138. (Yu Hongling, Wang Xiaoling, Cheng Zhengfei, et al. Improved DSAE model for anomaly detection of dam seepage safety monitoring data [J]. Journal of Hydroelectric Engineering, 2023, 42(10): 128-138. (in Chinese))

[7] 熊敏,江德军,高志良,等.大坝监测数据多维度 LSTM 异常检测与恢复[J].电子测量技术,2023,46(6):51-56. (Xiong Min, Jiang Dejun, Gao Zhiliang, et al. Dam monitoring data multi-dimensional LSTM anomaly detection and recovery [J]. Electronic Measurement Technology, 2023, 46(6): 51-56. (in Chinese))

[8] Lin S, Clark R, Birke R, et al. Anomaly detection for time

series using VAE-LSTM hybrid model [C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona: IEEE, 2020: 4322-4326.

[9] Ou Bin, Zhang Caiyi, Xu Bo, et al. Innovative approach to dam deformation analysis: integration of VMD, fractal theory, and WOA-DELM [J]. Structural Control and Health Monitoring, 2024, 2024(1): 1710019.

[10] 岳明昊,刘仲鹏,欧斌,等.大坝监测数据缺失插补与奇异值修正处理[J].农业工程,2022,12(7):47-51. (Yue Minghao, Liu Zhongpeng, Ou Bin, et al. Missing interpolation and singular value correction of dam monitoring data [J]. Agricultural Engineering, 2022, 12(7): 47-51. (in Chinese))

[11] 许秋鸿,刘晓青.基于 VMD-XGBoost-GRU 模型的危岩体变形预测[J].水利水电科技进展,2024,44(2):92-98. (Xu QiuHong, Liu Xiaoqing. Deformation prediction of dangerous rock mass based on VMD-XGBoost-GRU model [J]. Advances in Science and Technology of Water Resources, 2024, 44(2): 92-98. (in Chinese))

[12] 张建中,顾冲时,袁冬阳,等.基于优化 VMD 与 GRU 的混凝土坝变形预测模型[J].水利水电科技进展,2023,43(5):38-44. (Zhang Jianzhong, Gu Chongshi, Yuan Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU [J]. Advances in Science and Technology of Water Resources, 2023, 43(5): 38-44. (in Chinese))

[13] Wei Y, Jang-Jaccard J, Xu W, et al. LSTM-autoencoder-based anomaly detection for indoor air quality time-series data[J]. IEEE Sensors Journal, 2023, 23(4): 3787-3800.

[14] 黎伟,赵二峰,何菁.大坝变形监测异常数据识别和重构模型[J].水利水电科技进展,2023,43(2):109-114. (Li Yi, Zhao Erfeng, He Jing. Abnormal data identification and reconstruction model of dam deformation monitoring [J]. Advances in Science and Technology of Water Resources, 2023, 43(2): 109-114. (in Chinese))

[15] 荆志朋,柴林杰,胡诗尧.基于改进 LSTM-VAE 的配电网异常负荷检测方法研究[J].电测与仪表,2024,61(9):71-76. (Jing Zhipeng, Chai Linjie, Hu Shiyao. Research on abnormal load detection method for distribution network based on improved LSTM-VAE [J]. Electrical Measurement & Instrumentation, 2024, 61(9): 71-76. (in Chinese))

[16] 杨英,唐平. VAE-LSTM 算法在时间序列预测模型中的研究[J].湖南科技大学学报(自然科学版),2020,35(3):93-101. (Yang Ying, Tang Ping. Research of VAE-LSTM algorithm in time series prediction model [J]. Journal of Hunan University of Science and Technology (Natural Science), 2020, 35(3): 93-101. (in Chinese))

(下转第 109 页)

efficient channel attention for deep convolutional neural networks [C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle:IEEE,2020;11534-11542.

[17] 施慧慧,徐雁南,滕文秀,等. 高分辨率遥感影像深度迁移可变形卷积的场景分类法 [J]. 测绘学报,2021,50 (5):652-663. (Shi Huihui,Xu Yannan,Teng Wenxiu,et al. Scene classification of high-resolution remote sensing imagery based on deep transfer deformable convolutional neural networks [J]. Acta Geodaetica et Cartographica Sinica,2021,50 (5):652-663. (in Chinese))

[18] 何旺,钮新强,田金章,等. 基于 MobileNetV2-DeepLabv3+的混凝土坝水下裂缝语义分割模型 [J]. 水利水电科技进展,2024,44 (6):106-112. (He Wang,Niu Xinqiang,Tian Jinzhang,et al. Semantic segmentation model for underwater cracks in concrete dams based on MobileNetV2-DeepLabv3+[J]. Advances in Science and Technology of Water Resources,2024,44 (6):106-112. (in Chinese))

[19] Li C Y,Li L L,Jiang H L,et al. YOLOv6:a single-stage object detection framework for industrial applications [J/OL]. arXiv: 2209. 02976, 2022. <https://doi.org/10.48550/arXiv.2209.02976>.

[20] 叶栢铖,朱尤攀,周永康,等. 轻量级目标检测算法综述 [J]. 红外技术,2025,47 (3):289-298. (Ye Baicheng,Zhu Youpan,Zhou Yongkang,et al. Review of lightweight object detection algorithms [J]. Infrared Technology,2025,47 (3):289-298. (in Chinese))

[21] Liu Yahui,Yao Jian,Lu Xiaohu,et al. DeepCrack:a deep hierarchical feature learning architecture for crack segmentation [J]. Neurocomputing,2019,338:139-153.

[22] 高文飞. 基于 CW-YOLOv5 网络的大坝裂缝检测研究 [J]. 水利技术监督,2024 (12): 30-33. (Gao Wenfei. Research on dam crack detection based on CW-YOLOv5 network [J]. Technical Supervision in Water Resources,2024 (12):30-33. (in Chinese))

[23] Hou Qibin,Zhou Daquan,Feng Jiashi. Coordinate attention for efficient mobile network design [C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 13713-13722.

[24] Woo S,Park J,Lee J Y,et al. CBAM:convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich: Springer,2018;3-19.

[25] Hu Jie, Shen Li, Sun Gang. Squeeze-and-excitation networks [C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE,2018;7132-7141.

[26] Ren Shaoqing, He Kaiming, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39 (6):1137-1149.

[27] Liu Wei, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [C]//European Conference on Computer Vision. Amsterdam:Springer,2016;21-37.

[28] Farhadi A, Redmon J. YOLOv3: an incremental improvement [C]//Computer Vision and Pattern Recognition. Berlin:Springer,2018,1804:1-6.

[29] Wang C Y,Bochkovskiy A,Liao H Y M. YOLOv7;trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver:IEEE,2023;7464-7475.

[30] Ultralytics. YOLOv8 (2023) [EB/OL]. (2023-04-01). <https://github.com/ultralytics/ultralytics>. (收稿日期:2025-03-25 编辑:俞云利)

(上接第 99 页)

[17] 欧斌,张才溢,陈德辉,等. 基于改进 EMD-LSTM 的混凝土坝变形预测模型 [J]. 水利水电科技进展,2024,44 (6):93-99. (Ou Bin,Zhang Caiyi,Chen Dehui,et al. Deformation prediction model for concrete dams based on improved EMD-LSTM [J]. Advances in Science and Technology of Water Resources,2024,44 (6):93-99. (in Chinese))

[18] 赵宇,郑东健,冉成,等. 基于 QR-KOA-ITransformer-BiLSTM 的混凝土坝变形和变形区间预测模型 [J]. 河海大学学报 (自然科学版),2026,54 (2):102-108. (Zhao Yu,Zheng Dongjian,Ran Cheng,et al. Concrete dam deformation and deformation interval prediction model based on QR-KOA-ITransformer-BiLSTM [J]. Journal of Hohai University (Natural Sciences),2026,54 (2):102-108. (in Chinese))

[19] 王译玲,丁勇,李登华. 耦合 DWT-IFLOF 的大坝监测数据异常检测算法 [J]. 中国农村水利水电,2024 (7):203-209. (Wang Yiling,Ding Yong,Li Denghua. Anomaly detection algorithm for dam monitoring data coupled with DWT-IFLOF [J]. China Rural Water and Hydropower,2024 (7):203-209. (in Chinese))

[20] 李元梦,李登华,丁勇. 基于 DBSCAN 的大坝安全监测异常数据检测算法 [J]. 水电能源科学,2024,42 (1):149-152. (Li Yuanmeng,Li Denghua,Ding Yong. Abnormal data detection algorithm for dam safety monitoring based on DBSCAN [J]. Water Resources and Power,2024,42 (1):149-152. (in Chinese))

(收稿日期:2025-03-18 编辑:俞云利)