

引用格式:王智弘,熊富强,左佳文,等.基于软约束潜在正则化对抗的高压并联电抗器异常声音检测[J].电力科学与技术学报,2026,41(1):307-318.
Citation: WANG Zhihong, XIONG Fuqiang, ZUO Jiawen, et al. Anomaly sound detection of high-voltage shunt reactors based on soft-constrained latent regularized adversarial learning[J]. Journal of Electric Power Science and Technology, 2026, 41(1): 307-318.

基于软约束潜在正则化对抗的高压并联 电抗器异常声音检测

王智弘^{1,2}, 熊富强^{1,2}, 左佳文³, 唐明珠³, 章健军^{1,2}, 唐星昱^{1,2}

(1. 国网湖南省电力有限公司超高压变电公司, 湖南长沙 410004; 2. 变电智能运检国网湖南省电力有限公司实验室, 湖南长沙 410004;
3. 长沙理工大学能源与动力工程学院, 湖南长沙 410114)

摘要:随着高压并联电抗器在电力系统中的广泛应用,其运行过程中产生的异常现象逐渐引起关注。现有潜在正则化对抗异常检测(latent regularization adversarial anomaly detection, LRAAD)方法中,超参数 M 对生成器生成频谱图的KL散度上限施加了硬约束,导致模型难以在潜在空间中有效区分正常数据和异常数据,会给模型训练带来不稳定和异常检测效果不足的问题。对此,提出了一种软约束潜在正则化对抗异常检测(Soft-LRAAD)方法,Soft-LRAAD方法引入软约束损失来替代硬约束损失,通过使用平滑函数逼近KL散度上限,增强了模型在潜在空间中的区分能力和训练的稳定性。实验结果表明,Soft-LRAAD方法有效提升了高压并联电抗器异常检测的准确性和鲁棒性,为电力设备故障诊断提供了更优的解决方案。

关键词:声学异常检测;半监督学习;对抗学习;潜在变量正则化对抗

DOI: 10.19781/j.issn.1673-9140.2026.01.029 中图分类号: TM46 文章编号: 1673-9140(2026)01-0307-12

Anomaly sound detection of high-voltage shunt reactors based on soft-constrained latent regularized adversarial learning

WANG Zhihong^{1,2}, XIONG Fuqiang^{1,2}, ZUO Jiawen³, TANG Mingzhu³,
ZHANG Jianjun^{1,2}, TANG Xingyu^{1,2}

(1. State Grid Hunan Extra High Voltage Substation Company, Changsha 410004, China; 2. Substation Intelligent Operation and Inspection Laboratory of State Grid Hunan Electric Power Co., Ltd., Changsha 410004, China; 3. College of Energy and Power Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: With the widespread application of high-voltage shunt reactors in power systems, abnormal phenomena arising during their operation have attracted increasing attention. In existing latent regularization adversarial anomaly detection (LRAAD) methods, the hyperparameter M imposes a hard constraint on the upper bound of the KL divergence of generator-produced spectrograms, which hampers the model's ability to effectively distinguish normal from abnormal data in the latent space, leading to training instability and degraded anomaly detection performance. To address this issue, this paper proposes a soft-constrained latent regularization adversarial anomaly detection (Soft-LRAAD) method. The proposed method introduces a soft constraint loss to replace the hard constraint loss, and enhances the discrimination capability in the latent space and the training stability by approximating the upper bound of the KL divergence using a smooth function. Experimental results demonstrate that the proposed method effectively improves the accuracy and robustness of anomaly detection for high-voltage shunt reactors, providing a superior

收稿日期: 2024-03-06; 修回日期: 2024-07-15

基金项目: 国网湖南省电力科技项目(5216A3220019)

通信作者: 唐明珠(1983—), 男, 博士, 教授, 主要从事超特高压换流阀、电力变压器状态监测与智能评估等研究; E-mail: tmzhu@163.com

solution for power equipment fault diagnosis.

Key words: acoustic anomaly detection; semi-supervised learning; adversarial learning; latent variable regularized adversarial learning

高压并联电抗器在特高压变电站中起着至关重要的作用,其主要功能是补偿无功功率,稳定电网电压,防止电力系统中过电压的发生^[1-4]。由于特高压变电站运行环境复杂,高压并联电抗器在长期运行过程中可能会出现各种故障,如电弧放电、绕组松动、机械振动等^[5-6]。这些故障往往伴随着异常的声音信号,因此对高压并联电抗器进行异常声音检测,对于保障电力系统的安全和可靠运行具有重要意义^[7]。

目前,针对高压并联电抗器的异常检测方法主要包括油色谱检测、超声局放检测和高频局放检测。这些方法虽然在一定程度上能够帮助识别设备内部的潜在故障,但也存在着一些局限性。油色谱检测是一种相对成熟的故障诊断方法,主要通过分析油中的气体组分来判断设备内部是否存在放电或过热问题^[8]。尽管油色谱分析能够提供关于放电或过热故障的早期预警信息,但其检测周期较长,实时性差,且难以反映电抗器的瞬时状态变化。此外,油色谱检测对早期和微小故障的敏感度较低,可能导致故障发展到较严重阶段时才被检测到。超声检测通过捕捉电抗器内局部放电产生的超声波信号来检测异常^[9],高频检测利用高频电磁波信号检测电抗器内部的局部放电现象^[10]。

这些方法在检测高压设备中的局部放电方面具有较高的灵敏度,尤其是在设备内部绝缘材料老化或发生局部放电时可以提供较准确的诊断结果^[11]。然而,这些方法的检测精度和灵敏度容易受到环境噪声和外部干扰的影响,尤其是在复杂的电磁环境中,检测结果可能存在不稳定性^[12]。此外,超声和高频局放检测在检测机械故障和设备的振动问题时,效果较为有限,难以全面反映高压并联电抗器的运行状态。

相比之下,基于声学信号的检测方法能够同时监测设备运行中的机械和电气故障,且不受油质变化和局放信号的限制,具有更强的实时性和鲁棒性^[13-16]。本文基于潜在正则化对抗异常检测(latent regularization adversarial anomaly detection, LRAAD)方法提出软约束潜在正则化对抗异常检测方法(Soft-LRAAD),其结合深度学习模型在声

学信号分析中的优势,能够有效提高高压并联电抗器故障检测的精度和可靠性。

现有研究已经涵盖了多种声学异常检测方法和相关技术。其中,一些方法依赖传统的信号处理技术,而另一些方法则利用了深度学习和人工智能等新兴技术^[17-18]。传统的信号处理方法通常包括特征提取、模式识别和分类等步骤,使用滤波器、时频域分析、频谱分析等技术来提取声音信号的特征,并使用分类器(如支持向量机、k最近邻等)来识别异常。尽管传统方法在某些情况下取得了一定的成果,但其局限性在于依赖人工特征设计和手动调整参数,且难以处理复杂的非线性关系和大规模数据^[19-20]。

近年来,随着深度学习技术的发展,基于自编码器的方法在电力设备声学异常检测领域取得了显著的进展^[21-25]。文献[23]提出了一种基于卷积自编码器(convolutional autoencoder, CAE)的工业过程声学异常检测方法。该方法使用对数刻度的梅尔频谱特征作为模型的输入特征。与传统的异常检测方法单类支持向量机(one-class support vector machine, OCSVM)^[26]相比,CAE方法在工业过程中表现出了更好的异常检测效果。基于变分自编码器(variational autoencoder, VAE)的异常检测方法^[24-25]通过引入潜在变量和KL散度来学习数据的潜在表示,从而提高了模型的泛化能力。文献[24]提出了一种基于VAE的异常检测方法,该方法通过训练一个VAE模型来学习正常数据的潜在表示,然后使用KL散度来衡量正常数据和异常数据之间的差异。

基于生成对抗网络(generative adversarial network, GAN)的异常检测方法在异常检测领域取得了显著的进展。文献[27]提出了一种基于GAN的异常检测方法AnoGAN,该方法通过对正常样本进行建模来识别异常。AnoGAN方法使用迭代方法寻找图像在潜在空间的表示。f-AnoGAN方法^[28]在AnoGAN方法的基础上进行了改进,通过学习从图像到潜在空间的映射,显著提高了速度。文献[29]提出了一种名为GANomaly的新型编码器-解码器-编码器架构模型,其同时使用重构损

失、潜在表示损失和对抗损失来训练模型和进行异常分数计算。实验表明,其性能优于当代最先进的基于 GAN 和传统自编码器的异常检测方法,具有泛化到任何异常检测任务的能力。文献[30]提出了一种利用 GAN 进行机器音频异常检测的无监督模型。研究表明,通过引入鉴别器来提供特征级别的指导,该模型可以更深入地理解表示,不仅关注表面噪声,还解决了 CAE 可能会重构出异常信号的问题。文献[31]提出了 LRAAD 方法,该方法的判别器引入了 KL 散度量度机制,使编码器能够通过潜在空间表征与标准正态分布的偏离度判别输入频谱图的真实性和真实性。这种判别方式使得编码器在判别过程中同步提取关键声纹特征,指导生成器合成更逼真的训练样本,从而学习到更真实的数据分布。

LRAAD 方法通过硬约束来控制潜在空间的 KL 散度上限,这种硬约束虽然可以帮助模型在潜在空间中区分正常数据和异常数据,但也容易导致模型在训练过程中出现不稳定,影响最终的检测效果。此外,硬约束的引入还可能使生成的潜在空间不够灵活,难以捕捉异常数据的多样性和复杂性^[31]。

为了解决这些问题,本文提出了 Soft-LRAAD 方法。该方法通过引入软约束损失函数,替代 LRAAD 方法中的硬约束损失函数,从而在潜在空间中更灵活地处理正常数据和异常数据的分布问题。这种改进不仅提高了模型的训练稳定性,也增强了模型在不同工况下的异常检测性能。此外,本文在特高压变电站的实测声音数据集上对所提出的方法进行了实验验证。结果表明,Soft-LRAAD 方法在异常检测任务中表现出优异的性能,显著优于传统方法。

本文的主要贡献包括以下几点。

1) 提出了异常检测方法 Soft-LRAAD,通过软边界的方式来控制生成器生成频谱图的 KL 散度上界,极大地提高了正常数据和异常数据在潜在空间的分离效果,从而提高了异常检测的准确性和鲁棒性。

2) 设计了基于 KL 散度损失和重构损失的异常分数,相比于仅使用重构损失作为异常分数的方法,基于 KL 散度和重构损失的异常分数能够更好地区分正常数据和异常数据,提高了异常检测的性能。

3) 使用特高压变电站的实测声音数据对模型

进行了验证,实验结果表明,Soft-LRAAD 方法在不同负载条件下均表现出较高的异常检测准确率和鲁棒性。

1 基于 LRAAD 的异常检测方法

1.1 证据下界

证据下界(evidence lower bound, ELBO)是变分推断(variational inference, VI)领域中的核心概念,用于优化概率模型中的潜在变量分布,以有效逼近真实数据分布。ELBO 提供了一种有效的方法来近似计算数据对数似然函数的下界,是训练 VAE 以及其他基于变分推断模型的重要优化目标,可表示为

$$f_{\text{ELBO}}(x) = E_{q_{\phi}(z|x)}(\log p_{\theta}(x|z)) - D_{\text{KL}}(q_{\phi}(z|x) \| p(z)) \quad (1)$$

式中, $f_{\text{ELBO}}(x)$ 为证据下界; E 表示期望; $q_{\phi}(z|x)$ 表示由编码器定义的近似后验分布; $p_{\theta}(x|z)$ 表示由解码器定义的生成数据的条件概率分布; $p(z)$ 表示潜在变量的先验分布(通常假设为标准正态分布); $D_{\text{KL}}(\cdot)$ 为 KL 散度。ELBO 的优化目标是在最大化数据生成对数似然性的同时,尽量减小近似后验分布 $q_{\phi}(z|x)$ 与潜在变量先验分布 $p(z)$ 之间的差异; θ 、 ϕ 分别为解码器和编码器的网络参数; x 、 z 分别为输入数据和潜在空间中的潜在变量。

ELBO 由以下两部分组成。

1) 重构误差项: $E_{q_{\phi}(z|x)}(\log p_{\theta}(x|z))$ 。

该项指标用于衡量模型生成样本 x 的质量,其目标是提高模型对原始数据的拟合能力。

2) 正则化项(KL 散度项): $-D_{\text{KL}}(q_{\phi}(z|x) \| p(z))$ 。

该项用于确保潜在变量的近似后验分布与先验分布之间的差距最小化,从而规范潜在空间结构,增强模型的泛化能力。

通过优化 ELBO,模型能够自动学习潜在变量空间中的有效表示,既能有效重构输入数据,又能确保潜在空间表示的良好分布特性,使模型具有更好的泛化性能。在式(1)中,最大化重构误差项 $E_{q_{\phi}(z|x)}(\log p_{\theta}(x|z))$ 即最小化 $\|x - x'\|^2$,故 ELBO 的计算也可表述为

$$f_{\text{ELBO}}(x) = -\|x - x'\|^2 - D_{\text{KL}}(q_{\phi}(z|x) \| p(z)) \quad (2)$$

式中, x 为原始输入的频谱; x' 为生成器生成的频谱。

1.2 基于LRAAD的异常检测方法

LRAAD模型结合了对抗学习和潜在变量模型的优势,能够有效地提取数据的深层次特征,实现对异常模式的高精度识别。LRAAD模型通过编码器和生成器来学习正常数据的潜在表示,并通过对抗学习的方式来区分正常数据和异常数据。LRAAD模型的核心思想是通过最小化正常数据的潜在表示与标准正态分布之间的KL散度来学习将正常数据映射到潜在空间中的正态分布,同时将异常数据映射到潜在空间中的非正态分布。通过这种方式,LRAAD模型可以更好地区分正常数据和异常数据,从而实现异常检测的目的。LRAAD模型的训练流程如图1所示。其中,E代表编码器,G代表生成器。




图1 LRAAD模型的训练流程

Figure 1 Training pipeline of LRAAD model

记 $D_{KL}(x) = D_{KL}(q(\cdot|x)p(\cdot))$ 。其中, $q(\cdot|x)$ 表示编码器编码频谱图 x 的潜在表示的分布, $p(\cdot)$ 表示标准正态分布, 即 $\mathcal{N}(0, I)$ 。

$$\mathcal{L}_E = \|x - x'\|^2 + D_{KL}(x) + [M - D_{KL}(x')]^+ + [M - D_{KL}(x'')]^+ \quad (3)$$

$$\mathcal{L}_G = \|x - x'\|^2 + D_{KL}(x') + D_{KL}(x'') \quad (4)$$

式中, \mathcal{L}_E 、 \mathcal{L}_G 分别为编码器损失函数和生成器损失函数; M 为一个超参数, 用于控制KL散度的上限, 避免生成图像的KL散度无穷大; $[M - D_{KL}(\cdot)]^+$ 表示生成图像的KL散度的约束项, 定义为 $\max(0, M - D_{KL}(\cdot))$ 。

将式(3)、(4)代入式(2), 且生成器训练过程中生成器对真实数据的KL散度为常量, 则编码器损

失函数和生成器损失函数可以等价地表示为

$$\mathcal{L}_E = -f_{ELBO}(x) + [M - D_{KL}(x')]^+ + [M - D_{KL}(x'')]^+ \quad (5)$$

$$\mathcal{L}_G = -f_{ELBO}(x) + D_{KL}(x') + D_{KL}(x'') \quad (6)$$

然而, LRAAD方法中硬约束的引入容易导致模型训练不稳定, 影响最终的检测效果。为了解决这一问题, 本文提出了一种基于软约束潜在正则化对抗学习的高压并联电抗器异常检测方法 Soft-LRAAD。Soft-LRAAD方法用软约束损失替代硬约束损失, 提高了模型在潜在空间中区分正常数据和异常数据的能力, 增强了模型训练的稳定性, 从而提升了整体性能。

2 基于Soft-LRAAD的异常检测方法

2.1 Soft-LRAAD方法

Soft-LRAAD方法是一种改进的异常检测方法, 旨在克服LRAAD方法中因硬约束导致的潜在空间区分能力不足和模型训练不稳定的问题。硬约束的引入会在潜在空间中设置严格的边界, 使得生成图像的KL散度限制在边界 M 之下, 限制了模型的表现。而软约束通过使用平滑函数来逼近KL散度的上限, 从而缓解了这种限制, 使得模型能够在保持生成图像质量的同时, 更好地在潜在空间中分离正常数据和异常数据。通过引入软约束损失函数, Soft-LRAAD方法不仅能够更有效地区分正常数据和异常数据, 还提高了模型的训练稳定性。

图2、3分别展示了LRAAD模型的KL散度硬约束函数以及Soft-LRAAD模型的KL散度软约束函数。Soft-LRAAD方法使用一个平滑的函数 $\frac{1}{\alpha} \exp(-\alpha D_{KL}(x))$ 来逼近KL散度的上限约束损失 $[M - D_{KL}(x)]^+$ 。具体来说, Soft-LRAAD方法使用软约束损失函数 $\frac{1}{\alpha} \exp(-\alpha D_{KL}(x')) + \frac{1}{\alpha} \exp(-\alpha D_{KL}(x''))$ 来替代LRAAD方法中的硬约束损失 $[M - D_{KL}(x')]^+ + [M - D_{KL}(x'')]^+$ 。其中 α 是一个可调节的超参数, 用于控制软约束项的影响程度。相比于硬约束, 软约束的函数图像呈现出平滑递减的趋势, 这样的设计使得损失在KL散度接近阈值时依旧缓慢降低, 而不是像硬约束那样保持不变, 使得生成图像的KL散度可以变大, 但又不

至于无穷大。通过这种方式,Soft-LRAAD方法能够更好地保持生成图像的质量,同时提高模型的异常检测性能。




图 2 LRAAD 模型的 KL 散度硬约束函数

Figure 2 KL divergence hard constraint function in LRAAD model




图 3 Soft-LRAAD 模型的 KL 散度软约束函数

Figure 3 KL divergence soft constraint function in Soft-LRAAD model

Soft-LRAAD 方法的编码器损失函数 \mathcal{L}'_E 和生成器损失函数 \mathcal{L}'_G 分别定义如下:

$$\mathcal{L}'_E = -f_{\text{ELBO}}(x) + \frac{1}{\alpha} \exp(-\alpha D_{\text{KL}}(x')) + \quad (7)$$

$$\frac{1}{\alpha} \exp(-\alpha D_{\text{KL}}(x''))$$

$$\mathcal{L}'_G = -f_{\text{ELBO}}(x) + D_{\text{KL}}(x') + D_{\text{KL}}(x'') \quad (8)$$

对于 KL 散度项,增加一个重构损失项可以更好地保持生成图像的质量,同时提高模型的异常检测性能。通过这种方式,Soft-LRAAD 方法能够更好地区分正常数据和异常数据,提高异常检测的准确性和鲁棒性:

$$\mathcal{L}'_E = -f_{\text{ELBO}}(x) + \frac{1}{\alpha} \exp(\alpha f_{\text{ELBO}}(x')) + \quad (9)$$

$$\frac{1}{\alpha} \exp(\alpha f_{\text{ELBO}}(x''))$$

$$\mathcal{L}'_G = -f_{\text{ELBO}}(x) - f_{\text{ELBO}}(x') - f_{\text{ELBO}}(x'') \quad (10)$$

软约束对模型训练的影响主要体现在以下几个方面:首先,软约束使得潜在变量在潜在空间中的分布更加灵活,增强了模型对正常数据和异常数据的区分能力;其次,软约束的引入有助于模型在训练过程中更加稳定,避免了硬约束可能导致的梯

度不连续和训练不稳定问题;最后,通过调节参数 α ,可以灵活控制软约束对 KL 散度的惩罚力度,进一步优化模型性能。

2.2 模型训练

Soft-LRAAD 模型的结构与 LRAAD 模型类似,包括编码器 E、生成器 G 两个部分。编码器 E 负责将输入的梅尔频谱图 x 映射到潜在空间,生成器 G 负责将潜在变量映射回梅尔频谱域,实现频谱图的重建。Soft-LRAAD 模型的训练流程如图 4 所示。

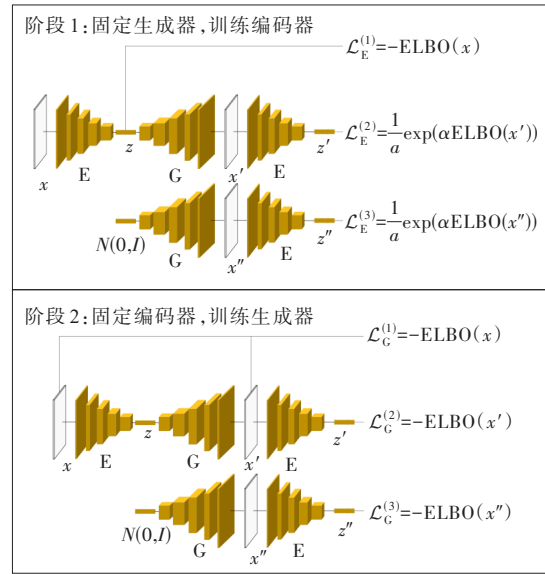


图 4 Soft-LRAAD 模型的训练流程

Figure 4 Training pipeline of Soft-LRAAD model

Soft-LRAAD 模型的训练过程主要包括编码器 E 和生成器 G 的训练,具体的训练流程如下。

- 1) 初始化编码器和生成器网络参数。
- 2) 对于每个 epoch:从数据集中随机抽取小批量数据 X 。
- 3) 计算 X 的潜在表示: $Z = E(X)$ 。
- 4) 从先验分布 $p(z) = \mathcal{N}(0, I)$ 中采样 Z_p 。
- 5) 计算 Z 和 Z_p 的重构频谱图: $X' = G(Z)$, $X'' = G(Z_p)$ 。
- 6) 计算 X' 和 X'' 的潜在表示: $Z' = E(X')$, $Z'' = E(X'')$ 。
- 7) 根据式(9)计算编码器损失 \mathcal{L}'_E 。
- 8) 通过最小化 \mathcal{L}'_E 更新编码器参数。
- 9) 根据式(10)计算生成器损失 \mathcal{L}'_G 。
- 10) 通过最小化 \mathcal{L}'_G 更新生成器参数。
- 11) 结束循环。

Soft-LRAAD 模型的编码器与生成器以对抗的

方式进行训练,通过最小化编码器和生成器的损失函数来优化模型参数。通过交替训练编码器和生成器,Soft-LRAAD模型的编码器能更好地区分正常数据和异常数据,生成器能更好地重建输入的频谱图,从而提高异常检测的准确性和鲁棒性。

2.3 异常检测

Soft-LRAAD方法采用重构误差和KL散度之和作为异常分数。重构误差衡量生成频谱图与原始输入频谱图之间的差异,而KL散度则衡量潜在表示与标准正态分布之间的差异。正常数据的重构误差较小,其潜在表示接近标准正态分布;而异常数据的重构误差较大,其潜在表示远离标准正态分布。通过结合这两个指标,模型能够更准确地识别异常数据。异常分数定义如下:

$$\mathcal{A}(x) = \|x - G(P(x))\|^2 + D_{\text{KL}}(P(x) \parallel \mathcal{N}(0, I)) \quad (11)$$

式中, $\mathcal{A}(x)$ 为输入频谱图 x 的异常分数; $P(x)$ 为输入频谱图 x 的潜在表示; $G(P(x))$ 为潜在表示 $P(x)$ 的重构频谱图; $D_{\text{KL}}(P(x) \parallel \mathcal{N}(0, I))$ 为潜在表示 $P(x)$ 与标准正态分布之间的KL散度。本方法通过计算异常分数,可以对输入频谱图 x 进行异常检测,判断其是否为异常数据。

3 实验分析

3.1 数据集描述

本实验的数据集来源于高压并联电抗器。在该设备中,高压并联电抗器的A相发生故障,这台高压并联电抗器的A、B、C三相的声音信号可以作为模型的训练和测试数据。

图5展示了传声器的安装位置。传声器环绕高压并联电抗器设备布置,安装在距离高压并联电抗器本体约0.1 m的位置,从四周对高压并联电抗器的A、B、C三相进行声音监测;通过在各相周围近距离分布传声器,捕捉高压并联电抗器在不同运行状态下的声学特征信号,为后续分析与异常检测提供可靠的数据来源。




图5 传声器的安装位置示意

Figure 5 Installation position of microphone

音频数据的主要处理步骤如下。

1) 梅尔频谱图转换:将音频片段转化为梅尔频谱图,以更直观地反映声音信号的频谱特征。梅尔频谱图采用梅尔刻度的横轴和功率谱的纵轴,更符合人类听觉特性。

2) 对数变换与归一化:对梅尔频谱图进行对数变换,以压缩幅度动态范围,突出低频信号的细节。同时,对数据进行归一化处理,以优化模型的训练效果。

为确保数据集的多样性和代表性,录音过程中尽可能覆盖了高压并联电抗器在各种运行状态下的声音信号。视在功率范围对应的数据集如表1所示。根据设备运行时的视在功率范围,处理后的数据被划分为6个子数据集,分别对应不同的视在功率。每个子数据集均包含正常和异常状态的声音信号样本,以支持模型在多工况下的异常检测性能评估。图6展示了数据采集现场的情况。

表1 视在功率范围对应的数据集

Table 1 Dataset corresponding to different apparent power ranges

数据集	视在功率范围/(MV·A)
Dataset 1	400~500
Dataset 2	500~600
Dataset 3	600~700
Dataset 4	700~800
Dataset 5	800~900
Dataset 6	900~1 000



图6 数据采集现场

Figure 6 Data collection site

3.2 实验设置

在训练 Soft-LRAAD模型时,需要设置多个超参数来调节模型的性能,如编码器和生成器的学习率、损失函数的权重系数(重构损失、对抗损失、KL散度损失的权重)、潜在空间的维度大小、软约束系数、训练的迭代次数等。本实验中采用的超参数设置如表2所示。

表 2 Soft-LRAAD 模型超参数设置

Table 2 Hyperparameter settings of Soft-LRAAD model

超参数	设置值
潜在空间维度	32
学习率(编码器)	0.000 2
学习率(生成器)	0.000 2
重构损失权重	1
对抗损失权重	1
KL散度损失权重	1
软约束系数 α	128×128
Epochs	100

3.3 实验结果

本文将基于 Soft-LRAAD 模型在高压并联电

抗器声音信号异常检测任务中的实验结果与其他传统深度学习模型进行了对比分析,主要关注模型的检测精度、鲁棒性以及在不同负载条件下的表现。为了量化各模型的性能,本文使用了接受者操作特性(receiver operating characteristic, ROC)、曲线下面积(area under curve, AUC)、部分 AUC(p-AUC)、混淆矩阵和精确率-召回率(precision-recall, PR)等评估指标。实验结果显示,Soft-LRAAD 模型在多个实验数据集上均表现出优异的检测性能。

图 7 展示了不同模型在不同数据集上的 ROC 曲线。实验中,Soft-LRAAD 模型的 ROC 曲线明显

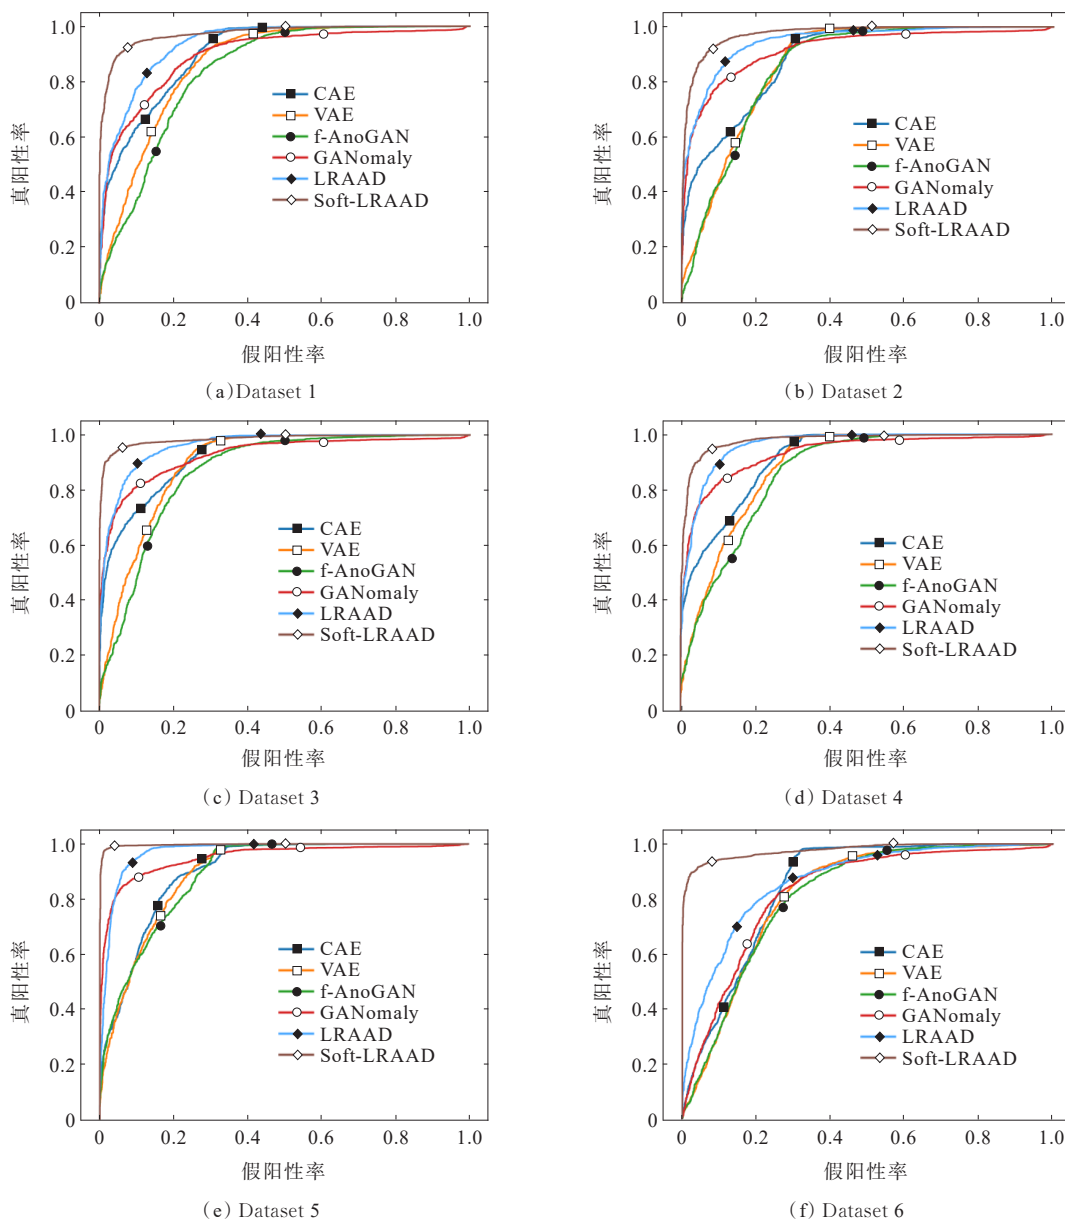


图 7 不同模型在不同数据集上的 ROC 曲线

Figure 7 ROC curves of different models on different datasets

优于传统方法和其他深度学习模型,曲线整体上更接近左上角,表明其不同阈值下均能有效区分正常数据和异常数据。在6个不同的数据集上,Soft-LRAAD模型的ROC曲线始终处于其他模型之上,表现出更高的真阳性率(true positive rate, TPR)和更低的假阳性率(false positive rate, FPR)。这说明,Soft-LRAAD模型在检测电抗器运行中产生异常声音信号时,能够更准确地识别出异常,并有效降低误报率。

值得注意的是,在Dataset 6上,Soft-LRAAD模型的ROC曲线出现显著提升的现象,Dataset 6在

正常数据和异常数据之间的差异相对更明显。Soft-LRAAD模型通过在潜在空间中引入软约束来控制KL散度,能够更加灵活地处理正常数据和异常数据的分布。当数据中正常样本与异常样本的差异更明显时,这种灵活性使得模型能更有效地捕捉这种差异并进行区分。实验结果表明,对于像Dataset 6这种与异常数据差异较为明显的数据集,Soft-LRAAD模型能够更有效地进行区分,因此其表现得更加优秀,AUC也显著提高。

表3~6分别展示了不同模型在不同数据集上的AUC和p-AUC结果。

表3 不同模型的AUC结果

Table 3 AUC results of different models on different datasets

数据集	AUC					
	CAE	VAE	f-AnoGAN	GANomaly	LRAAD	Soft-LRAAD
Dataset 1	0.903 2	0.866 2	0.840 0	0.896 6	0.936 1	0.974 2
Dataset 2	0.888 1	0.865 2	0.856 0	0.919 5	0.947 5	0.975 5
Dataset 3	0.926 6	0.895 8	0.866 2	0.926 6	0.960 7	0.985 1
Dataset 4	0.914 2	0.886 8	0.865 4	0.933 3	0.962 6	0.978 8
Dataset 5	0.900 5	0.896 5	0.891 0	0.951 1	0.972 1	0.997 5
Dataset 6	0.848 0	0.817 8	0.812 6	0.827 0	0.867 4	0.978 2

表4 不同模型的p-AUC结果(FPR小于0.3)

Table 4 p-AUC results of different models (FPR less than 0.3)

数据集	p-AUC					
	CAE	VAE	f-AnoGAN	GANomaly	LRAAD	Soft-LRAAD
Dataset 1	0.815 5	0.754 8	0.716 6	0.837 6	0.878 6	0.955 3
Dataset 2	0.790 2	0.741 2	0.734 9	0.877 5	0.909 1	0.953 7
Dataset 3	0.859 4	0.799 0	0.761 3	0.889 2	0.924 5	0.975 3
Dataset 4	0.834 4	0.779 9	0.752 7	0.894 4	0.928 2	0.963 2
Dataset 5	0.811 3	0.799 6	0.790 0	0.924 2	0.946 4	0.995 2
Dataset 6	0.712 2	0.686 0	0.682 9	0.722 3	0.786 6	0.964 8

表5 不同模型的p-AUC结果比较(FPR小于0.2)

Table 5 p-AUC results of different models (FPR less than 0.2)

数据集	p-AUC					
	CAE	VAE	f-AnoGAN	GANomaly	LRAAD	Soft-LRAAD
Dataset 1	0.775 3	0.695 3	0.656 7	0.801 7	0.839 9	0.944 9
Dataset 2	0.752 7	0.678 0	0.669 4	0.853 5	0.882 2	0.938 5
Dataset 3	0.825 3	0.736 7	0.700 6	0.869 6	0.901 0	0.970 5
Dataset 4	0.791 4	0.723 7	0.697 9	0.873 3	0.902 3	0.951 3
Dataset 5	0.760 6	0.744 6	0.743 6	0.909 6	0.926 0	0.993 7
Dataset 6	0.649 2	0.622 2	0.624 3	0.663 7	0.743 9	0.959 4

表 6 不同模型的 p-AUC 结果比较(FPR 小于 0.1)

Table 6 p-AUC results of different models (FPR less than 0.1)

数据集	p-AUC					
	CAE	VAE	f-AnoGAN	GANomaly	LRAAD	Soft-LRAAD
Dataset 1	0.727 8	0.618 8	0.593 5	0.752 5	0.773 9	0.919 6
Dataset 2	0.718 2	0.604 8	0.599 1	0.809 8	0.828 4	0.903 1
Dataset 3	0.783 2	0.652 4	0.614 3	0.834 0	0.850 2	0.958 4
Dataset 4	0.749 8	0.650 9	0.642 5	0.834 1	0.843 8	0.924 5
Dataset 5	0.678 5	0.669 8	0.683 6	0.879 6	0.870 7	0.990 3
Dataset 6	0.592 6	0.556 8	0.559 9	0.597 3	0.674 5	0.948 8

可以看出,Soft-LRAAD 模型在大多数数据集上均取得了最高的 AUC,表明其在异常检测任务中具有更强的分类能力。此外,Soft-LRAAD 模型在 FPR 分别小于 0.3、0.2 和 0.1 时的 p-AUC 也明显优于其他模型,表明其在低 FPR 区域的性能更加出色。这些结果表明,Soft-LRAAD 模型在高压并联电抗器的声音信号异常检测任务中具有更高的检测精度和鲁棒性,能够更好地识别正常数据和异常数据。

图 8 展示了不同模型的混淆矩阵。实验结果表明,Soft-LRAAD 模型在混淆矩阵中的 TPR 和 FPR 表现优异,能够有效降低误报率,同时确保较高的召回率。

图 9 展示了不同模型在不同数据集上的 PR 曲线。在本文的实验中,Soft-LRAAD 模型的 PR 曲线表现优于其他模型,尤其在低假阳性率区域,模型能够维持较高的精确度和召回率。这表明,Soft-LRAAD 模型能够在实际应用中有效识别异常,同时尽可能降低误报和漏报的风险。

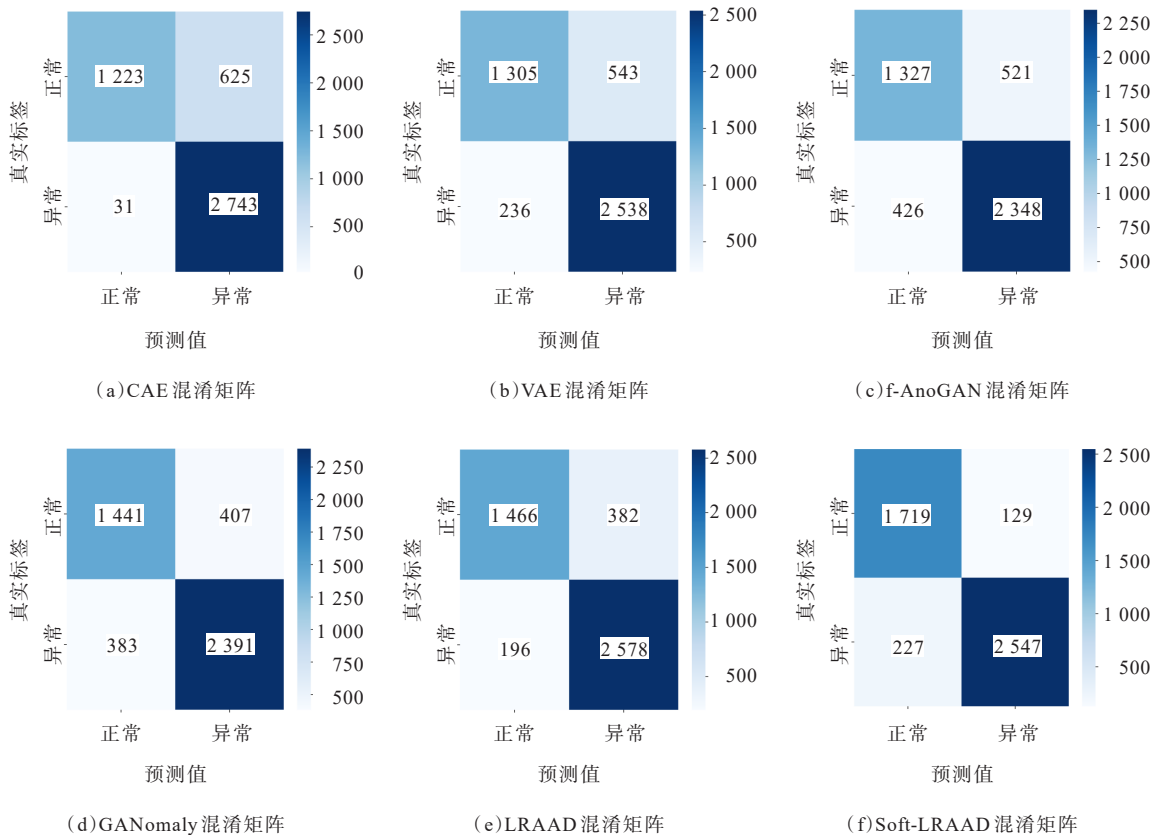


图 8 不同模型的混淆矩阵

Figure 8 Confusion matrices of different models

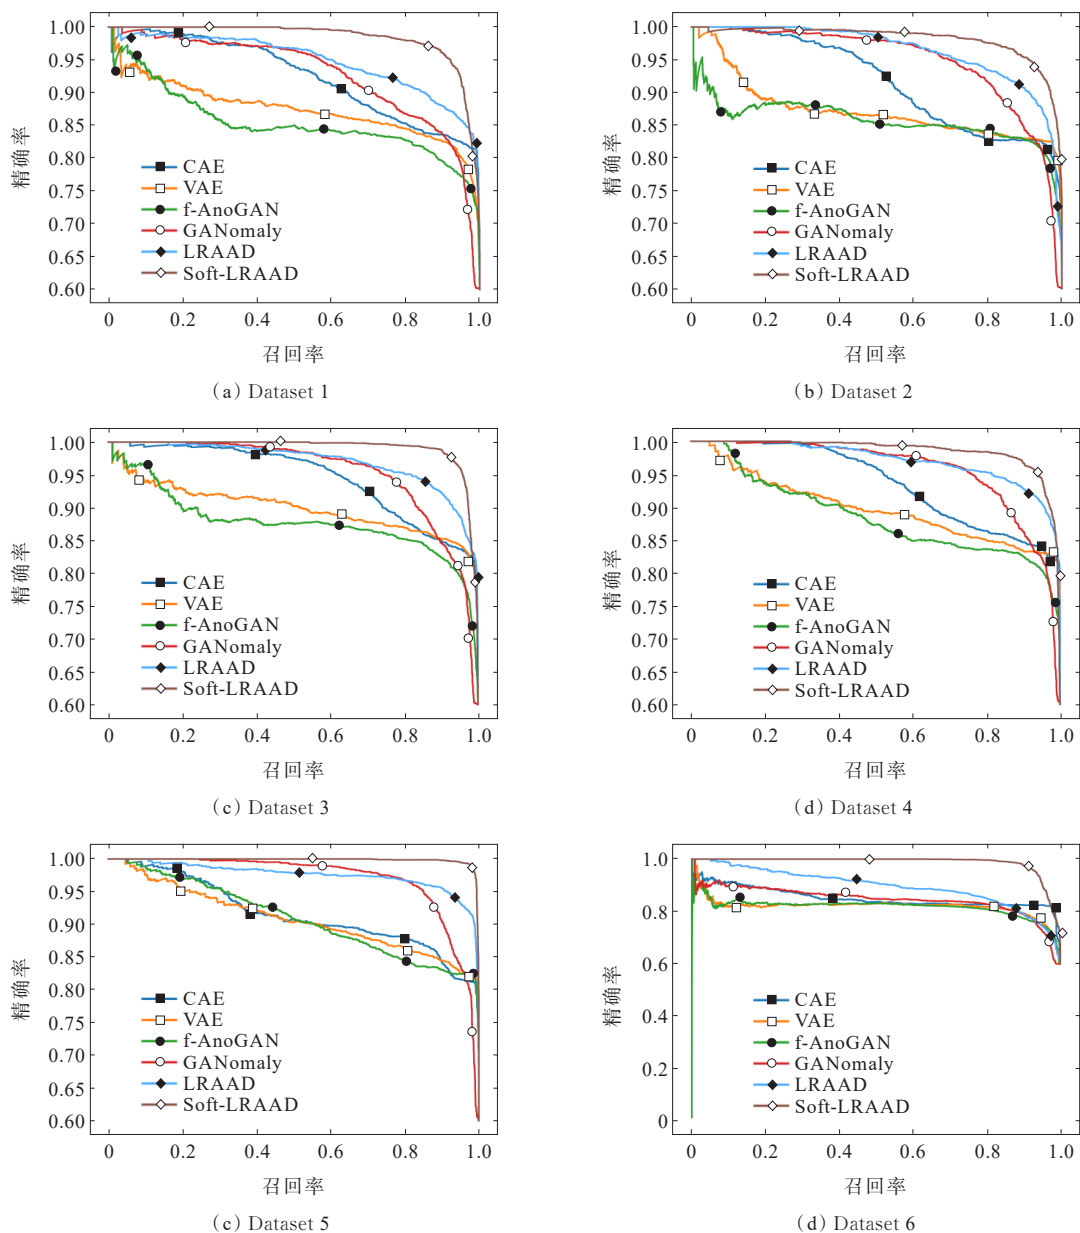


图9 不同模型在不同数据集上的PR曲线

Figure 9 PR Curves of different models on different datasets

4 结语

本文提出了一种基于软约束潜在正则化对抗学习的高压并联电抗器声音信号异常检测方法 Soft-LRAAD。该方法旨在解决现有异常检测技术在面对复杂工况时的灵敏度较低和鲁棒性不足的问题。通过引入软约束损失函数,Soft-LRAAD模型在潜在空间中实现了对正常数据和异常数据的更有效区分,并在模型训练的稳定性 and 检测精度方面取得了显著提升。

实验结果表明,Soft-LRAAD方法在不同负载和工况条件下均表现出优异的异常检测性能。相

比于传统的油色谱分析、超声波检测和高频局放检测等方法,Soft-LRAAD方法不仅提高了检测的实时性和精度,还能够更好地应对复杂电磁环境中的干扰问题。此外,与其他深度学习模型相比,Soft-LRAAD方法在AUC和p-AUC等指标上取得了更高的分数,显示出了其在低FPR区域的检测优势。

参考文献:

- [1] DAS S, SIDHU T S, ZADEH M R D, et al. A novel hybrid differential algorithm for turn to turn fault detection in shunt reactors[J]. IEEE Transactions on Power Delivery, 2017, 32(6): 2537-2545.

- [2] MAGDALENO-ADAME S, ESCARELA-PEREZ R, OLIVARES-GALVAN J C, et al. Temperature reduction in the clamping bolt zone of shunt reactors: design enhancements[J]. IEEE Transactions on Power Delivery, 2014, 29(6): 2648-2655.
- [3] TŪMAY M, DEMIRDELEN T, BAL S, et al. A review of magnetically controlled shunt reactor for power quality improvement with renewable energy applications [J]. Renewable and Sustainable Energy Reviews, 2017, 77: 215-228.
- [4] 汪先进, 周凯, 赵世林, 等. 不同材料对变电站内三相空心电抗器磁场干扰的屏蔽效果研究[J]. 电力科学与技术学报, 2021, 36(4): 150-156.
WANG Xianjin, ZHOU Kai, ZHAO Shilin, et al. Research for magnetic shielding effect of 3-phase air core reactor in substation by using different materials[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 150-156.
- [5] YAO C G, ZHAO Z Y, LI C X, et al. Noninvasive method for online detection of internal winding faults of 750 kV EHV shunt reactors[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(5): 2833-2840.
- [6] ARIAS VELÁSQUEZ R M, MEJÍA LARA J V. Root cause analysis for shunt reactor failure in 500 kV power system[J]. Engineering Failure Analysis, 2019, 104: 1157-1173.
- [7] 高树国, 汲胜昌, 孟令明, 等. 基于在线监测系统与声振特征预测模型的高压并联电抗器运行状态评估方法 [J]. 电工技术学报, 2022, 37(9): 2179-2189.
GAO Shuguo, JI Shengchang, MENG Lingming, et al. Operation state evaluation method of high-voltage shunt reactor based on on-line monitoring system and vibro-acoustic characteristic prediction model[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2179-2189.
- [8] ALI M S, ABU BAKAR A H, OMAR A, et al. Conventional methods of dissolved gas analysis using oil-immersed power transformer for fault diagnosis: a review[J]. Electric Power Systems Research, 2023, 216: 109064.
- [9] WANG Y, LI X M, GAO Y, et al. Partial discharge ultrasound detection using the Sagnac interferometer system[J]. Sensors, 2018, 18(5): 1425.
- [10] ZHENG S S, CUI Y Z, QI B. Feasibility of detecting partial discharge in smoothing reactor using UHF method [M]//Proceedings of the 21st International Symposium on High Voltage Engineering. Cham: Springer International Publishing, 2019: 993-1002.
- [11] 周力行, 李毅, 龚杰, 等. 基于PD信号提取的干式空心电抗器早期故障研究[J]. 电力科学与技术学报, 2008, 23(2): 41-45+50.
ZHOU Lixing, LI Yi, GONG Jie, et al. Research on forepart faults of dry-type air-core reactors based on the extraction of PD signals[J]. Journal of Electric Power Science and Technology, 2008, 23(2): 41-45+50.
- [12] 倪园, 周兵, 裴春明, 等. 1 000 kV 特高压并联电抗器周围声波干涉特性分析[J]. 高电压技术, 2014, 40(12): 3926-3932.
NI Yuan, ZHOU Bing, PEI Chunming, et al. Characteristics analysis of acoustic interference around 1 000 kV UHV shunt reactor[J]. High Voltage Engineering, 2014, 40(12): 3926-3932.
- [13] 李亮亮, 丁杰, 陈俊, 等. 电抗器声学包电磁噪声特性分析及声学优化[J]. 机车电传动, 2019(4): 89-92.
LI Liangliang, DING Jie, CHEN Jun, et al. Electromagnetic noise characteristic analysis and acoustic optimization of reactor acoustic package[J]. Electric Drive for Locomotives, 2019(4): 89-92.
- [14] ILKHECHI H D, SAMIMI M H. Applications of the acoustic method in partial discharge measurement: a review[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2021, 28(1): 42-51.
- [15] GAO S G, XING C, ZHANG Z G, et al. Early warning of high-voltage reactor defects based on acoustic-electric correlation[J]. Energies, 2022, 15(19): 7196.
- [16] 王果, 雷武, 闵永智, 等. 改进EEMD算法在高压并联电抗器声信号去噪中的应用[J]. 电力系统保护与控制, 2023, 51(24): 164-174.
WANG Guo, LEI Wu, MIN Yongzhi, et al. Application of an improved EEMD algorithm in high voltage shunt reactor sound signal denoising[J]. Power System Protection and Control, 2023, 51(24): 164-174.
- [17] MNASRI Z, ROVETTA S, MASULLI F. Anomalous sound event detection: a survey of machine learning based methods and applications[J]. Multimedia Tools and Applications, 2022, 81(4): 5537-5586.
- [18] JOMBO G, ZHANG Y. Acoustic-based machine condition monitoring: methods and challenges[J]. Eng, 2023, 4(1): 47-79.
- [19] PANG G S, SHEN C H, CAO L B, et al. Deep learning for anomaly detection[J]. ACM Computing Surveys, 2022, 54(2): 1-38.
- [20] SHI Z X, ZHAO Q, SU L, et al. Equipment anomaly detection in power grids using deep learning[C]//2021 International Conference on Intelligent Computing, Automation and Systems (ICICAS). Chongqing, China. IEEE, 2021: 271-275.
- [21] SUEFUSA K, NISHIDA T, PUROHIT H, et al. Anomalous sound detection based on interpolation deep neural network[C]//ICASSP 2020-2020 IEEE International

- Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona, Spain. IEEE, 2020: 271-275.
- [22] HUANG C, YANG Z H, WEN J, et al. Self-supervision-augmented deep autoencoder for unsupervised visual anomaly detection[J]. IEEE Transactions on Cybernetics, 2022, 52(12): 13834-13847.
- [23] DUMAN T B, BAYRAM B, İNCE G. Acoustic anomaly detection using convolutional autoencoders in industrial processes[M]//14th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2019). Cham: Springer International Publishing, 2019: 432-442.
- [24] AN J, CHO S. Variational autoencoder based anomaly detection using reconstruction probability[J]. Special Lecture on IE, 2015, 2(1): 1-18.
- [25] WU Y M, CARSAULT T, NAKAMURA E, et al. Semi-supervised neural chord estimation based on a variational autoencoder with latent chord labels and features[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2020, 28: 2956-2966.
- [26] ERFANI S M, RAJASEGARAR S, KARUNASEKERA S, et al. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning[J]. Pattern Recognition, 2016, 58: 121-134.
- [27] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[M]// Information Processing in Medical Imaging. Cham: Springer International Publishing, 2017: 146-157.
- [28] 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.
- [29] AKCAY S, ATAPOUR-ABARGHOU EI A, BRECKON T P. GANomaly: semi-supervised anomaly detection via adversarial training[M]//Computer Vision-ACCV 2018. Cham: Springer International Publishing, 2019: 622-637.
- [30] JIANG A B, ZHANG W Q, DENG Y F, et al. Unsupervised anomaly detection and localization of machine audio: a Gan-based approach[C]//ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece. IEEE, 2023: 1-5.
- [31] 唐明珠, 左佳文, 王智弘, 等. 基于潜在正则化对抗的主变压器声音异常检测[J]. 兵器材料科学与工程, 2025, 48(4): 167-176.
- TANG Mingzhu, ZUO Jiawen, WANG Zhihong, et al. Anomalous sound detection of main transformers based on latent regularization adversarial learning[J]. Ordnance Material Science and Engineering, 2025, 48(4): 167-176.