

文章编号: 2097-096X(2026)03-0306-13

基于DEGAN和SHAP的水电机组异常检测研究

陈欣^{1,2}, 张卫君^{1,2}, 李建辉^{1,2}, 闫亚男², 刘晓波^{1,2}, 陈小松²

(1. 中国水利水电科学研究院, 北京 100048; 2. 北京中水科水电科技开发有限公司, 北京 100038)

摘要: 针对水电站监控系统中固定阈值法在复杂工况下异常检测灵敏度低、难以实现有效预警的问题, 本文提出了一种基于生成对抗网络判别器与密度估计的特征增强异常检测模型(FEAD-DEGAN)。该模型将卷积与全局平均池化方法用于优化判别器结构, 强化时序特征提取, 并结合动态阈值策略与核密度估计算法, 提升检测灵敏度。以轴流转浆式机组受油器摆度异常数据样本为研究对象, 通过与孤立森林和自编码器方法进行对比验证, 所提方法在异常检测成功率与误报率方面表现更优。进一步采用SHAP解释方法对监测指标的异常贡献度进行量化, 提升了模型的可解释性, 有助于故障溯源和检修策略优化, 有效辅助了水电机组设备故障诊断和智慧化运维。

关键词: 水电机组; 异常检测; DEGAN; SHAP; 受油器摆度

中图分类号: TV734

文献标识码: A

doi: 10.13244/j.cnki.jiwhr.20250087

1 研究背景

水电机组作为水电站的核心设备, 其运行状态直接影响发电效率和系统安全^[1]。水电机组运行工况受电网调度、设备老化、环境变化等因素影响, 异常检测对于保障机组的安全稳定运行至关重要^[2]。目前, 固定报警阈值法仍是水电站监控系统中机组异常报警的常用手段, 其既缺乏对复杂工况的动态适应能力, 也无法在异常发生初期实现预警^[3-4]。随着大中型水电站“无人值班(少人值守)”方式的逐步推进以及大数据技术的迅速发展, 基于机器学习的智能异常检测成为水电行业的研究热点^[5-7]。受监测数据高维、非线性等特性影响, 传统方法在处理复杂异常检测任务时存在局限性^[8-10]。

近年来, 深度学习方法因其能通过多层神经网络自动提取复杂特征, 减少人工特征工程依赖, 在自动特征提取和异常识别方面展现出显著的优势^[11-14]。目前, 基于深度学习的异常检测方法可分为深度学习特征提取、正常性特征表示学习和端到端异常评分学习三类^[15]。在深度学习特征提取方法中, 深度学习模型用于从高维或非线性可分的数据中提取低维特征表示, 再结合传统的异常检测方法(如SVM、聚类等)进行异常评分。代表性算法包括自编码器及其变体算法^[16-18], 通过重构误差进行异常检测, 适用于图像和高维数据处理。正常性特征表示学习方法通过学习正常数据的潜在特征表示, 结合异常评分进行异常检测。生成对抗网络(Generative Adversarial Network, GAN)^[19]及其变体模型是该方法的典型代表。端到端异常评分学习方法则通过神经网络端到端地进行异常评分学习, 将特征表示与异常评分优化相结合。常见的算法包括基于深度学习的单类支持向量机和深度支持向量数据描述, 通过优化特征表示与异常评分一体化, 有效处理高维数据和复杂数据结构。深度学习模型普遍存在黑箱特性, 即其通过多层非线性变换实现的端到端预测过程缺乏透明性, 具体表现为隐层特征空间与输入数据的语义关联断裂、输出决策依据难以追溯, 异常检测结果缺乏可解释性, 难以量化各监测指标对异常状态的贡献^[20]。SHAP(Shapley Additive Explanations)是由Lundberg等^[21]在2017年提出的一种基于博弈论的模型解释方法, 能够有效解析模型决策过程, 量化各监测指标在异常检测中的影响, 提升

收稿日期: 2025-04-07; 网络首发时间: 2025-05-21

网络首发地址: <https://link.cnki.net/urlid/10.1788.tv.20250521.1335.001>

基金项目: 中国水利水电科学研究院基本科研项目(AU0145C012024, AU0145B012021)

作者简介: 陈欣(2000—), 硕士生, 主要从事水电及新能源设备故障智能诊断与预警等研究。E-mail: chenxin@edu.iwhr.com

通信作者: 李建辉(1963—), 正高级工程师, 主要从事水电及新能源自动化控制系统等研究。E-mail: Li_jh@iwhr.com

模型的透明性和诊断能力。

在正常性特征表示学习方法中, GAN因其强大的数据生成能力, 近年来已成为无监督异常检测的重要工具^[22-25], 其变体模型在异常检测中表现突出。如, Akcay等^[26]提出的 GANomaly 模型结合编码器-解码器结构, 显著优化了模型在无标签图像异常检测中的效果。Li等^[27]结合长短期记忆网络进行多变量时间序列异常检测, 提高了工业数据中的检测精度。时间序列异常检测的难点在于其动态时序依赖性与正常模式的高度不确定性。传统基于重构误差的方法易受噪声干扰, 只依赖判别器输出的方法难以量化异常置信度。生成对抗网络判别器与密度估计(Generative Adversarial Network Discriminators and Density Estimation, DEGAN)^[28]通过独立训练的判别器提取时序特征的空间分布, 再运用核密度估计(Kernel Density Estimation, KDE)构建多维联合概率密度函数作为异常评分依据。显著提升了复杂工况下异常检测的鲁棒性。然而, 现有的 DEGAN 仍存在局限性: 判别器未能充分捕捉时间序列数据的局部与全局特征, 限制了对关键异常模式的学习能力, 同时固定检测参数降低了模型的自适应能力, 影响其泛化性和适用性。

本文提出了一种改进的基于 DEGAN 的特征增强异常检测模型(Feature-Enhanced Anomaly Detection based on DEGAN, FEAD-DEGAN), 以水电机组受油器摆度异常作为研究对象, 验证 FEAD-DEGAN 在关键指标异常检测中的有效性, 并与孤立森林(Isolation Forest)和自编码器(Autoencoder)进行对比实验。通过对 FEAD-DEGAN 异常检测结果进行 SHAP 解释分析, 进一步揭示机组异常的潜在机理, 为水电机组智慧化运维提供了新思路。

2 DEGAN 和 SHAP 解释方法

FEAD-DEGAN 模型是在 DEGAN 模型基础上进行结构与参数优化得到的。本文以 FEAD-DEGAN 模型训练得到的判别器作为解释对象, 引入 SHAP 方法, 对异常检测结果进行特征贡献度分析。

2.1 DEGAN GAN 由两个主要的神经网络组成: 生成器(G)和判别器(D)。G 的目标是生成接近真实的样本, 使 D 无法分辨其真伪。D 接受输入数据(真实数据和生成数据), 并输出数据为真实数据的概率 $D(x)$ 。以尽可能正确地识别真实样本与生成样本。

GAN 的训练过程基于一个极小化和极大化的博弈, 生成器和判别器在对抗中相互优化。其目标是使生成器生成的样本在判别器看来无法区分于真实数据。具体的损失函数定义为:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log (1 - D(G(z)))] \quad (1)$$

式中: E 表示数学期望运算; $x \sim p_{data}(x)$ 表示 x 的样本是依据数据分布 $p_{data}(x)$ 随机获取的; $z \sim p_z(z)$ 表示随机变量 z 服从分布 $p_z(z)$; $D(x)$ 是判别器对真实样本 x 的输出, 表示真实样本的概率; $D(G(z))$ 是判别器对生成样本 $G(z)$ 的输出, 表示该样本被认为是真实样本的概率。

GAN 的优化最终达到纳什均衡时, 即 $D(G(z)) \approx 0.5$, 此时生成器成功获得了真实数据分布。

DEGAN 是基于 GAN 的异常检测模型(结构如图 1 所示), 利用正常时间序列数据训练判别器, 使




图1 DEGAN网络结构图

Fig. 1 The structural diagram of the DEGAN network

其成为独立的异常预测器，结合滑动窗口处理与KDE，有效提升时间序列异常检测的准确性与可靠性。

以两层Dense神经网络作为基础模型，输入层为从固定标准高斯分布(范围0到1)抽取的随机值，采用两个全连接层，以Tanh激活层结尾。判别器则采用一维卷积模型(CNN-D)，由一个卷积层、两个全连接层组成，Conv1D输出经扁平化处理输入全连接层。Conv1D层公式如式(2)所示：

$$y_i = \sum_{j=0}^{k-1} \omega_j x_{i+j} + b \quad (2)$$

式中： y_i 是输出特征图在位置 i 的值； ω_j 是卷积核的权重； x_{i+j} 是输入数据在位置 $i+j$ 的值； k 是卷积核的大小； b 是偏置项。

判别器目标如式(3)所示：

$$D_{DEGAN}(x) = p_{\text{model}}(x) \quad (3)$$

式中： $D_{DEGAN}(x)$ 是判别器输出的概率密度； $p_{\text{model}}(x)$ 是数据的真实分布。判别器通过估计数据的概率密度来判定数据是否为正常样本。

异常检测中，对于可能异常的数据点，采用核密度估计生成概率密度函数。给定有限的异常数据点 $(x_1, x_2, \dots, x_n)$ ，其密度函数 $\hat{f}_h(x)$ 估计公式如式(4)所示：

$$\hat{f}_h(x) = \frac{1}{n} \sum_{i=1}^n K_h(x - x_i) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (4)$$

式中： $K(\cdot)$ 为非负核函数；带宽 $h > 0$ 控制平滑程度。

2.2 SHAP方法 基于博弈论中的Shapley值，SHAP通过公平分配所有特征组合对预测结果的边际贡献，量化每个特征在模型决策中的重要性，具有局部准确性、缺失性和一致性三个性质。具体地，SHAP使用公式(5)来计算特征 i 的重要性值：

$$\phi_i(f, x) = \sum_{S \subseteq F \setminus \{i\}} \frac{|S| \cdot (|F| - |S| - 1)!}{|F|!} \left[f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S) \right] \quad (5)$$

式中： S 表示特征子集； F 表示全部特征集合； f_S 是在子集 S 上的模型输出。

SHAP值符号表示正向或负向影响，绝对值大小表示影响程度。

本文采用SHAP方法对FEAD-DEGAN的输出结果进行解释，以揭示各指标对指定指标异常检测结果的贡献程度与影响机制，揭示模型的“决策过程”。

3 融合FEAD-DEGAN与SHAP的异常检测方法

本文提出了一种基于FEAD-DEGAN模型的多元参数异常诊断方法，针对单一参数异常诊断的局限性，进一步引入多元相关变量，深入挖掘各个参数之间的相互关系及其对目标参数异常检测的影响机制，从而提升目标指标异常检测的准确性和鲁棒性。同时结合SHAP方法，揭示各指标对检测结果的贡献程度和内在影响机制，整体优化流程结构如图2所示。

3.1 FEAD-DEGAN结构优化 在实际数据应用中，FEAD-DEGAN模型着重对DEGAN模型结构进行了优化。主要体现在以下两方面：

(1) 生成器结构适配

调整生成器为与输入特征维度匹配的网络结构，提升生成样本的质量，更好地捕捉输入数据的特征分布。生成器的输入层为从固定标准高斯分布中抽取的随机值，经过中间层的处理后，输出层神经元数量与输入数据维度相匹配，确保生成器能够更好地学习输入数据的特征表示。

(2) 判别器特征提取增强

在判别器网络中，结合一维卷积层(Conv1D)和全局平均池化(GlobalAveragePooling1D)方法进行模型优化。首先使用Conv1D来处理输入的时间序列数据，提取局部特征，捕捉到输入序列中的局部模




图2 整体优化技术流程

Fig. 2 Flow chart of the overall optimization technology

式和时序依赖关系，然后使用 GlobalAveragePooling1D 对卷积输出的特征进行池化操作，在减少了模型的复杂度和计算开销基础上，强化模型对全局特征的感知，从而增强判别器对真实和生成数据的分辨能力，推动生成器学习到更真实的数据结构。GlobalAveragePooling1D 层公式如式(6)所示：

$$y = \frac{1}{n} \sum_{i=1}^n x_i \quad (6)$$

式中： y 是输出值； x_i 是输入数据在位置 i 的值； n 是输入数据的长度。其输出为与输入数据维度一致的重构值，便于计算多特征的重构误差，为异常检测提供了更精确的判断依据。

生成器和判别器的详细结构设置见表1。

3.2 异常检测机制优化 为了提高异常检测的准确性和及时性，本文引入了异常检测机制优化措施。

(1)动态阈值自适应调整 在异常检测模型的构建中，FEAD-DEGAN模型引入了动态阈值设定机制，使得异常检测能够自适应数据的分布变化。根据重构误差的均值和标准差进行调整，自动应对不同数据分布的变化，避免人工设置固定阈值的局限性，公式如式(7)所示：

$$dynamic_ano_thr = mean_error + c * std_error \quad (7)$$

式中： $mean_error$ 是预测误差均值； std_error 是标准差； c 是一个可调整的系数。

(2)KDE与峰值检测优化引入KDE平滑重构误差的分布，有效减少数据中的噪声干扰，使指定指标的异常点更加凸显。同时加入find_peaks函数进一步减少噪声的影响，提高了异常点的检测精度。

表1 生成器和判别器详细结构

Table 1 Generator and discriminator detailed structure

网络	层类型	神经元/卷积通道数	激活函数	选择依据
生成器	Dense	64	tanh	适用于归一化
	Dense	113	tanh	保持数值范围
	Conv1D	8通道	ReLU	避免梯度消失
判别器	Global AveragePooling1D	-	-	提取全局特征
	Dense	8	linear	适用于数值回归
	Dense	113	linear	预测原始特征值

3.3 SHAP分析 将FEAD-DEGAN模型训练好的判别器作为解释对象。通过SHAP的DeepExplainer方法，将训练数据作为背景数据输入模型，捕获模型对特征的整体判断逻辑；再使用测试数据作为具体待解释样本输入模型，计算得到每个特征SHAP值。SHAP值反映了每个特征对判别器输出异常评分的具体贡献程度，明确模型如何依据各个特征来识别异常，提高FEAD-DEGAN模型的可解释性。

4 实例分析

4.1 数据介绍 本文选取一台立式轴流转桨式机组的受油器X向摆度异常越限报警事件作为研究对象，以同时期监控系统数据作为样本集，开展模型在水电机组异常诊断中的应用研究。

(1)机组受油器结构：其作用是将桨叶主配压阀输出的压力油从静止的压力油管路可靠地传递到与桨叶接力器相连接的旋转油管，同时将旋转油管内的回油经受油器传回静止的回油管路，实现压力油与回油在静止部分与旋转部分之间的稳定传输。

可通过操作油管将操作桨叶的压力油输送到桨叶接力器以控制桨叶角度，使水轮机能够适应不同的水头和流量工况^[29]，如受油器简化结构图(图3)与机组整体结构图(图4)所示。

图4可见受油器与其他部件的关系。从整体来看，受油器、上导轴承、水导轴承及推力机架均共用一根主轴，其动态特性相互耦合并产生联动效应。

(2)样本选取：由于机组的稳定性与工况参数密切相关^[30-31]，不同工况下的数据需分别处理。本文选取机组稳定运行区数据，将机组有功功率与水头数据进行网格划分。本文选取水头在35~37 m、有功功率为100~150 MW、机组转速为89~90 rpm的一个月处于发电状态的分钟级数据作为研究样本。根据机组稳定性要求，选取振动、摆度、四部轴承温度等关键监测指标(见表2)，部分指标对应多个测点，最后共选取113个维度数据。

4.2 异常诊断结果 FEAD-DEGAN模型异常检测结果如图5所示，实际数据的核密度估计分数在分布密度较高或变化较快的区域呈现明显的波动趋势，异常点主要集中在KDE曲线的波峰或波谷附近。

为了进一步验证FEAD-DEGAN模型的检测性能，本文选取了孤立森林(Isolation Forest)和自编码器(Autoencoder)作为对比基准，分别代表基于孤立性假设的无监督异常检测方法和基于数据重构误差的深度学习方法。

孤立森林主要通过随机选择特征和划分子空间来评估数据点的孤立程度，适用于单指标的异常检测^[32]，而自编码器通过构建低维潜在空间表示并重构输入数据，以计算重构误差来判断异常^[33]。对比结果如图6所示。




图3 受油器结构示意图

Fig. 3 Structural diagram of the oil head




图4 轴流转桨式水轮发电机组结构图

Fig. 4 Structural diagram of the Kaplan turbine generator unit

尽管固定阈值不能作为判断异常的唯一标准，但其在一定程度上可以用于评估模型的检测效果。三个模型异常检测结果对比情况见表3。

数据中共有73个报警点，FEAD-DEGAN、Isolation Forest和Autoencoder检测成功率分别为100%，84.9%和37.0%。FEAD-DEGAN在检测中能够成功覆盖所有报警点，Autoencoder的漏报率较高。在预测方面，FEAD-DEGAN能够提前预测异常趋势，大部分橙色点(即未报警但检测出的异常点)在后续时间均触发报警，表明该模型具有较好的预警能力。其预测准确率达到84%，显示出较高的检测可靠性。Isolation Forest可实现部分高值预警，但存在低值预警的误报情况。在水电机组稳定性分析中，摆度、振动等稳定性指标主要关注高值异常，因此低值预警可能影响实用性。Autoencoder在一些时间段内的预警能力优于另外两种算法，能够更早地识别出异常时间点，但同时检测出了大量低值异常，与水电机组稳定性相关指标的实际异常特征不符。

Isolation Forest分裂过程中首先随机选一个特征，在该特征的范围内随机选一个阈值进行切分，这种方式未考虑不同特征之间的联合关系、相互依赖或时序模式^[32]，因此在水电机组稳定性相关异常检测应用中可能产生误报。Autoencoder更为关注数值匹配而非结构模式^[33]，能够学习到数据的低维表

表2 机组稳定性关键监测指标

Table 2 Key monitoring indicators for unit stability

大部件 组成	大部子项部件组成	测点指标组成
水轮机	水导	水导轴承瓦温
		水导油槽温度
		水导油槽油位
		水导摆度 X 向
		水导摆度 Y 向
	顶盖	顶盖压力脉动
		顶盖振动 X
		顶盖振动 Y
		顶盖振动 Z
	导水机构	蜗壳进口压力脉动
		尾水锥管压力脉动
		尾水肘管压力脉动
发电机	机架	上机架振动 X
		上机架振动 Y
		上机架振动 Z
		推力机架振动 X
		推力机架振动 Y
		推力机架振动 Z
	定子振动	定子机架振动 X
		定子机架振动 Y
		定子铁芯水平振动
		定子铁芯垂直振动
	上导轴承	上导摆度 X 向
		上导摆度 Y 向
		上导轴承瓦温
		上导油槽油位
		上导油槽油温
	推力轴承	推力轴承摆度 X 向
		推力轴承摆度 Y 向
		推力轴承瓦温
		推力油槽油位
		推力油槽油温
	下导轴承	下导摆度 X 向
		下导摆度 Y 向
		下导轴承瓦温
		下导油槽油位
		下导油槽油温




图5 受油器摆度x方向异常检测结果

Fig. 5 Abnormal detection results of the oil head's swing amplitude in the x direction

示，但在面对高维和非线性特征时难以识别特征之间的复杂依赖关系，影响了异常检测的成功率，并导致对低值异常过度敏感。FEAD-DEGAN倾向于捕捉全局或结构性异常，单一维度或局部的“低值”不足以显著影响整体误差，在机组稳定性相关指标异常检测中的适配性更优。

综上所述，FEAD-DEGAN在本文异常检测任务中表现最优，能够准确检测出所有报警点，并提前识别部分异常趋势，同时避免了低值误报的情况，适用于水电机组摆度异常的智能诊断。

5 结合SHAP的特征分析与异常原因推断

本文将FEAD-DEGAN模型训练好的判别器作为解释对象，得到受油器X向摆度异常结果的影响因素重要性排序，图7中可以看出，除自身以及对应的受油器Y向摆度影响外，上导轴瓦和油槽温度、水导摆度以及推力机架垂直振动对模型预测影响程度高，其余指标影响很小，因此未在图中全部展示。

SHAP特征摘要如图8所示，当SHAP值为正时，表明该因子对异常状态的发生起到促进作用；当SHAP值为负时，说明该因子对异常状态的发生具有抑制作用。


指标的高值样本(红色)显著拉高SHAP值，表明这些指标超出正常范围的波动会直接推动模型判定为异常状态，低值样本(蓝色)多分布于SHAP负值区域，表明当相关指标处于正常低区间时，模型倾向于判定为正常状态，符合稳定性指标异常判断逻辑。

上导轴瓦温度贡献值显著高于其他特征，高值样本(红色密集区)SHAP值集中于正向区间(>0)，说明温升与摆度存在显著正相关关系，更符合运行激励引发的热—振耦合放大效应。模型通过捕捉温度与摆度的时序关联，揭示了受油器浮动瓦偏磨的潜在故障模式。这一异常力学状态更可能是由运行激励引发的热—振耦合放大效应传导至其他部件，水导Y向摆度作为次高贡献因子，其高值样本的正向SHAP值反映了与操作油管径向受力随动的关联性。FEAD-DEGAN通过多变量时序特征学习，识别了主轴在负荷扰动下对水导摆度的传导效应。尽管推力机架与受油器无直接连接，但其振动高值样本的SHAP正向贡献表明FEAD-DEGAN捕捉到了主轴轴向力波动传递的耦合特征，指向推力轴承热稳定性下降的可能性。


根据厂站固定阈值报警系统的历史记录，仅受油器摆度指标触发了报警，其他指标未出现显著异常。SHAP影响因素排序图中未见下导轴承相关指标，说明受油器振摆异常主要与运行工况激励和热—振耦合相关，不能完全排除液压系统脉动的影响，推测由水力或液压激励导致的动态放大效应可能性最高。

结合巡检记录可知，受油器传感器状态正常，仅操作油管表面存在轻微磨损。这一发现进一步印证了异常推断的准确性。


综上所述，推测受油器摆度异常是由水力脉动激励引发的热—振耦合放大，使受油器摆度先行超限，油管出现随动轻微磨损。SHAP方法增强了FEAD-DEGAN模型的可解释性，结合理论和实际设备运行规律验证了模型异常检测过程的合理性和可靠性。



(a) FEAD-DEGAN



(b) Isolation Forest



(c) Autoencoder

图6 异常检测结果与实际阈值报警结果对比

Fig. 6 Comparison of anomaly detection results and actual threshold alarms

表 3 异常检测结果对比

Table 3 Comparison of anomaly detection results

统计结果	FEAD-DEGAN	Isolation Forest	Autoencoder
未报警但检测异常点数量(橙色圆形)	25	40	30
报警未检测出点数量(红色方形)	0	11	46
报警已检测出点数量(绿色三角形)	73	62	27




图 7 影响因素重要性排序

Fig. 7 Ranking of the importance of influencing factors




图 8 SHAP 特征摘要

Fig. 8 SHAP feature summary

6 结论

本文针对水电机组监测数据的高维复杂性,提出了一种基于FEAD-DEGAN与SHAP解释方法的水电机组异常检测方法。并以受油器摆度异常为研究对象进行验证。通过实验分析与工程应用,主要得

出以下结论:

(1)FEAD-DEGAN 模型在 DEGAN 基础上经过判别器结构优化,实现时间序列局部-全局特征的协同挖掘,有效学习了多维指标的关系,提升了异常检测的准确性和稳定性。

(2)在机组受油器摆度实验中,FEAD-DEGAN 在高维、复杂时序数据的异常检测中能够准确覆盖所有报警点,提前预测异常趋势,并有效避免低值误报。

(3)引入 SHAP 方法量化多指标对异常状态的贡献度。揭示 FEAD-DEGAN 判定受油器摆度异常过程中上导轴瓦温度、水导 Y 向摆度、推力机架垂直振动起主要贡献作用,基于此结合巡检记录等推测受油器摆度异常更可能是由水力激振或液压系统压力脉动等运行激励导致的热-振耦合效应所致。

(4)FEAD-DEGAN 结合 SHAP 解释方法,实现了在水电机组异常状态的智能诊断的基础上构建了“检测-解释-推因”的融合分析框架。

参 考 文 献:

- [1] 周建平, 杜效鹄, 周兴波. “十四五”水电开发形势分析、预测与对策措施[J]. 水电与抽水蓄能, 2021, 7(1): 1-5. (ZHOU Jianping, DU Xiaohu, ZHOU Xingbo. Situation analysis, prediction and countermeasures of hydropower development during the 14th five-year period[J]. Hydropower and Pumped Storage, 2021, 7(1): 1-5. (in Chinese))
- [2] DE SANTIS R B, GONTIJO T S, COSTA M A. Condition-based maintenance in hydroelectric plants: A systematic literature review[J]. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 2022, 236(5): 631-646.
- [3] 张飞, 潘罗平, 安学利. 水轮发电机组稳定性参数统计特性与监测报警阈值研究[J]. 水力发电学报, 2013, 32(5): 269-272, 293. (ZHANG Fei, PAN Luoping, AN Xueli. Study on statistical characteristics and maintenance alarm strategy for stability parameters of hydraulic turbine generator unit[J]. Journal of Hydroelectric Engineering, 2013, 32(5): 269-272, 293. (in Chinese))
- [4] 段炼达, 刘晓波. 基于摆度大数据的水轮发电机故障预测方法研究[J]. 中国水利水电科学研究院学报, 2017, 15(6): 439-443. (DUAN Lianda, LIU Xiaobo. Study on failure prediction for hydro-generator based on big data of run-out value[J]. Journal of China Institute of Water Resources and Hydropower Research, 2017, 15(6): 439-443. (in Chinese))
- [5] 齐敏芳. 大数据技术及其在电站机组分析中的应用[D]. 北京: 华北电力大学, 2016. (QI Minfang. Big data technology and its application on the analysis of power plant units[D]. Beijing: North China Electric Power University, 2016. (in Chinese))
- [6] 张婷婷, 王斌, 王坤, 等. 基于增强层次对称点图像分析和深度残差网络的水电机组故障诊断[J]. 水利学报, 2023, 54(11): 1380-1391. (ZHANG Tingting, WANG Bin, WANG Kun, et al. Fault diagnosis of hydropower units based on enhanced hierarchical Symmetrized Dot Pattern and Resnet50[J]. Journal of Hydraulic Engineering, 2023, 54(11): 1380-1391. (in Chinese))
- [7] 张兼博, 李想, 曾云, 等. TSMSE 结合 IOOA-BiLSTM 的水电机组轴系故障诊断方法[J]. 水利学报, 2024, 55(7): 862-873. (ZHANG Jianbo, LI Xiang, ZENG Yun, et al. TSMSE combined with IOOA-BiLSTM for the fault diagnosis method of hydropower unit shafting[J]. Journal of Hydraulic Engineering, 2024, 55(7): 862-873. (in Chinese))
- [8] 曹晨曦, 田友琳, 张昱堃, 等. 基于统计方法的异常点检测在时间序列数据上的应用[J]. 合肥工业大学学报(自然科学版), 2018, 41(9): 1284-1288. (CAO Chenxi, TIAN Youlin, ZHANG Yukun, et al. Application of statistical methods in outlier detection for time series data[J]. Journal of Hefei University of Technology (Natural Science), 2018, 41(9): 1284-1288. (in Chinese))
- [9] 吴杰辉, 柳毅. 面向多元时间序列的联合优化异常检测模型[J]. 计算机工程, 2025, 51(9): 166-176. (WU Jiehui, LIU Yi. Jointly optimized anomaly detection model for multivariate time series[J]. Computer Engineering, 2025, 51(9): 166-176. (in Chinese))
- [10] 黄训华, 张凤斌, 樊好义, 等. 基于多模态对抗学习的无监督时间序列异常检测[J]. 计算机研究与发展,

- 2021, 58(8): 1655–1667. (HUANG Xunhua, ZHANG Fengbin, FAN Haoyi, et al. Multimodal adversarial learning based unsupervised time series anomaly detection[J]. Journal of Computer Research and Development, 2021, 58(8): 1655–1667. (in Chinese))
- [11] 张鹏锋. 基于深度学习的电厂设备运行参数异常检测[D]. 武汉: 华中科技大学, 2020: 5–15). (ZHANG Pengfeng. Anomaly detection of power plant equipment operating parameters based on deep learning[D]. Wuhan: Huazhong University of Science and Technology, 2020: 5–15). (in Chinese))
- [12] 唐杰阳, 唐凡, 杨东, 等. 水电站计算机监控系统综合智能告警研究[J]. 中国水利水电科学研究院学报(中英文), 2022, 20(4): 377–385. (TANG Jieyang, TANG Fan, YANG Dong, et al. Research on comprehensive intelligent alarm of computer monitoring system of hydropower station[J]. Journal of China Institute of Water Resources and Hydropower Research, 2022, 20(4): 377–385. (in Chinese))
- [13] 潘罗平, 安学利, 周叶. 基于大数据的多维度水电机组健康评估与诊断[J]. 水利学报, 2018, 49(9): 1178–1186. (PAN Luoping, AN Xueli, ZHOU Ye. Multi-dimension health assessment and diagnosis of hydropower unit based on big data[J]. Journal of Hydraulic Engineering, 2018, 49(9): 1178–1186. (in Chinese))
- [14] 周叶, 唐澍, 潘罗平. HM9000ES水电机组故障诊断专家系统的设计与开发[J]. 中国水利水电科学研究院学报, 2014, 12(1): 104–108. (ZHOU Ye, TANG Shu, PAN Luoping. Design and development of HM9000ES fault diagnosis expert system for hydropower units[J]. Journal of China Institute of Water Resources and Hydropower Research, 2014, 12(1): 104–108. (in Chinese))
- [15] PANG G S, SHEN C H, CAO L B, et al. Deep learning for anomaly detection: A review[J]. ACM Computing Surveys, 2022, 54(2): 1–38.
- [16] 黄光球, 赵梦娜, 陆秋琴. 融合时域卷积网络和深度自编码器的VOCs数据异常检测[J]. 安全与环境学报, 2023, 23(10): 3749–3759. (HUANG Guangqiu, ZHAO Mengna, LU Qiuqin. VOCs data anomaly detection based on time-domain convolutional network and depth self-encoder[J]. Journal of Safety and Environment, 2023, 23(10): 3749–3759. (in Chinese))
- [17] AUDIBERT J, MICHIARDI P, GUYARD F, et al. USAD: UnSupervised anomaly detection on multivariate time series[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Virtual Event CA USA. ACM, 2020: 3395–3404.
- [18] WANG H T, LIU X W, MA L Y, et al. Anomaly detection for hydropower turbine unit based on variational modal decomposition and deep autoencoder[J]. Energy Reports, 2021, 7: 938–946.
- [19] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139–144.
- [20] GUIDOTTI R, MONREALE A, RUGGIERI S, et al. A survey of methods for explaining black box models[J]. ACM Computing Surveys, 2019, 51(5): 1–42.
- [21] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Advances in Neural Information Processing Systems 31 (NeurIPS 2017). Long Beach, CA, USA: Curran Associates, Inc., 2017.
- [22] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//International conference on machine learning. PMLR, 2017.
- [23] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. F-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 54: 30–44.
- [24] BASHAR M A, NAYAK R. TAnoGAN: Time series anomaly detection with generative adversarial networks[C]//2020 IEEE Symposium Series on Computational Intelligence (SSCI). Canberra, ACT, Australia. IEEE, 2020: 1778–1785.
- [25] LI Y F, PENG X Y, ZHANG J, et al. DCT-GAN: Dilated convolutional transformer-based GAN for time series anomaly detection[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(4): 3632–3644.
- [26] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. GANomaly: Semi-supervised anomaly detection via adversarial training [M]//Computer Vision – ACCV 2018. Cham: Springer International Publishing, 2019: 622–637.
- [27] LI D, CHEN D C, JIN B H, et al. MAD-GAN: Multivariate anomaly detection for time series data with generative adversarial networks[M]//Artificial Neural Networks and Machine Learning – ICANN 2019: Text and Time Series.

Cham: Springer International Publishing, 2019: 703–716.

- [28] GU Y Y, JAZIZADEH F. Time series anomaly detection using generative adversarial network discriminators and density estimation for infrastructure systems[J]. Automation in Construction, 2024, 165: 105500.
- [29] 梁召. 水轮发电机组受油器振动异常分析与处理[J]. 广西水利水电, 2017(6): 66–69. (LIANG Zhao. Analysis and treatment of oil head abnormal vibration for bulb turbine generator unit [J]. Guangxi Water Resources & Hydropower Engineering, 2017(6): 66–69. (in Chinese))
- [30] 刘希琛, 阚光远, 丁留谦, 等. 新安江模型参数优化的一种约束 SCE-UA 算法研究[J]. 中国水利水电科学研究院学报(中英文), 2023, 21(5): 434–443, 465. (LIU Xichen, KAN Guangyuan, DING Liuqian, et al. Study on a constrained SCE-UA algorithm for parameter optimization of the Xinanjiang model[J]. Journal of China Institute of Water Resources and Hydropower Research, 2023, 21(5): 434–443, 465. (in Chinese))
- [31] 孙天野, 王忠静, 祝宝山. 盐环定扬黄灌区五泵站运行优化研究[J]. 中国水利水电科学研究院学报(中英文), 2024, 22(1): 97–107. (SUN Tianye, WANG Zhongjing, ZHU Baoshan. Optimization study on the operation of No. Five Pumping Station in the Yanhuan Dingyang Yellow River irrigation district[J]. Journal of China Institute of Water Resources and Hydropower Research, 2024, 22(1): 97–107. (in Chinese))
- [32] LIU F T, TING K M, ZHOU Z H. Isolation forest[C]//2008 Eighth IEEE International Conference on Data Mining. Pisa, Italy. IEEE, 2009: 413–422.
- [33] KINGMA D P, WELLING M. Auto-encoding Variational Bayes[C]//2nd International Conference on Learning Representations (ICLR). 2014.

Research on anomaly detection of hydropower units based on DEGAN and SHAP

CHEN Xin^{1,2}, ZHANG Weijun^{1,2}, LI Jianhui^{1,2}, YAN Yanan², LIU Xiaobo^{1,2}, CHEN Xiaosong²

(1. China Institute of Water Resources and Hydropower Research, Beijing 100048, China; 2. Beijing IWHR Technology Co., Ltd, Beijing 100038, China)

Abstract: In hydropower station monitoring systems, fixed threshold methods are commonly used for over-limit alarms, but they exhibit low sensitivity in complex conditions, making early warnings difficult. This paper proposes a feature-enhanced anomaly detection (FEAD-DEGAN) model based on generative adversarial network discriminator and density estimation (DEGAN). Convolution and global average pooling methods optimize the discriminator structure, enhancing time-series feature extraction. The dynamic threshold strategy and kernel density estimation improve detection sensitivity. The model is validated with abnormal oil head swing amplitude data from an axial-flow pump-turbine unit. Compared with Isolation Forest and Autoencoder, the proposed approach shows better performance in anomaly detection success rate and false alarm rate. SHAP quantifies the contribution of monitoring indicators to anomalies, identifying key factors that influence abnormal behavior and enhancing process interpretability. This supports root cause analysis and facilitates the optimization of maintenance strategies, thereby contributing to more effective fault diagnosis and intelligent maintenance.

Keywords: hydropower unit; anomaly detection; DEGAN; SHAP; oil head swing amplitude

(责任编辑: 祁 伟)