

基于改进生成对抗网络与深度迁移学习的末级过热器超温故障诊断方法

曹熠云¹, 茅大钧¹, 陈思勤²

(1. 上海电力大学 自动化工程学院, 上海 200090; 2. 华能国际电力股份有限公司上海石洞口第二电厂, 上海 200942)

摘要:末级过热器管壁频繁超温且机理复杂,快速准确地追溯机组超温原因有助于从源头解决超温问题,对电厂的安全运行具有重要意义。针对正常服役机组超温样本稀疏不平衡所导致的传统诊断模型泛化能力不足的问题,提出基于改进生成对抗网络(CWGAN)与深度迁移学习(TL)的末级过热器超温诊断方法(TL-Xception),以在役的某两台600 MW超临界机组末级过热器为对象进行验证。通过格拉姆角差场GADF编码将1号源域机组的关键特征变量转换为二维图像,以适配迁移学习模型。利用CWGAN生成高质量超温样本,显著提高了Xception网络在1号源域机组中的泛化能力,微调在1号源域机组上预训练后的网络,并将其迁移到稀疏不平衡的2号目标域机组中。结果表明:本文所提方法的平均准确率达到99.03%,相较于传统深度学习方法,该方法的收敛速度更快、准确率更高,实现了对2号目标域机组末级过热器超温的快速诊断。

关键词:末级过热器;稀疏不平衡样本;对抗生成网络;深度迁移学习;超温诊断

中图分类号:TH17;TP183

文献标识码:A

DOI:10.16146/j.cnki.rndlgc.2024.12.022

[引用本文格式]曹熠云,茅大钧,陈思勤.基于改进生成对抗网络与深度迁移学习的末级过热器超温故障诊断方法[J].热能动力工程,2024,39(12):195-204. CAO Yiyun, MAO Dajun, CHEN Siqin. Fault diagnosis method of final-stage superheater overtemperature based on improved generative adversarial networks and deep transfer learning[J]. Journal of Engineering for Thermal Energy and Power, 2024,39(12):195-204.

Fault Diagnosis Method of Final-stage Superheater Overtemperature based on Improved Generative Adversarial Networks and Deep Transfer Learning

CAO Yiyun¹, MAO Dajun¹, CHEN Siqin²

(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code: 200090;

2. Shidongkou Second Power Plant, Huaneng International Power Co., Ltd., Shanghai, China, Post Code: 200942)

Abstract: The frequent overheating of the final-stage superheater tube walls with complex mechanisms in power plants necessitates a rapid and accurate tracing of the causes of overheating in order to address the issue at its root, which is crucial for the safe operation of the power plant. Addressing the problem of sparse and unbalanced samples of overheating in normal operating units leading to insufficient generalization capabilities of traditional diagnostic models, a method for diagnosing overheating (TL-Xception) in the final-stage superheater based on improved generative adversarial networks (CWGAN) and deep transfer learning (TL) was proposed. The final-stage superheaters of two 600 MW supercritical units in operation were validated as research object. The key feature variables of unit 1 of source domain were transformed into two-dimensional images using Gramian angular difference field (GADF) encoding to adapt to the transfer learning model. The conditional Wasserstein generative adversarial network (CWGAN) was

收稿日期:2024-03-07; 修订日期:2024-04-29

基金项目:中国华能集团有限公司2022年度科技项目(HNKJ22-HF22)

Fund-supported Project: Science and Technology Project of China Huaneng Group Co., Ltd. in 2022 (HNKJ22-HF22)

作者简介:曹熠云(2000-),男,上海电力大学硕士研究生。

utilized to generate high-quality overheating samples, significantly enhancing the generalization capability of the Xception network in unit 1 of source domain. The pre-trained network on unit 1 of source domain was fine-tuned and transferred to the sparse and unbalanced unit 2 of target domain. The results show that the proposed method achieves an average accuracy of 99.03%. Compared with traditional deep learning methods, this approach demonstrates faster convergence and higher accuracy, enabling rapid diagnosis of overheating in the final-stage superheater of the unit 2 of target domain.

Key words: final-stage superheater, sparse imbalanced sample, generative adversarial network, deep transfer learning, overtemperature diagnosis

引 言

锅炉是燃煤机组实现能量传递和转换的核心设备,因锅炉受热面超温导致的爆管事故一直是影响火电机组安全运行的问题之一^[1]。作为锅炉受热面最主要的部件,受管内高温工质和管外高温烟气的双重作用,末级过热器管壁超温问题频繁发生。近年来,以光伏、风电为代表的可再生能源装机量逐年增加,但这类机组发电稳定性较差^[2],火电机组目前仍承担着巨大的调峰压力,频繁的变负荷工况也进一步加剧了末级过热器管壁的超温现象。此外,由于超温现象本身具有突发性和复杂性,运行人员通常只能通过调整运行措施以控制壁温,无法追溯造成超温现象的源头。因此,若能快速准确地追溯机组超温原因,有助于从源头解决超温问题,对火电机组的安全性、经济性具有重要意义。

目前,诸多学者采用基于机器学习、深度学习等方法对工业锅炉故障进行诊断。基于机器学习的方法通过提取设备正常与故障时的大量时、频域信号,以建立故障诊断模型。沙骁等人^[3]研究发现,火电机组锅炉受热面壁温均具有与机组负荷波动相同的特征频率,对壁温故障特征频率的提取有重要意义。Zhong 等人^[4]采用小波包分析提取锅炉受热面管屏振动信号的时域特征,进而构建支持向量机(SVM)模型对结渣故障进行检测。但此类方法的准确性很大程度上依赖于人为提取故障特征参数。

近年来,深度学习凭借特有的深层结构和极强的特征学习能力,能够避免人为干预的影响,因而得到了广泛应用^[5]。Guo 等人^[6]提出基于自适应深度的 CNN 卷积神经网络,以自动提取轴承频谱图中的特征。Lee 等人^[7]利用 CNN 卷积神经网络模型对半导体的制造过程进行缺陷检测。但深度学习模型深层结构复杂,需要训练的参数量大幅增加,因此训

练一个大型深度学习网络会耗费大量时间成本。此外,在实际工业生产中,获取大量高质量故障样本数据本身也存在一定困难,稀疏不平衡的数据会导致模型产生过拟合现象。

迁移学习作为深度学习中的一个分支,可将某个领域中训练好的模型应用于另一个不同但相关的领域^[8]。该方法通过微调源域中充分训练后的模型,利用已有的知识和数据,在数据稀缺或相关领域的学习任务中取得更好的效果。Wen 等人^[9]提出了基于稀疏自编码器与迁移学习的多工况故障诊断方法,通过迁移辅助数据来改善不同工况下滚动轴承的诊断性能。Li 等人^[10]提出了基于深度迁移学习的故障诊断架构,在不同的数据集上都取得了较好的效果。刘飞等人^[11]通过将短时傅里叶变换与伪彩色处理结合的方法,建立基于迁移学习的深度残差网络诊断模型。

目前,迁移学习的方法在锅炉受热面故障诊断领域仍存在以下问题:模型在处理稀疏不平衡的源域数据时常会表现出较低的泛化能力,当迁移至目标域时其性能会进一步衰退;目前的研究多针对一维信号,输入样本单一也会限制模型精度进一步提升。

针对以上问题,本文提出一种基于改进对抗生成网络(CWGAN)与深度迁移学习(TL)的末级过热器超温诊断方法。通过格拉姆角差场 GADF 编码将 1 号超临界机组中的多维关键时序变量转换为二维图像,再通过改进生成对抗网络 CWGAN 生成高质量图像样本,以显著提高 Xception 网络在 1 号源域机组中的泛化能力。最后,微调在源域机组中预训练的 Xception 网络,并将其迁移至 2 号目标域机组中,从而实现对目标域机组末级过热器超温的快速精确诊断。

1 数据预处理

1.1 最大信息系数特征筛选

最大信息系数 MIC 是一种以信息论为基础的

相关性分析方法,相较于传统的皮尔逊、斯皮尔曼等线性相关性系数,该方法能够同时衡量变量之间的线性关系或非线性关系,非常贴合火电机组各测点间的复杂关系。

计算 MIC 系数首先计算变量 X 和 Y 之间的互信息,表示为:

$$I(x,y) = \int P(x,y) \log \frac{P(x,y)}{P(x)P(y)} dx dy \tag{1}$$

式中: $P(x,y)$ — X 和 Y 的联合概率密度函数; $P(x)$ 和 $P(y)$ — X 和 Y 的边缘概率密度函数。

将变量 X 和 Y 分别划分成 p 个和 q 个不同的网格区间,通过计算每个网格区间的互信息,进而确定数据在不同网格中的分布情况。通过上述方法划分不同标准的网格规模,并选取互信息的最大值作为最终的最大信息系数 MIC,具体表示为:

$$MIC(x,y) = \max_{p \times q < B} \frac{I(x,y)}{\log \min(p,q)} \tag{2}$$

式中: B —划分网格的最大值。

1.2 格拉姆角差场 GADF

格拉姆角场 (GAF) 算法是由 Wang 等人^[12]提出的一种能将一维特征数据转换为二维彩色图像的方法,近年来在故障诊断领域得到广泛应用。该方法基于格拉姆矩阵的概念,通过计算一维特征数据的相似性来构建二维彩色图像,计算过程如下:

(1) 将一维特征序列 $X = \{x_1, x_2, \dots, x_n\}$ 中的各特征变量缩放至 $[-1, 1]$ 中:

$$\tilde{x}_{-1}^i = \frac{(x_i - \max X + (x_i - \min X))}{\max X - \min X} \tag{3}$$

(2) 将缩放后的各特征变量编码作为角度余弦,以时间戳为半径,进而将缩放后的各特征变量转换到极坐标中:

$$\begin{cases} \varphi_i = \arccos(\tilde{x}_i), & -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{M}, & t_i \in N \end{cases} \tag{4}$$

式中: M —常数因子; t_i —时间戳; r_i — t_i 所对应的半径。

(3) 计算特征序列在相邻时间点之间的角度差即格拉姆角差场 (GADF),并将角度差映射到图像的像素值上:

$$\begin{cases} G_{GADF} = \sin(\Phi_i - \Phi_j), & i, j \in \{1, 2, \dots, n\} \\ G_{GADF} = \sqrt{I - \tilde{X}^2} \tilde{X} - \tilde{X}^T \sqrt{I - \tilde{X}^2} \end{cases} \tag{5}$$

式中: I —单位向量。

2 基于生成对抗网络的样本生成

2.1 生成对抗网络

生成对抗网络 (GAN) 是由 Goodfellow 等人^[13]提出的深度学习模型,主要由生成器 G 和判别器 D 组成,其结构如图 1 所示。




图 1 GAN 基本框架结构
Fig. 1 Basic framework structure of GAN

该网络模型基于博弈论的思想提出,即生成器 G 和判别器 D 通过博弈的方式不断训练并相互竞争。在模型训练过程中,随机噪声 n 输入到生成器 G 中以不断生成新的样本 $G(n)$,而判别器 D 要最大限度地识别出新样本中的真实样本,当生成器 G 和判别器 D 的损失函数如式 (6) 和式 (7) 都收敛时训练结束。

$$L_G = - E_{n \sim P_g(n)} [D(G(n))] \tag{6}$$

$$L_D = - \{ E_{x \sim P_r(x)} [\lg D(x)] + E_{n \sim P_g(n)} [\lg (1 - D(G(n)))] \} \tag{7}$$

式中: x —真实样本; $P_r(x)$ —真实样本的概率密度函数; $P_g(n)$ —生成样本的概率密度函数; $D(x)$ —判别器对真实样本的判定结果; $D(G(n))$ —判别器对生成样本的判定结果。

2.2 改进生成对抗网络

传统的 GAN 网络使用 JS 散度或 KL 散度来衡量生成样本与真实样本的差异,但在训练过程中通常会出现模式坍塌和梯度消失等问题^[14]。为了解决上述问题, WGAN 引入梯度惩罚 Wasserstein 距离^[15]作为衡量标准,有效改善了训练过程中的稳定性和梯度问题。然而,该方法一次只能生成一类样本,效率比较低。

为此,本文在 WGAN 的基础上引入条件辅助信息,进一步引导数据生成,使得改进对抗生成网络 (CWGAN) 模型具备同时生成多类样本的能力,改进后的生成器 G 和判别器 D 的损失函数为:

$$L_G' = -E_{x \sim P_\phi(x)} [\mathbf{D}(x \mid y)] \quad (8)$$

$$L_D' = \underbrace{-E}_{x \sim P_r(x)} [D(x|y)] + \underbrace{E}_{x \sim P_y(x)} [D(x|y)] +$$

$$\lambda E_{x \sim P_{\mathbf{x}}(x)} [\| \nabla_x D(x \parallel y) \|_{p-1}]^2 \quad (9)$$

式中: y —各类样本的标签; ∇x —梯度; λ —惩罚系数。

标签数据 y 先与待生成样本数据一起输入生成器 G 中以生成各类样本数据,再输入判别器 D 中一起训练。CWGAN 的基本框架如图 2 所示。




图 2 CWGAN 基本框架结构

Fig. 2 Basic framework structure of CWGAN

3 迁移学习末级过热器超温诊断方法

3.1 Xception 网络结构及其微调

Xception 网络是普通卷积神经网络的一种变

体,采用深度可分离卷积核心模块来代替传统的二维卷积操作。深度可分离卷积模块主要由深度卷积和逐点卷积两部分组成,结构如图3所示。




图3 深度可分离卷积模块结构

Fig.3 Depthwise separable convolutional module structure

深度卷积是在每个输入通道上分别进行空间卷积操作后再进行合并,逐点卷积是在每个通道上进行逐点的 1×1 卷积,将不同通道的特征图进行融合。这相当于将空间特征学习与通道特征学习分开,因此与普通卷积相比,深度可分离卷积的参数更少,模型更轻量化,效率更高。

Xception 网络主要由入口流、中间流和出口流等流程组成,其结构及微调如图 4 所示。




图 4 Xception 网络结构及其微调

Fig. 4 Xception network structure and fine-tuning

由图 4 可知,Xception 网络共包含 36 个卷积层,分布在 14 个模块中,每个模块中都堆叠了若干深度可分离卷积层 (SeparableConv)、最大池化层 (Max Pooling) 和激活函数层 (ReLU),且各模块之间均采用残差连接以提升训练效率,并通过全局平均池化 (Global Average Pooling) 汇聚信息,最终通过全连接层进行输出。

3.2 迁移学习

迁移学习主要围绕域和任务展开。域主要由源域 D_s 和目标域 D_t 组成:

$$D_s = \{X_s, P(X_s)\} \tag{10}$$

$$D_t = \{X_t, Q(X_t)\} \tag{11}$$

式中: X_s, X_t —源域和目标域的特征样本; P 和 Q —概率密度分布。

任务是指解决的具体问题,主要包括源域的任务和目标域的任务:

$$T_s = \{Y_s, f_s(\cdot)\} \tag{12}$$

$$T_t = \{Y_t, f_t(\cdot)\} \tag{13}$$

式中: Y_s, Y_t —源域和目标域中的标签集合; $f(\cdot)$ —

任务函数。

迁移学习的目的是结合域和任务,将模型在源域上学习到的知识迁移到目标域的任务中,这样即使目标域为小数据量样本时也能完成训练。

3.3 基于迁移学习的末级过热器超温诊断流程

在燃煤电站机组故障诊断领域中,传统的深度学习需要收集各机组丰富的高质量故障样本,且需要设计对应的深度神经网络分别进行训练,会耗费大量的时间和成本。基于此,利用深度迁移学习的方法,以某燃煤电站的两个超临界机组为例进行研究。其中,1 号机组作为源域收集了大量的机组超温数据,并利用 CWGAN 解决了数据集规模不平衡的现象;2 号机组作为目标域仅有少量的机组超温数据。

因此,通过保留模型 (Xception) 在 1 号源域机组中预训练后的参数,并对其进行微调后应用在样本稀疏且不平衡的 2 号机组中,进而实现了基于深度迁移学习的末级过热器超温诊断,诊断流程如图 5 所示。




图 5 基于迁移学习的末级过热器超温诊断流程

Fig. 5 Final-stage superheater overtemperature diagnosis process based on transfer learning

4 实例分析

4.1 研究对象

以某电厂在役的两台 600 MW 超临界机组作为研究对象,机组的额定蒸汽压力为 25.4 MPa,额定蒸汽温度为 541/569 ℃。两台机组的锅炉为具有螺旋水冷壁、一次中间再热的超临界直流锅炉,该锅炉为单炉膛、四角切向燃烧、半露天布置,其结构为全悬吊钢构造的Ⅱ型锅炉,锅炉受热面布置如图 6 所示。




图 6 锅炉受热面布置结构图

Fig. 6 Boiler heating surface arrangement diagram

该锅炉的末级过热器由 33 片屏组成,每片屏包含 16 根管段,每根管段上各设有 1 个壁温测点,共 16 个测点。选取该电厂超温次数最多的壁温测点进行分析,对于其他测点的分析方法同理,此处不再说明。

通过分析厂级监控(SIS)系统的历史数据并结合运行人员的经验发现,造成两台机组末级过热器壁温超温的主要原因包括混煤煤质特性不佳(热值高、灰分高、灰熔点低)和运行操作不当(喷水流量小、风煤比不当),共计 5 类超温原因。

本文迁移学习的超温诊断流程是将在 1 号机组中充分训练的模型迁移到 2 号机组中。为此,将两台机组的末级过热器超温数据划分为源域机组数据 A 和目标域机组数据 B。其中,源域数据 A 来自 1 号超临界机组,收集了大量的末级过热器超温数据,共 3 000 组;目标域数据 B 来自 2 号超临界机组,仅提供少量超温数据,共 500 组。

4.2 特征筛选

计算各特征与末级过热器壁温之间的最大信息

系数 MIC,将相关系数高于 0.7 的锅炉负荷、混煤热值、灰分、磨煤机实时煤量等关键特征作为末级过热器壁温超温诊断模型的输入,如表 1 所示。

表 1 最大信息系数 MIC 特征筛选结果

Tab. 1 MIC feature selection result

参 数	最大信息系数
锅炉负荷/MW	0.752
混煤热值/GJ	0.847
给煤机给煤量/ $\text{t}\cdot\text{h}^{-1}$	0.876
混煤灰熔点/℃	0.915
混煤灰分/%	0.824
烟气挡板开度/%	0.831
喷水流量/ $\text{kg}\cdot\text{h}^{-1}$	0.814

4.3 GADF 编码

为充分发挥迁移学习在图片分类方面的优势,采用格拉姆角差场 GADF 算法将表 1 中筛选的关键一维特征数据转换成二维彩色图像,每张图像代表一类故障样本,具体效果如图 7 所示。从图 7 中看出,经 GADF 编码后得到的图像特征区别明显,纹理清晰,有利于故障分类。




图 7 各种健康状态 GADF 编码图

Fig. 7 Various health status GADF encoding diagrams

4.4 基于 CWGAN 的 1 号机组样本生成

在实际工业领域中,获取各种故障类型的高质量样本需要耗费大量的时间。图 8 为源域数据 A 故障样本分布情况,由图 8 可以发现,故障样本分布存在不平衡现象,其中喷水流量小、风煤比不当等超温故障样本明显少于其他故障类别。说明基于这些原始故障样本建立的诊断模型可能无法很好地识别

出这两类故障,从而严重影响诊断精度。




图 8 1 号源域机组故障样本分布情况

Fig.8 Distribution of failure samples of unit 1 of source domain

因此,采用改进对抗生成网络 CWGAN 同时生成高质量样本,缓解 1 号机组超温样本的不平衡现象,将经格拉姆角差场 GADF 编码后得到的三通道图像输入到 CWGAN 模型中进行训练,生成前后的图像如图 9 所示。从图 9 中可以看出,利用 CWGAN 生成的样本与实际样本非常相似,尽管在局部区域存在微小的差别,但可以明显看出生成样本与真实样本的特征基本具有相同的分布。这些细微的差别也侧面说明 CWGAN 学习到了 1 号机组真实超温样本数据的分布,而不是简单地复制原始样本,进一步增强了诊断模型在 1 号源域机组中的泛化能力,为之后的模型迁移奠定了良好的基础。





图 9 CWGAN 生成图像前后对比

Fig.9 Comparison of images before and after those generated by CWGAN


4.5 基于样本扩充后的 1 号机组模型训练

将经 GADF 编码及不平衡样本补充后的 1 号源域机组的超温图像数据按 8:2 的比例划分为训练集和测试集,输入到 Xception 网络模型中进行训练,并设置最小批量大小为 128,优化器为 RMSprop,初始化学学习率为 0.02,选择交叉熵作为损失函数。

为验证 CWGAN 扩充不平衡样本的必要性,将补充样本前后的诊断准确率曲线进行对比,结果如图 10 所示。从图 10 中可以看出,基于原始不平衡数据集建立的诊断模型存在严重的过拟合现象。测试集准确率曲线在 80% 上下波动,这说明模型并未完全学习到部分样本的故障特征,限制了准确率的进一步提升。经样本扩充后诊断模型的准确率得到了明显改善,过拟合现象进一步缓解,且测试集准确率显著提升且更稳定。这表明基于 CWGAN 模型生成的样本能有效地平衡 1 号源域机组的数据集,从而使得深度迁移学习模型在源域机组中得到了充分训练,为后续将模型迁移到 2 号机组奠定了良好的基础。



(a) 扩充样本前



(b) 扩充样本后

图 10 CWGAN 扩充样本前后的 1 号机组准确率曲线

Fig.10 Accuracy curves of unit 1 before and after CWGAN sample expansion

4.6 基于深度迁移学习的 2 号机组模型测试

将 2 号机组的目标域超温数据按 1:1 的比例划分为训练集和测试集。将在 1 号机组中经过充分训练的 Xception 网络的卷积层权重参数冻结,并只对全连接层的权重参数进行训练,进而实现源域向目标域迁移的末级过热器超温诊断。

基于 Xception 网络的深度迁移学习模型超参数设置如下:最小批量为 64,优化器为 RMSprop,初始学习率为 0.01,交叉熵为损失函数,训练次数为 30 次。同时,为了避免过拟合情况发生,在全连接层后加入了 Dropout 丢弃层。

2 号机组迁移学习准确率曲线诊断结果如图 11 所示。可以看出,本文所提深度迁移学习方法在小样本且不平衡的数据集中准确率达到 99%。此外,不同于传统的深层卷积网络,深度迁移学习的方法在第 10 次训练时准确率就已达到 90%,在第 20 次训练时就已经收敛且一直保持稳定的结果,缩短了训练时间。




图 11 2 号机组迁移学习准确率曲线

Fig. 11 Transfer learning accuracy curve for unit 2

为了更直观地体现基于深度迁移学习方法的特征提取效果,对目标域的测试集使用 t 分布随机近邻嵌入(t-SNE)进行散点可视化分析,结果如图 12 所示。t-SNE 旨在将高维数据映射到二维空间,其中距离较近的点表示具有相似特征,而距离较远的点则会表现出显著差异。此外,t-SNE 生成的横纵坐标不代表具体的物理单位或度量,因此没有单位标注。从图 12 中可以看出,通过保留 Xception 网格模型在 1 号源域机组中预训练后的参数,并对其进

行微调后,基于深度迁移学习的方法可以应用在数据样本少且规模不平衡的目标域 2 号机组的末级过热器中,能有效地进行特征分类,并具有较高的提取精度。




图 12 2 号机组迁移学习样本特征可视化

Fig. 12 Feature visualization for transfer learning sample of unit 2

4.7 模型性能对比

为进一步验证基于深度迁移学习 (TL-Xception) 模型的性能,将其在 2 号目标域机组数据集中进行 10 次训练,并分别与原始 Xception、2D-CNN 和 TL-2D-CNN 模型进行对比,结果如表 2 所示。

表 2 各模型评价结果对比

Tab. 2 Comparison of various model evaluation results

模型	平均准确率/%	训练时间/s
2D-CNN	82.10	185
Xception	85.60	168
TL-2D-CNN	95.20	35
TL-Xception	99.03	32

实验结果表明,当面对数据集稀疏且不平衡的末级过热器时,未使用迁移学习的 2D-CNN、Xception 模型的整体诊断准确率受到限制,仅约为 85%。使用迁移学习的方法后,这两个模型的平均准确率均得到了大幅提升,其中基于 TL-Xception 模型的平均准确率已经达到了 99.03%。

此外,由于深度迁移学习的方法只需微调模型,而无需从头训练一个深层网络,可以大幅缩短训练时间,因此本文所提出的基于 TL-Xception 模型的平均训练时间仅为 32 s。

2 号机组目标域测试集混淆矩阵如图 13 所示。由图 13 可知,末级过热器大部分超温故障原因都得到了准确划分,混煤热值高、灰熔点低全部分类准确,而其余超温故障只有少部分产生了错误分类。




图 13 2 号目标域机组测试集混淆矩阵

Fig. 13 Confusion matrix of test set of unit 2 of target domain

5 结 论

针对末级过热器管壁频繁超温且原因难以及时追溯的问题,本文提出了一种基于改进对抗生成网络(CWGAN)与深度迁移学习(TL)的末级过热器超温诊断算法(TL-Xception),成功将 1 号源域机组上的预训练模型迁移到数据集稀疏不平衡的 2 号目标域机组中,实现了对末级过热器超温原因的快速诊断,并可得到以下结论:

- (1) 通过 GADF 编码将 SIS 系统中的多个关键测点信号转化为二维图像,既保留了测点间时间序列的相关性,又能适配迁移学习模型的输入。
- (2) 通过 CWGAN 生成高质量样本,以解决源域机组数据集不平衡的问题,从而显著提高深层网络模型在源域中的泛化能力和准确率,为后续的迁移任务奠定了良好的基础。
- (3) 采用深度迁移学习方法,对源域机组中预训练后的 Xception 网络进行微调,并将其迁移到数据集稀疏不平衡的目标域机组中。实验结果表明,本文所提方法的平均准确率为 99.03%,高于其他

迁移学习模型。相较于未使用迁移学习的模型,TL-Xception 算法的准确率更高,训练时间更短,实现了对目标域机组末级过热器管壁超温的快速准确诊断。

参考文献:

[1] 王小华,张战锋,黄伟珍,等. 1 000 MW 机组锅炉低负荷下管壁超温诊断及运行优化调整[J]. 热能动力工程,2019,34(8): 80 - 86,94.

WANG Xiaohua,ZHANG Zhanfeng,HUANG Weizhen,et al. Over-temperature diagnosis and optimal adjustment of tube wall temperature of 1 000 MW unit boiler under low load condition[J]. Journal of Engineering for Thermal Energy and Power,2019,34(8): 80 - 86,94.

[2] 陈 力,兰 宇. 新能源发电在电力系统中的应用[J]. 中国设备工程,2023(6):249 - 251.

CHEN Li,LAN Yu. Application of new energy generation in power systems [J]. China Equipment Engineering,2023(6):249 - 251.

[3] 沙 骁,黄 骞,柳冠青,等. 燃煤锅炉受热面壁温监测数据的时序特征分析[J]. 燃烧科学与技术,2021,27(5):475 - 481.

SHA Xiao,HUANG Qian,LIU Guanqing,et al. Time series analysis of monitored heating surface wall temperature of coal-fired boiler[J]. Journal of Combustion Science and Technology,2021,27(5):475 - 481.

[4] ZHONG W,PENG L,ZHOU Y G. Slagging diagnosis of boiler based on wavelet packet analysis and support vector machine[J]. Journal of Zhejiang University (Engineering Science), 2016,50(8):1499 - 1506.

[5] 唐晓彬,沈 童. 深度学习框架发展综述[J]. 调研世界,2023(4):83 - 88.

TANG Xiaobin,SHEN Tong. Review of development of deep learning frameworks[J]. The World of Survey and Research,2023(4): 83 - 88.

[6] GUO X,CHEN L,SHEN C. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis[J]. Measurement,2016,93(16):490 - 502.

[7] LEE K B,CHEON S,KIM C O. A convolutional neural network for fault classification and diagnosis in semiconductor manufacturing process[J]. IEEE Transactions on Semiconductor Manufacturing,2017,30(2):135 - 142.

[8] 冯国红,王宏恩,刁鹏飞,等. 小样本下基于递归图和迁移学习的轴承故障诊断[J]. 机床与液压,2024,52(16):240 - 248.

FENG Guohong,WANG Hongen,DIAO Pengfei,et al. Bearing fault diagnosis based on recursive graph and transfer learning in small sample [J]. Machine Tool & Hydraulics,2024,52(16):

240 – 248.

[9]

WEN L,GAO L,LI X. A new deep transfer learning based on sparse auto-encoder for fault diagnosis [J]. IEEE Transactions on Systems,Man,and Cybernetics:Systems,2017,49(1):136 – 144.

[10]

LI Xudong, HU Yang, LI Mingtao, et al. Fault diagnostics between different type of components: A transfer learning approach [J]. Applied Soft Computing Journal,2020(86):105950.

[11]

刘 飞,陈仁文,邢凯玲,等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法 [J]. 振动与冲击,2022,41(3):154 – 164.

LIU Fei,CHEN Renwen,XING Kailing, et al. Fast fault diagnosis algorithm for rolling bearing based on transfer learning and deep residual network [J]. Journal of Vibration and Shock, 2022, 41(3):154 – 164.

[12]

WANG Z G,OATES T. Imaging time-series to improve classification and imputation[C]//The 24th International Joint Conference on Artificial Intelligence(IJCAI), Buenos Aires, Argentina,2015.

[13]

GOODFELLOW I J,POUGET-ABADIE J,MIRZA M,et al. Generative adversarial-nets[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014: 2672 – 2680.

[14]

苏元浩,孟 良,许同乐,等. 不平衡数据集下优化 WGAN 的风电机组齿轮箱故障诊断方法 [J]. 太阳能学报,2022,43(11):148 – 155.


SU Yuanhao,MENG Liang,XU Tongle, et al. Wind turbine gearbox fault diagnosis method for optimized WGAN with unbalanced data sets [J]. Acta Energiæ Solaris Sinica, 2022, 43(11): 148 – 155.

[15]

卢俊波,刘俊峰,罗 燕,等. 基于改进 WGAN 考虑特征分布相似性的小样本负荷预测方法 [J]. 控制理论与应用,2024,41(4):597 – 608.

LU Junbo,LIU Junfeng,LUO Yan, et al. Small sample load forecasting method considering characteristic distribution similarity based on improved WGAN[J]. Control Theory and Applications, 2024,41(4):597 – 608.

(刘 颖 编辑)



GE Vernova 风力发电机入选印度 51 MW 风电项目

2024 年 10 月,印度 Powerica 公司选择在其位于印度古吉拉特邦 Devbhumi Dwarka 的 51.3 MW 风电项目中安装 19 台 GE 2.7 – 132 风力发电机。该订单于 2024 年第二季度预订,预计将于 2024 年 11 月开始供应风力发电机。

印度 Powerica 公司成立于 1984 年,是一家专门从事柴油备用和主要电源应用的电源解决方案提供商。2006 年,该公司扩展到可再生能源领域,并于 2008 年作为独立电力生产商投产了其第一个风力发电项目。

Powerica 公司在印度古吉拉特邦拥有并经营着 11 个风力发电场,总装机容量为 279.55 MW。该公司计划到 2025 年将装机容量增加到 400 MW,到 2030 年将装机容量增加到 1 000 MW。

(孙嘉忆摘译自 [https://www. powerengineeringint. com](https://www.powerengineeringint.com))