

基于 FEG – MLViT 的草原与牧区光伏电站故障诊断方法

刘利强^{1,2} 李佳磊^{1,2} 齐咏生^{1,2} 马然^{1,3} 李永亭^{1,3}

(1. 内蒙古工业大学电力学院, 呼和浩特 010080; 2. 大规模储能技术教育部工程研究中心, 呼和浩特 010080;
3. 内蒙古自治区高等学校智慧能源技术与装备工程研究中心, 呼和浩特 010080)

摘要: 针对草原与牧区光伏电站特定故障频发, 生物损害对光伏发电设备造成损坏且实际场景中故障样本不足及数据标签缺失等问题, 提出一种融合伪标签的编码生成对抗-视觉元学习 (Fusion pseudo-label and encoder-generator adversarial network with meta-learning vision transformer, FEG – MLViT) 故障诊断方法。首先, 将采集的时序数据利用连续小波变换 (CWT) 从一维时序信号中学习数据结构的时频特征, 增强非线性特征的表达能力; 之后, 设计编码生成对抗网络结合伪标签机制生成标签故障数据, 同时, 设计一种三维度综合评价指标对原始样本和生成样本进行综合评估, 解决了传统评价指标单一的问题; 最后, 构建一种元视觉 (MLViT) 诊断网络, 利用其全局特征提取与快速自适应能力实现高精度故障诊断。利用实际光伏发电数据对所提方法进行验证, 并通过与最新的方法进行对比, 验证了所提方法的可行性, 最终诊断准确率在 5 类故障诊断中平均达到 95.56%, 且所提方法在小样本 (仅 9 条数据) 下就达到收敛, 表明所提方法可有效解决小样本的故障诊断问题。

关键词: 光伏发电; 故障诊断; 元学习; 小样本学习; 数据增强; MLViT

中图分类号: TM615 **文献标识码:** A **文章编号:** 1000-1298(2026)21-0357-10

OSID:



Fault Diagnosis System for Photovoltaic Power Stations in Grassland and Pastoral Areas Based on FEG – MLViT

Liu Liqiang^{1,2} Li Jialei^{1,2} Qi Yongsheng^{1,2} Ma Ran^{1,3} Li Yongting^{1,3}

(1. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China

2. Engineering Research Center of Large Energy Storage Technology, Ministry of Education, Hohhot 010080, China

3. Inner Mongolia Autonomous Region Higher Education Engineering Research Center for Smart Energy Technology and Equipment, Hohhot 010080, China)

Abstract: Aiming to address the specific issues of frequent faults in photovoltaic (PV) power stations located in grassland and pastoral areas, particularly those caused by biological damage to PV equipment, as well as the challenges of insufficient fault samples and missing data labels in real-world scenarios, a novel fault diagnosis network was proposed: the fusion pseudo-label and encoder-generator adversarial network with meta-learning vision transformer (FEG – MLViT). Firstly, the collected time-series data was transformed by using continuous wavelet transform to extract time-frequency features from one-dimensional signals, thereby enhancing the representation of nonlinear characteristics. Then an encoder-generator adversarial network integrated with a pseudo-labeling mechanism was designed to generate labeled fault data. In addition, a novel three-dimensional comprehensive evaluation metric was proposed to assess both real and generated samples, addressing the limitations of traditional single-dimensional evaluation indicators. Finally, a meta-learning-based vision transformer (MLViT) diagnostic network was constructed, leveraging its global feature extraction and rapid adaptation capabilities to achieve high-precision fault diagnosis. The proposed method was validated by using real PV operational data. Comparative experiments with state-of-the-art approaches demonstrated the feasibility and effectiveness of

收稿日期: 2025-07-22 修回日期: 2025-08-27

基金项目: 国家自然科学基金项目 (62363029)、自治区科技计划项目 (2025KYPT0042)、自治区“英才兴蒙”工程团队项目 (2025TEL07) 和自治区教育厅创新团队项目 (NMGIRT2508)

作者简介: 刘利强 (1975—), 男, 教授, 博士, 主要从事电工理论与新技术研究, E-mail: llqiang@imut.edu.cn

通信作者: 齐咏生 (1975—), 男, 教授, 博士, 主要从事故障监测与故障诊断技术研究, E-mail: qys@imut.edu.cn

the proposed model, achieving an average diagnostic accuracy of 95.56% across five fault categories. Moreover, the model converged with as few as nine samples, indicating its strong performance in few-shot fault diagnosis scenarios.

Key words: photovoltaic power generation; fault diagnosis; meta-learning; few-shot learning; data augmentation; MLViT

0 引言

随着“碳达峰”和“碳中和”目标的提出,清洁能源的装机容量不断增加,其中,在众多清洁能源中,太阳能发电凭借其灵活性和优异可部署性,逐渐成为我国能源结构中不可或缺的重要组成部分^[1]。

近年来,内蒙古地区凭借其得天独厚的自然条件,大力发展太阳能发电^[2]。然而,大容量太阳能发电系统多位于高海拔、太阳能辐射强度高的地区,这些地区多位于沙漠化地区和草原地区,这些地方常年风沙频发并且生物损害对光伏发电系统造成了不同程度的损伤^[3]。因此,针对光伏系统进行故障诊断和预测性维护显得尤为重要。

传统光伏发电故障诊断方法主要以电气参数监测为基础^[4],常见的方法主要有基于传感器的实时监测和故障特性分析法。这些方法通过监测光伏系统的电压、电流、功率等电气参数的变化来识别故障,其优势在于方法简单,易于实现,并能够定位到具体光伏阵列的故障支路^[5]。然而,该方法也存在一定的局限性,需要依赖人工分析和比较各个阵列的电气参数从而判断故障发生的位置,由于人为判断的参与,可能导致误判和效率低下的问题。

与传统诊断方法相比,深度神经网络不仅能够高效处理海量数据,还具备高精度的识别准确率,显著提升了诊断的效率和精度^[6]。Gong 等^[7]提出一种特征增强改进的扩张卷积神经网络(CNN)用于光伏阵列的故障诊断,诊断结果表明,所提模型的平均诊断准确率为 98.95%。Xiang 等^[8]提出了一种基于频率通道注意力的视觉 Transformer 方法,在两个数据集上表现出较高的诊断准确性。然而,深度学习算法的构建过程通常依赖大量的故障数据,在实际发电场景中,光伏发电系统并不常处于故障状态,这使得故障数据的采集变得异常困难^[9]。此外,光伏电站中传感器采集的数据精度往往有限,这进一步增加了获取高质量故障数据的难度。

针对上述问题,一些学者在目标任务缺乏足够训练数据的情况下,采用迁移学习来解决故障数据稀缺的问题,通过特征迁移和参数迁移来建立源任务与目标任务之间的关联,从而构建能够从少量样本中快速学习的模型。Na 等^[10]提出了一种异构迁

移学习网络,利用公共数据集减少对轨道电路真实数据的依赖,同时还提出了一种可转移性评估指数,评估异构迁移学习的可行性及实施复杂性。She 等^[11]提出了一种元迁移学习驱动的故障诊断方法,引入多步损失优化、条件对抗网络和批量特征约束,以优化模型更新策略,从而在稀缺故障样本和可变工况条件下实现高效的故障诊断。

然而,在故障诊断领域,迁移学习方法一方面依赖复杂的机理仿真模型或领域泛化,另一方面其迁移效果受限于源任务与目标任务之间的差异。当源任务与目标任务之间差异较大时,迁移学习的效果往往受到较大影响。因此,针对这一问题,一些学者提出了基于数据生成的方法,以进一步增强小样本问题下的故障诊断效果。

Radford 等^[12]将卷积神经网络应用于 GAN,通过引入卷积层来替代反卷积层,使 GAN 能更有效地生成复杂图形,并减少了训练过程中的不稳定性。Arjovsky 等^[13]引入了 Wasserstein 距离来衡量生成数据和真实数据之间的距离,并通过权重剪枝(weight clipping)来保证训练的稳定性,有效解决了训练不稳定、梯度消失等问题。但是目前 GAN 和它的各种变体还存在着缺乏综合性评价指标和无法控制生成数据的多样性等问题。Higgins 等^[14]通过引入超参数 β 来控制 KL 散度项的权重,从而增强潜在空间中的各个维度的独立性,这使得生成模型能够更好地学习到每个因素的独立表示,进而使生成的数据更具可解释性。Van 等^[15]使用一个离散的码本来代替 VAE 中的连续潜在变量,这种离散化可以使模型更适合生成高质量的离散数据,同时结合了自编码器和 GAN 的思想,通过对离散潜在空间的学习来提升生成质量。但是 VAE 及变体仍存在潜在空间结构的可解释与多样性不足和训练效率低下等问题。

为了在深度神经网络算法训练中能够更好地利用不平衡故障数据集,元学习方法结合深度神经网络被作为主要思路,Li 等^[16]针对工况轴承故障诊断中引入动态原型调整模块,通过记忆增强机制自适应优化类原型,提升模型的区分能力,同时,采用多尺度卷积结构以并行方式提取信号在不同尺度下的深层特征,实现更全面的特征表示。Zhao 等^[17]提出

一种自动聚类元学习方法,通过数据增强提升样本多样性,结合对比学习构建特征生成器,从未标注数据中提取判别性特征。引入聚类生成器实现簇划分并生成伪标签,进而构建分类任务并嵌入元学习器中。虽然上述方法在一定程度上解决了复杂场景中故障样本稀缺的故障诊断难题,但是仍存在小样本场景下的过拟合和计算开销大等问题,难以兼顾效率与鲁棒性。

综上,目前研究还存在以下问题有待解决:①实际光伏发电系统故障数据难以获得,且故障数据大多为无标签数据,导致故障诊断模型诊断准确率低,鲁棒性差。②现有生成模型等数据增强方法存在生成多样性不可控、可解释性弱等问题,难以保障生成样本与真实故障特征的语义一致性。③传统评价指标多聚焦单一维度,未能综合考量模型在小样本适应性及特征可解释性等方面的多维性能表现。

针对上述问题,本文提出一种融合伪标签的编码生成对抗网络和元视觉学习的光伏组串故障分析和诊断方法。首先,提出一种融合伪标签的编码生成对抗网络,提升生成样本的质量并提高生成速度。设计一种伪标签机制,并将其与编码生成对抗网络相结合,解决生成样本质量难以控制及生成样本无标签的问题,从而提升网络的整体性能。然后提出一种 FEG - MLViT 小样本光伏故障诊断框架,该框架将编码生成对抗网络与元视觉学习结合,借助 MAML 提升模型快速适应能力,提高小样本场景下的诊断精度与泛化性。最后设计一种综合评价指标,从数据相似性、生成质量、整体效率 3 个维度构建综合评估框架,突破传统方法单一评价指标的片面性。

1 基于 FEG - MLViT 小样本故障诊断方法

光伏发电数据通常存在时域和频域特性,所以在进行数据处理时,选择使用连续小波变换将时序数据转化为时频图,这样可以同时分析时域和频域的信息,使数据的特征更加清晰。本文提出的基于 FEG - MLViT 的小样本智能故障诊断方法主要分为 3 个阶段:连续小波变换、融合伪标签机制的编码生成对抗网络、MLViT 故障诊断。该方法首先通过连续小波变换(CWT)将一维时序电流、电压信号转化为时频图,通过时频联合分析构造时频特征;其次,设计 FPE - GAN 生成网络,创新性融合编码器、卷积生成对抗网络混合架构与伪标签机制:编码器与生成器共享参数以约束潜空间连续性,KL 散度 D_{KL} 正则化潜在分布,对抗损失 L_C^{adv} 、分类损失 L_C^{cls} 联合优化生成过程,伪标签机制通过判别器注入类别条件

信息,确保生成样本兼具高保真度与明确故障标识;最后,将预训练的 Vision Transformer 模型,引入模型不可知元学习(MAML),构建 MLViT 网络,MAML 通过双层优化动态调整 ViT 的位置编码与多头注意力初始化参数,使模型在 5 类故障类型的极低数据条件下仍保持较高的诊断准确率。

为系统化评估性能,提出三维度评价指标:自适应余弦相似度(ACS)通过 ViT 特征加权量化时频图语义相似性;双粒度 ANND 联合局部最近邻距离与全局 Hellinger 距离评估分布一致性;效率得分 ES 融合生成网络纳什均衡轮数与诊断准确率,进一步评价了模型的有效性。实验表明,该方法在小样本条件下实现了快速适应与高精度分类。总体结构如图 1 所示。

1.1 FPE - GAN 生成网络

在传统数据生成网络中,变分自编码器(VAE)生成的样本通常比较模糊,质量较低,且 VAE 的潜码包含随机噪声成分,单一样本的编码不具有唯一确定性,而生成对抗网络(GAN)可以产生清晰真实的样本,但是 GAN 训练过程中面临模式崩溃和不稳定的问题,同时 GAN 的生成器通常从简单的先验噪声生成数据,先验与数据分布独立可能影响训练收敛且难以控制生成分布,虽然 DCGAN 通过引入卷积神经网络(CNN)提高训练的稳定性,生成效果也有了显著提升,但训练过程中仍存在模式崩溃和收敛速度慢等问题。

基于上述问题,提出一种基于伪标签机制的编码生成对抗网络(FPE - GAN),将编码器融入到 DCGAN 的生成器中,DCGAN 直接从固定噪声分布生成数据会阻碍训练收敛,编码器提供的数据驱动先验可改善这种情况,将编码器与生成器构建为同一网络,两者共享参数,判别器同时指导重构质量和生成真实性,这样设计确保潜在空间的连续性和可判别性。通过共享编码器和生成器,并用判别器特征替代重构误差度量,从而获得高质量样本和有意义的潜在表示。编码器和生成器实现了双向生成建模,既能从数据推断潜在变量,又能从潜在变量生成数据。编码器受到对抗训练约束,可学习到专属输入样本的潜在表示,同时编码器提供的后验更加精确,VAE 提供了重构误差和 KL 正则作为额外约束,防止生成器仅关注判别器而忽略数据覆盖,相当于对 GAN 训练加入一种自监督重构信号。

为了进一步提高生成样本的速度,设计了一种伪标签机制,增强了生成样本的判别性和类别一致性。在生成的未标记样本中赋予模型预测的“伪”类别标签,并将其加入训练。通过将类别条件引入




图 1 总体结构图

Fig. 1 Overall structure of proposed model

生成过程,生成器在接收潜变量的同时接收类别信息,从而指导生成样本带有明确的类别属性。伪标签机制确保生成数据具有清晰的类别标识,有利于接下来故障诊断模型的学习,融入伪标签机制后,判别器不仅判断真伪,同时还输出样本所属类别,生成器以类别标签为条件来生成样本,从而使生成图像更具有类别特征,克服了传统 GAN 网络以及 GAN 的变体中无法控制样本类别的缺陷。伪标签机制确保每个未标记样本在训练中都有暂定的监督信号,缓解了判别器过拟合有限标签样本的风险。FPE - GAN 生成网络框架如图 2 所示。

在 FPE - GAN 网络中,真实样本通过编码器转换为潜在空间中的表示 z ,在此过程中,重构损失 L_{recon} 确保了从潜在空间 z 解码回原样本的准确性,而 KL 散度 D_{KL} 则保证了 z 的分布接近先验分布。生成器基于潜在变量 z 和标签生成新的样本 $\hat{x}$,通过与




图 2 FPE - GAN 网络框架图

Fig. 2 Overall training flow of FPE - GAN

判别器的对抗训练来优化生成过程:生成器通过最小化对抗损失 L_G^{adv} 来欺骗判别器,使判别器认为生成的样本是真实的,同时,生成器还通过分类损失 L_G^{cls} 来提高生成样本标签的准确性。另一方面,判别器通过最大化对抗损失 L_D^{adv} 和分类损失 L_D^{cls} 来准确区分真实样本和生成样本。融合网络通过损失函数共同作用,实现了对模型的有效训练。FPE - GAN 的基本架构如图 3 所示。




图 3 FPE - GAN 网络结构图

Fig. 3 Architecture of FPE - GAN network

1.2 MLViT 诊断网络

目前, Vision Transformer(ViT) 凭借其强大的建模能力, 在各类任务中表现优越。然而, ViT 模型参数量庞大、结构深, 在训练中依赖大规模数据集进行预训练, 在小样本任务中, ViT 容易出现训练不稳定、过拟合严重等问题。同时, ViT 的位置编码通常是固定或任务无关的, 无法动态适应光伏时频样本的局部特征和全局特征, 多头自注意力机制在传统训练中是静态的, 难以适应光伏发电数据中多支路电流电压的时序特征和频域特征需求。Model-agnostic meta-learning(MAML) 作为一种优化型元学习算法, 通过学习模型初始化参数, 使其在适应少量新任务样本后即可快速完成模型微调, 从而实现强泛化能力与快速适应性。然而, MAML 在表征复杂结构数据时存在基础模型能力不足的问题, 尤其在采用浅层 CNN 作为基础网络时, 其对时频图的空间依赖与多尺度信息难以建模。

针对上述问题, 通过 MAML 优化 ViT 的嵌入层、Transformer 块的权重参数, 使其在少量样本下快速适应新任务。MAML 的“元初始化”策略会找到一组通用参数, 使得在少量梯度更新后, ViT 能针对光伏发电故障诊断任务快速收敛。将 MAML 引入位置编码的学习过程, 使位置编码成为任务相关的可变参数。通过元学习优化位置编码的初始化, 使其在新任务中仅需少量样本即可调整到合适的空间分布。结合 MAML, 使注意力权重的初始分布具备任务适应性, 元学习优化注意力头的初始参数, 使其在少量样本下快速调整关注模式, 增强对故障样本时频区域的注意力。MAML 通过双层优化机制实现这一目标: 内循环在具体任务上对模型参数进行局部更新, 在每个任务的支持集(support set) 上, 模型以初始参数 θ 为基础, 通过少量梯度下降步骤进行局部更新, 生成任务特定的参数 θ'_i 。数学表达式为

$$\theta'_i = \theta - \alpha \nabla_{\theta} \mathcal{L}_{T_i}(f_{\theta}, D_i^{\text{train}}) \quad (1)$$

式中 α ——学习率

D_i^{train} ——训练数据

$\mathcal{L}_{T_i}(f_{\theta}, D_i^{\text{train}})$ ——损失函数

∇_{θ} ——关于 θ 的梯度算子

外循环则通过全局参数优化从而提高跨任务适应性, 提高模型泛化能力, 在查询集(query set) 上评估内循环后的参数 θ'_i , 通过汇总多任务的损失, 反向优化初始参数 θ 。更新公式为

$$\theta \leftarrow \theta - \beta \sum_i \nabla \mathcal{L}_{T_i}(f_{\theta'_i}, D_i^{\text{val}}) \quad (2)$$

式中 β ——外循环学习率, 使用每个任务的验证数据 D_i^{val} 计算更新后参数 θ'_i 的损失

$$\mathcal{L}_{T_i}(f_{\theta'_i}, D_i^{\text{val}})$$

诊断网络的深度特征提取使用了 1 个卷积层将输入图像分割成 16×16 固定大小的块, 并将每个块映射到一个嵌入向量中, 特征提取的核心是多个 Transformer 块组成的编码器, 每个 Transformer 块包含一个多头注意力机制和一个前馈神经网络。

在每个 Transformer 块中, 首先对输入进行归一化处理, 然后应用多头自注意力机制, 接着通过残差连接与原始输入相加, 并通过 Dropout 函数。随后, 再次进行归一化处理并通过一个两层的前馈神经网络, 最后再通过一个残差连接。在层归一化与展平后得到深度特征, 并在融合特征后加入 Sigmoid 层用于分类。

在 MLViT 框架中, MAML 被用于进一步优化由 ViT 预训练得到的模型参数。MAML 通过在支持集上进行少量样本的训练, 并在查询集上评估性能, 不断更新模型参数, 以达到最佳的泛化效果。这种策略使得模型能够快速适应新的故障模式, 即使在数据量极为有限的情况下也能保持较高的诊断精度, MLViT 框架如图 4 所示。

1.3 评价指标

为更精准评估 FPE - GAN 的生成数据与真实数据的分布一致性, 本文提出三维评价评价指标, 从数据相似性、生成质量、整体效率 3 个维度构建综合评估框架, 突破传统方法单一指标的片面性。

提出自适应余弦相似度(Adaptive cosine similarity, ACS) 作为数据相似性维度的核心指标,




图 4 MLViT 网络框架图
Fig. 4 Architecture of MLViT network

传统余弦相似度 (Cosine similarity, CS) 虽能衡量向量方向一致性,但其固有缺点在于对所有特征维度赋予相同权重,无法适配光伏故障诊断中高频成分的关键性;直接应用于二维时频图需展平为向量 (Flattening),导致时空结构关系破坏且引入超高维计算负担。本研究引入自适应权重机制,针对光伏发电时域信号和频域特征向量动态调整特征维度权重。通过权重反映特征维度在故障诊断中高频成分的贡献度,提升相似性度量的任务适配性。计算公式为

$$ACS(\mathbf{v}_1, \mathbf{v}_2) = \frac{\sum_{i=1}^n w_i v_{1i} v_{2i}}{\sqrt{\sum_{i=1}^n w_i v_{1i}^2} \sqrt{\sum_{i=1}^n w_i v_{2i}^2}} \quad (3)$$

式中 $\mathbf{v}_1, \mathbf{v}_2$ ——向量
 v_{1i}, v_{2i} —— $\mathbf{v}_1, \mathbf{v}_2$ 中的特征点
 w_i ——第 i 维特征的自适应权重

时频图的本质是二维矩阵,ACS 作为余弦相似度,通常输入为一维向量,因此需要将时频图结构化表征为向量,直接展平的方法虽然保留了所有原始信息,但是计算效率低且忽略了时空结构关系。因此,通过预训练的 ViT 模型将时频图编码为紧凑特征向量,通过这种设计,ACS 可精准量化生成时频图在故障敏感特征上与真实数据的一致性,显著提升评估的物理可解释性。

为更精准评估 FPE - GAN 的生成数据与真实数据的分布一致性,提出双粒度 ANND (Average nearest neighbor distance) 指标:局部一致性和全局覆盖性。通过计算生成数据与真实数据的最近邻距离均值保证数据的局部一致性,通过引入生成数据与真实数据分布的 Hellinger 距离,量化全局分布匹配度,保证数据的全局覆盖性。联合局部一致性与全局覆盖性,避免传统 ANND 仅关注局部而忽略分布整体形态的缺陷。通过 Hellinger 距离抑制异常值干扰,解决 KL 散度对微小概率偏移过度敏感的问题,更适合光伏发电场景中带噪声数据的生成质

量评估,双粒度评价指标的计算公式为

$$A_{\text{NND}} = \frac{1}{N} \sum_{i=1}^N \min_{r_j \in R} d(g_i, r_j) \quad (4)$$

$$D_{\text{Hellinger}}(P, Q) = \sqrt{\frac{1}{2} \sum_{i=1}^k (\sqrt{P(i)} - \sqrt{Q(i)})^2} \quad (5)$$

式中 g_i ——生成数据中的第 i 个样本
 r_j ——真实数据中的第 j 个样本
 $d(\cdot)$ ——距离度量函数
 N ——生成数据的总样本数
 R ——真实数据集
 P ——真实数据分布
 $D_{\text{Hellinger}}$ ——Hellinger 距离
 Q ——生成数据分布
 A_{NND} ——平均最近邻距离

对每个生成样本 g_i ,在真实数据集 R 中搜索其最近邻样本 r_j ,计算二者在特征空间的距离 $d(\cdot)$,对所有生成样本的最近邻距离取平均,得到 A_{NND} 。

为了度量整体方法的诊断效率,结合数据生成网络的收敛速率与 ML - ViT 诊断网络的诊断准确率提出了效率得分 (Efficiency score, ES),用 E_s 表示。效率得分由数据生成网络达到纳什均衡所需要的训练轮数与生成的数据在诊断网络中的诊断准确率组成。其中,数据生成网络达到纳什均衡的训练轮数反映出网络的复杂度与计算资源的消耗程度;生成的增强数据的诊断准确率反映了生成数据的质量。将这两方面结合起来作为整体方法效率的评价既体现了生成网络的生成效率也体现了生成的数据质量。计算方式为

$$E_s = \frac{1}{M} \sum_{i=1}^M \left(\frac{\gamma}{T_i} + \delta A_i \right) \quad (6)$$

其中 $\gamma + \delta = 1$

式中 T_i ——第 i 个生成网络达到纳什均衡所需的训练轮数
 A_i ——第 i 个生成网络的数据在诊断网络中的分类准确率
 M ——生成网络的总数
 γ, δ ——可调权重系数

2 实验

2.1 实验数据选取

采用光伏发电公开数据集^[18],该数据集采集了 16 d 的光伏发电数据,在每天 07:30—17:00 采集数据,包括两个支路的电流和电压数据,采集频率为 1 Hz,包括短路、开路、老化与阴影 4 种故障状态和 1 种正常状态共 5 种数据类型。其中,在固定时间段引入故障实验,产生故障数据集,在此数据集中进

行有效性验证。

对原始数据集进行异常值筛除和归一化处理，将处理后的数据进行小波变换，将两个支路的电流

和电压进行小波变换后生成的时频图进行垂直叠加，构造一幅时频图作为一个样本，光伏发电时频图如图 5 所示。




图 5 时频样本图

Fig. 5 Time-frequency sample images

2.2 数据分割结果及分析

由于故障数据较少导致验证数据的数据量无法有效证明故障诊断框架的有效性，所以在进一步分析之前对现有数据进行分割预处理。为保证分割出的每个子序列特征提取时的相对独立性，同时避免信息重复，采用非重叠滑动窗口进行数据分割。

为了选择适当的滑动窗口大小，以最佳方式描述数据的特征，首先进行滑动窗口大小的分割。根

据现有数据分析，选择 4 种不同大小的滑动窗口，分别为 400、600、800 和 1 200。使用 4 类故障和正常状态共 5 类样本，每类故障都有 7 200 个采样点。分割后获得数量分别为 18、12、9、6 条的数据组。每个数据组都按照 3: 1 的比例划分训练集与测试集，并使用同一 ViT 网络进行训练与测试，共进行 20 轮验证实验并取均值作为此长度数据对应的最终准确率。取最后一次实验的结果做混淆矩阵，如图 6 所示。




图 6 不同长度滑动窗口对应的混淆矩阵

Fig. 6 Diagnostic accuracy of training with data of different lengths

可以得出当滑动窗口的长度为 800 时，诊断网络的效果最好，可以完整描述故障发生前后的状态。原因分析如下：

当滑动窗口长度为 400 时，由于窗口的数据长度较短，可获得的信息量有限。此外，采用多个短数据窗口的划分方式也破坏了一维时序数据中前后数据之间固有的时间序列特性。虽然这种方法增加了训练数据的数量，但由于数据中所包含的信息不足，导致数据之间的关联性较弱，从而降低了最终网络诊断的准确率。

当窗口长度为 800 时效果最佳，说明对于此类数据，800 个采样点可以更全面地描述数据的序列特征，获得最好的效果；同时对于 1 200 个采样点长度的窗口数据，由于数据的整体长度有限，过长的窗口与非重叠采样导致可采集的训练数据过少，使得网络无法充分学习，进而使准确率降低。所以，采用 800 个点的非重叠窗口进行数据的划分。

2.3 FPE - GAN 数据生成结果及分析

根据搭建的 FPE - GAN 网络对现有故障数据进行

数据生成。为了更好地模拟实际工况下光伏发电小样本故障数据的情况，使用故障状态的数据进行小波变换后进行对抗训练，这样能保证故障发生前、发生后、发生时的数据特征和频率特征。训练过程中，当编码器收敛且生成器与判别器的损失达到纳什均衡状态时，认为生成器已经学习到了数据的分布规律，停止训练。训练生成样本和原始样本对比如图 7 所示。

FPE - GAN 生成的数据基本能够覆盖原始数据，其生成的样本与真实样本数据分布非常接近。然而，部分生成数据可能会出现轻微的波动，这是因为虽然训练到纳什均衡状态下生成器的各层网络权重参数是固定的，但每次生成时输入层的数据需要进行随机初始化，因此会产生细微差异。这种波动并不会对数据生成质量产生影响，相反，适度的随机性输入可以提高通过生成数据训练出的模型的鲁棒性。通过 FPE - GAN 网络训练后的生成故障样本，每一类的数据都是同时生成且具有伪标签的数据，考虑到故障数据稀缺且各类数据不平衡的问题，所以对每一类别的原始数据增强 50 条。




图 7 生成样本与原始样本对比图

Fig. 7 Comparison between generated samples and real samples

2.4 MLViT 网络诊断结果及分析

上述算例验证了 FPE - GAN 的生成效果,接下来验证 MLViT 诊断网络的故障诊断性能。搭建 ViT 网络和 MLViT 网络,并在原始数据集上测试。同时为了使网络充分提取相应的特征并充分收敛,设置 2 个网络的损失阈值为 0.1。测试数据集上分类诊断效果的混淆矩阵如图 8 所示。




图 8 不同网络分类诊断效果的混淆矩阵

Fig. 8 Confusion matrices of different network classification diagnostic effects on test dataset

通过图 8 可以看出原始 ViT 网络的分类效果比较差,第 1 类数据的分类效果较好,2、3 类数据边界不清晰,分类效果最差;MLViT 网络的分类效果较好,除第 2 类在边界处分类不清晰外,其余类别都已按簇分离。通过原始数据分类的混淆矩阵可以发现,MLViT 网络结合了元学习与视觉 Transformer 的诊断优势,尤其在小样本数据场景下,可以达到 95.56% 的准确率。

模型在元训练阶段接触多类故障任务,ViT 提取的特征具有跨任务泛化能力,因此在测试集上表现稳定,准确率差距小。ViT 的全局建模能力从有限样本中充分挖掘关键特征,MAML 则可以确保这些特征可迁移至新任务,使准确率快速达到稳定。ViT 的预训练权重提供强视觉先验,MAML 在此基础上通过少量样本微调,实现小样本数据下的大模型高效利用。

综上所述,MLViT 网络通过元学习的快速适配能力与 ViT 的全局特征提取能力,在小样本数据集中实现损失快速收敛、准确率高的优异表现。

2.5 小样本故障诊断模型对比实验

为系统验证本研究所提光伏故障诊断模型 FEG - MLViT 的有效性,设计了多种对比实验,结果如表 1 所示。

表 1 不同模型故障诊断对比实验结果

Tab. 1 Comparative experiment results of fault diagnosis with different models

方法	平均准确率/%
MACF ^[19]	92.4
FSPDF ^[20]	71.1
CSMPN ^[21]	90.3
SC - MambaFew ^[22]	93.6
FD - DAML ^[23]	92.1
FEG - MLViT	95.6

选取 MACF、FSPDF、CSMPN、SC - MambaFew、FD - DAML 和 FEG - MLViT 进行比较。实验数据表明,本研究提出的 FEG - MLViT 模型展现出显著优势,与其他经典方法相比,元学习相关方法在此小样本数据集中表现出的精度更高,效果更好,实验结果均在 90% 以上。实验结果表明,FEG - MLViT 可以在少量样本的条件下实现故障诊断,其平均诊断准确率达到 95.6%,由此可以得出本文提出的故障诊断模型,不仅突破了传统方法在小样本方面的局限,而且识别结果稳定、收敛速度快。

2.6 小样本故障诊断模型消融实验

为全面评估本文提出的 FEG - MLViT 模型的性能,设计了 5 组消融实验进行验证。实验设置和结果如表 2 所示。实验 1 的结果表明,编码器将原始样本压缩到潜在空间,对特征表征能力至关重要,直接影响生成数据质量与诊断精度。实验 2 说明伪标签机制通过半监督学习显著提升数据利用率,尤其在样本稀缺场景下作用突出。实验 3 验证 DCGAN 对数据增强的核心作用,其缺失导致模型无法有效扩展特征空间。实验 4 表明多任务学习虽牺牲部分效率,却通过任务协同提升模型鲁棒性。

表 2 FEG-MLViT 消融实验设置与结果

Tab.2 Ablation study settings for FEG-MLViT

实验序号	编码器	伪标签机制	DCGAN	ViT	MAML	ANND	ACS	E_s	分类准确率/%
1	×	√	√	√	√	0.58	0.72	0.58	82.3
2	√	×	√	√	√	0.62	0.68	0.61	79.5
3	√	√	×	√	√	0.75	0.55	0.53	74.8
4	√	√	√	√	×	0.60	0.70	0.52	71.1
5	√	√	√	√	√	0.42	0.88	0.82	95.6

注：×表示在实验中删除此模块，√表示在实验中保留此模块。

2.7 极端数据稀缺场景下故障诊断模型实验

为了进一步说明所提方法在极端数据稀缺场景下的有效性,分别从每类 9 个样本中随机抽取 4、3、2、1 个样本作为训练集,其余样本作为测试集,并且每次实验重复 10 次取均值作为最终准确率,结果如表 3 所示。

表 3 极端数据稀缺场景下故障诊断实验结果

Tab.3 Experimental results of fault diagnosis under extremely data-scarce scenarios

训练样本数	测试样本数	平均准确率/%
4	5	84.0
3	6	83.0
2	7	77.1
1	8	67.5

根据实验结果可知,在极端小样本场景下训练样本数量与诊断准确率呈现显著正相关关系。当每类故障训练样本数从 4 个逐次递减至 1 个时,模型平均准确率从 84.0% 逐步下降至 67.5%,实验混淆矩阵如图 9 所示。

由上述实验结果可知,随着样本数量的减少,模型的性能有所下降,特别是在处理短路和开路类别时,误分类的情况增多。然而,在老化、正常和阴影这 3 个类别上,即使样本数量减少,模型依然保持了较高的准确率。这表明模型在这 3 个类别的特征识别上较为稳定,而短路和开路类别的特征可能较为复杂或相似,需要更多的样本数据来提高分类精度。




图 9 不同样本诊断效果混淆矩阵

Fig.9 Confusion matrix of diagnostic effects on different samples

3 结论

- (1)通过滑动窗口优化和时频图特征融合,有效提取了光伏发电故障数据的时频特征,减少了对局部噪声的敏感度。
- (2)提出的 FPE-GAN 模型结合编码器与 DCGAN 的优势,生成数据与真实样本的分布一致性

显著提升,并通过伪标签机制自动筛选高质量样本,扩充训练集的同时保障标签可靠性。

- (3)MLViT 网络集成 ViT 的全局特征提取能力与 MAML 的快速自适应机制,在小样本场景下准确率达 95.56%,且训练损失在 20 轮内快速收敛,验证了其高效性与鲁棒性。

参 考 文 献

[1] Li X, Yang Q, Duan H, et al. Carbon footprint and environmental impact of China's PV production and reduction potential of PV power generation[J]. Environmental Impact Assessment Review, 2025, 115: 107977.

[2] Wang H, Zhang J, Wang P, et al. The role of demand-side flexibilities on low-carbon transition in power system: a case study of West Inner Mongolia, China[J]. Renewable Energy, 2025, 242: 122478.

[3] Abdulla H, Sleptchenko A, Nayfeh A. Photovoltaic systems operation and maintenance: a review and future directions[J]. Renewable and Sustainable Energy Reviews, 2024, 195: 114342.

[4] Belhachat F, Larbes C, Bennia R. Recent advances in fault detection techniques for photovoltaic systems: an overview,

- classification and performance evaluation[J]. *Optik*, 2024, 306: 171797.
- [5] Ahmadipour M, Othman M M, Alrifay M, et al. Classification of faults in grid-connected photovoltaic system based on wavelet packet transform and an equilibrium optimization algorithm-extreme learning machine[J]. *Measurement*, 2022, 197: 111338.
- [6] Abuhashish M N, Refaat A, Kalas A, et al. Towards accurate and reliable fault diagnosis in PV systems: techniques, challenges, and future directions[J]. *Process Safety and Environmental Protection*, 2025: 107217.
- [7] Gong B, An A, Shi Y. Photovoltaic arrays fault diagnosis based on an improved dilated convolutional neural network with feature-enhancement[J]. *Measurement Science and Technology*, 2023, 35(1): 015011.
- [8] Xiang L, Bing H, Li X, et al. A frequency channel-attention based vision Transformer method for bearing fault identification across different working conditions[J]. *Expert Systems with Applications*, 2025, 262: 125686.
- [9] Saiprakash C, Joga S R K, Mohapatra A, et al. Improved fault detection and classification in PV arrays using Stockwell transform and data mining techniques[J]. *Results in Engineering*, 2024, 23: 102808.
- [10] Na L, Cai B, Zhang C, et al. A heterogeneous transfer learning method for fault prediction of railway track circuit[J]. *Engineering Applications of Artificial Intelligence*, 2025, 140: 109740.
- [11] She D, Yang Z, Duan Y, et al. A meta transfer learning-driven few-shot fault diagnosis method for combine harvester gearboxes[J]. *Computers and Electronics in Agriculture*, 2024, 227: 109605.
- [12] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [C]//*Proceeding of the International Conference on Learning Representations (ICLR)*, 2016.
- [13] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]//*International Conference on Machine Learning*. Pmlr, 2017: 214–223.
- [14] Higgins I, Matthey L, Pal A, et al. Beta-vae: learning basic visual concepts with a constrained variational framework[C]//*International Conference on Learning Representations*, 2017.
- [15] Van Den Oord A, Vinyals O. Neural discrete representation learning[C]//*Advances in Neural Information Processing Systems 30 (NIPS2017)*, 2017: 6309–6318.
- [16] Li X, Zhu G, Hu A, et al. A meta-learning method based on meta-feature enhancement for bearing fault identification under few-sample conditions[J]. *Mechanical Systems and Signal Processing*, 2025, 226: 112370.
- [17] Zhao Z, Jiao Y, Xu Y, et al. A fault diagnosis framework using unlabeled data based on automatic clustering with meta-learning[J]. *Engineering Applications of Artificial Intelligence*, 2025, 139: 109584.
- [18] Lazzaretti A E, Costa C H, Rodrigues M P, et al. A monitoring system for online fault detection and classification in photovoltaic plants[J]. *Sensors*, 2020, 20(17): 4688.
- [19] Wu Z, Li D, Zou L, et al. Multi-Granularity awareness via cross fusion for few-shot learning[J]. *Information Sciences*, 2025, 714: 122209.
- [20] Li D, Jin J, Zou L, et al. FSPDF: few-shot learning with progressive dual-domain feature fusion via self-supervised learning [J]. *Knowledge-Based Systems*, 2025, 317: 113389.
- [21] Zhang X, Huang W, Ding C, et al. Cross-supervised multisource prototypical network: a novel domain adaptation method for multi-source few-shot fault diagnosis[J]. *Advanced Engineering Informatics*, 2024, 61: 102538.
- [22] Truong G B, Tran T T, Than N L, et al. SC-MambaFew: few-shot learning based on Mamba and selective spatial-channel attention for bearing fault diagnosis[J]. *Computers and Electrical Engineering*, 2025, 123: 110004.
- [23] Zhang Y, Han D, Tian J, et al. Domain adaptation meta-learning network with discard-supplement module for few-shot cross-domain rotating machinery fault diagnosis[J]. *Knowledge-Based Systems*, 2023, 268: 110484.