

DOI: 10.19650/j.cnki.cjsi.J2615277

基于对抗特征增强与时空特征融合的 弓网电弧检测研究*

李 斌, 齐 慧, 舒嘉辉

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘 要:针对高速铁路弓网系统中电弧电流信号存在强噪声干扰、非平稳特性明显以及特征表达困难等问题,提出一种融合结构感知生成对抗网络(SA-GAN)、感受野注意力残差网络(RFA-ResNet50)与变换器(Transformer)的双分支弓网电弧检测方法。首先,采用改进杜鹃鲶鱼优化算法(ICCO)对卡尔曼滤波(KF)参数进行自适应优化,实现电弧信号降噪,在抑制背景噪声的同时保留电弧的突变特征。随后,利用马尔可夫转移场(MTF)将一维时序信号转换为二维图像,并引入结构感知生成对抗网络进行结构增强,提升关键特征的可分性和表征能力。在特征提取阶段,构建空间-时序双分支网络。其中,结构感知生成对抗网络、感受野注意力残差网络分支通过多尺度卷积和感受野注意力机制提取电弧图像的局部空间特征;变换器分支利用自注意力机制捕获信号长程时序依赖关系,实现对电弧动态变化过程的全局建模。然后,通过特征融合策略实现空间特征与时序特征的协同表达,并结合迁移学习缓解小样本条件下模型训练不足的问题,提高模型泛化能力。最后,将所提模型与其他对比模型在4种工况条件下采集到的实验数据进行多个方面的模型性能测试。实验结果表明,所提方法在信噪比提升、特征表达能力及检测准确率等方面均优于对比模型,能够实现复杂工况下弓网电弧的高精度识别。

关键词: 结构感知生成对抗网络;感受野注意力残差网络;变换器;改进杜鹃鲶鱼算法;迁移学习

中图分类号: TM501.2 TN06 TH86 **文献标识码:** A **国家标准学科分类代码:** 470.40

Research on pantograph-catenary arc detection based on adversarial feature enhancement and spatiotemporal feature fusion

Li Bin, Qi Hui, Shu Jiahui

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: To address the challenges of strong noise interference, pronounced non-stationary characteristics, and difficulties in feature representation of arc current signals in high-speed railway pantograph-catenary systems, this article proposes a dual-branch pantograph-catenary arc detection method that integrates a structure-aware generative adversarial network (SA-GAN), a receptive field attention residual network (RFA-ResNet50), and a Transformer. First, an improved cuckoo catfish optimization (ICCO) algorithm is used to adaptively optimize the parameters of the Kalman filter, thereby denoising arc signals while suppressing background noise and preserving abrupt arc features. Subsequently, one-dimensional time-series signals are transformed into two-dimensional images using the Markov transition field (MTF), and a SA-GAN is introduced to enhance structural information, thereby improving the discriminability and representational capability of critical features. During feature extraction, a spatial-temporal dual-branch network is constructed. The SA-GAN-enhanced RFA-ResNet50 branch extracts local spatial features through multi-scale convolutions and a receptive field attention mechanism, while the Transformer branch captures long-range temporal dependencies using self-attention to achieve global modeling of dynamic arc evolution. A feature fusion strategy is then employed to facilitate the collaborative representation of spatial and temporal information. In addition, transfer learning is incorporated to mitigate the issue of insufficient training under limited-sample conditions and improve model generalization. Finally, comprehensive performance evaluations are conducted on experimental datasets collected under

收稿日期: 2026-05-14 Received Date: 2026-05-14

* 基金项目: 2024 年辽宁省教育厅基本科研项目 (LJ232410147055) 资助

four operating conditions and compared with several representative baseline models. The experimental results show that the proposed method achieves superior performance in signal-to-noise ratio enhancement, feature representation capability, and detection accuracy, enabling high-precision identification of pantograph-catenary arcs under complex operating conditions.

Keywords: structure-aware generative adversarial network; receptive field attention residual network; Transformer; improved cuckoo catfish optimization algorithm; transfer learning

0 引 言

随着国家交通强国政策的贯彻落实,我国高速铁路建设迎来了发展的黄金期。自党的十八大以来,已经建成了“八纵八横”的高速铁路主通道,现代化高速铁路发展迅猛^[1]。到2025年底,我国高铁运营里程已经超过50 000 km,标志着我国已经建成世界规模最大,技术最先进的高速铁路网^[2]。高速铁路的快速发展对列车受流质量和供电系统运行可靠性提出了更高要求。作为高速铁路牵引供电系统的重要组成部分,受电弓与接触网之间通过滑动接触实现能量传输。当弓网接触状态受到线路不平顺、受电弓振动、接触压力波动及运行环境变化等因素影响时,容易发生弓网离线现象,从而产生弓网电弧。

弓网电弧不仅会引起受流电流波动和牵引功率不稳定,降低列车运行品质,而且持续燃弧还会导致受电弓碳滑板及接触线表面烧蚀,加速设备老化,缩短使用寿命。严重情况下甚至可能引发设备损坏、列车停车以及火灾等安全事故。因此,实现弓网电弧的快速检测与准确识别,对于保障高速铁路安全稳定运行具有重要的工程价值和现实意义。

近年来,国内外学者围绕弓网电弧机理分析、特征提取及智能识别等方面开展了大量研究。从电弧机理研究角度来看,吴广宁等^[3]系统分析了高速铁路弓网电弧的形成机制、影响因素及抑制措施,指出接触压力波动、运行速度变化、受电弓振动以及接触网结构参数等均会显著影响电弧产生概率。该研究为后续电弧检测与识别提供了重要理论基础。蔡智超等^[4]则从多源信息融合角度出发,提出融合可见光、红外及电流信息的弓网电弧检测方法,有效提高了复杂环境下电弧检测的准确性,体现了多模态感知技术在弓网状态监测中的应用潜力。

在传统智能算法方面,李斌等^[5]基于海鸥优化算法(seagull optimization algorithm, SOA)优化支持向量机(support vector machine, SVM)参数,构建电弧识别模型,实现了较好的分类效果。传统机器学习方法具有结构简单、计算量较小等优点,但通常依赖人工设计特征,难以充分挖掘电弧信号中的深层信息,在复杂工况和强噪声环境下识别性能容易下降,泛化能力受到一定限制。

随着深度学习技术的发展,研究重点逐渐转向基于

深层网络的自动特征学习方法。其中,卷积神经网络(convolutional neural network, CNN)凭借其优异的特征提取能力被广泛应用于故障诊断领域。李斌等^[6]将格拉姆角场(Gramian angular field, GAF)用于一维电流信号的二维编码,并结合CNN实现弓网电弧识别。研究表明,通过将时序信号映射为图像特征,能够增强电弧特征表达能力,提高模型识别性能。然而,该类方法主要关注空间特征提取,对电弧信号的时间演化规律利用不足。

为进一步挖掘电弧信号中的时序信息,李斌等^[7]进一步提出融合1D-2D特征的改进双通道卷积神经网络的弓网电弧识别模型,实现了一维时序特征与二维图像特征的联合建模。该方法有效提高了电弧识别精度,验证了时空特征融合在弓网电弧检测中的优势。然而,循环神经网络类模型在长序列建模过程中仍存在梯度衰减及全局依赖关系建模能力不足等问题。

国外学者同样开展了大量研究。Yang等^[8]基于电流信号波形变化特征构建电弧识别模型,通过分析电流突变、波动幅值等特征实现电弧状态判别;Quan等^[9]提出双分支语义分割模型(arcing segmentation, ArcSE),通过融合空间结构信息与语义特征,提高了复杂环境下弓网电弧检测的鲁棒性;Yan等^[10]构建深度学习电弧检测模型,通过优化网络结构及训练策略进一步提升了检测精度。这些研究表明,深度学习方法能够有效提升弓网电弧识别性能,但在复杂工况下仍面临噪声干扰强、特征表达不足及模型泛化能力有限等问题。

综合现有研究可以发现,弓网电弧信号具有明显的非平稳性、突变性和随机性特征,其识别过程仍面临以下4个挑战:

- 1) 弓网电流信号易受到机械振动、电磁干扰及环境噪声影响,导致电弧特征被淹没,降低模型识别性能;
- 2) 单一时域特征或图像特征难以全面表征电弧放电过程中的动态变化规律,特征表达能力仍有提升空间;
- 3) 现有方法多侧重空间特征提取或局部时序建模,对电弧信号长程依赖关系和时空关联特征挖掘不足;
- 4) 弓网电弧样本获取成本较高,数据规模有限,模型在小样本条件下的泛化能力仍有待提高。

针对上述问题,本文提出一种融合改进杜鹃鹌鱼算法(improved cuckoo catfish optimization algorithm, ICCO)优化卡尔曼滤波(Kalman filter, KF)^[11]、结构感知生成对抗网络(structure-aware generative adversarial network, SA-

GAN)特征增强、感受野注意力残差网络(receptive field attention residual network, RFA-ResNet50)空间特征提取与变换器(Transformer)^[12]时序建模的弓网电弧检测方法。首先,利用改进杜鹃鲶鱼算法优化卡尔曼滤波实现原始电流信号的自适应降噪,提高信号质量;随后通过马尔可夫转移场(Markov transition field, MTF)^[13]将一维信号映射为二维图像,并利用SA-GAN特征增强关键电弧特征;在特征提取阶段,构建基于RFA-ResNet50的空间特征提取分支和基于Transformer的时序特征建模分支,实现空间特征与时间特征的协同学习;最后,通过特征融

合与迁移学习策略提升模型在有限样本条件下的识别性能。实验结果表明,所提方法能够有效提高复杂工况下弓网电弧识别的准确率和鲁棒性,为高速铁路弓网状态在线监测提供了一种新的技术方案。

1 弓网实验模拟

如图1所示,本文搭建了一套弓网电弧实验模拟平台,用于模拟高速列车运行过程中受电弓与接触网之间的动态接触与离线电弧现象。




图 1 弓网电弧实验模拟平台

Fig. 1 Pantograph-catenary arc experimental simulation platform

实验平台主要由调压驱动系统、供电回路、碳滑板与接触线摩擦模块、风机扰动系统、数据采集系统以及上位机控制系统组成。实验过程中,通过调压驱动装置控制电机运行,带动接触线与碳滑板产生相对运动,从而模拟列车运行状态下的弓网动态受流过程;同时利用“Z”形摆动机构实现接触线横向摆动,以更真实地还原实际工况下弓网系统的运行状态。

根据表1所示实验参数设置,实验回路电流设定为141.4 A,能够有效模拟高速列车受流过程中典型的大电流运行环境;接触压力分别设置为40与60 N,用于研究不同接触状态对弓网电弧产生特性的影响。碳滑板往复运动速度设定为0.2 m/s,同时通过驱动系统实现碳滑板与接触线之间100 km/h的相对运行速度,以模拟列车高速运行条件下的动态摩擦过程。实验供电电压等级为工频交流36 V,用于构建稳定的交流供电环境。为进一步模拟列车高速运行时的空气扰动影响,实验平台引入暴风机系统,其气流速度分别设置为89.3和135.8 km/h,用于研究气流扰动条件下电弧形态及电流信号变化规律。

表 1 实验参数设置

Table 1 Experimental parameter settings

参数	数值
回路电流/A	141.4
滑板往复速度/(m·s ⁻¹)	0.2
接触压力/N	40/60
电压等级/V	工频交流 36
碳滑板-接触线相对速度/(km·h ⁻¹)	100
暴风机气流速度/(km·h ⁻¹)	89.3/135.8

在实验过程中,上位机通过Modbus通信协议实现对调压驱动系统、数据采集模块及运动控制模块的统一协调控制,并实时采集弓网电弧电流、电压以及运行状态数据。通过该实验平台,可以较为真实地复现高速列车弓网系统在复杂运行条件下的电弧放电现象,为后续弓网电弧信号分析、特征提取及智能检测算法研究提供可靠的数据基础。

以暴风机气流速度为89.3 km/h,接触压力为40 N的实验条件为例,采集电流信号如图2所示。




图2 电弧电流波形

Fig. 2 Arc current waveform

从图2中可以看出,该电流信号整体呈现近似正弦变化趋势,表明系统基本处于正常受流状态,但在0.08~0.12 s区间内波形出现明显异常,尤其是在电流过零附近表现出显著的畸变特征。正常情况下电流应平滑穿越零点,而此处却出现短暂“停滞”与抖动现象,即典型的零休现象,说明弓网接触发生不稳定并伴随电弧的产生。同时,该区间内叠加了较强的高频扰动,波形局部呈现出明显的毛刺与振荡特征,反映出电弧燃烧过程中等离子体状态的快速变化以及系统非线性增强。

基于上述分析可知,弓网电弧信号在关键时间区间内具有明显的瞬态特征,但同时伴随着较强的高频噪声干扰,使得有效特征与噪声成分相互叠加,增加了后续特征提取与识别模型的难度。因此,在保证电弧瞬态信息不被削弱的前提下,实现对噪声成分的有效抑制,成为提升模型识别性能的关键环节。针对这一问题,需引入具备自适应调节能力的信号处理方法,以在不同工况下实现降噪效果与特征保持能力之间的平衡。在此背景下,本文选取卡尔曼滤波作为基础框架,并进一步结合 ICCO 对其关键参数进行优化,从而构建更具鲁棒性的电弧信号降噪模型。

2 改进杜鹃鲶鱼算法优化的卡尔曼滤波降噪模型

2.1 卡尔曼滤波建模

KF^[11]是一种高效率的递归滤波器,它能够从一系列的不完全及包含噪声的测量中,估计动态系统的状态。鉴于弓网电流信号在电弧作用下表现出一定的随机性与动态变化特征,同时其演化过程可在短时间内近似看作线性时变系统,为实现对信号状态的递推估计与噪声抑制,有必要对其进行数学建模与状态空间描述。因此,将弓网电流信号建模为线性离散系统如式(1)和(2)所示。

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{w}_k \quad (1)$$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \quad (2)$$

其中, $\mathbf{w}_k \sim N(0, \mathbf{Q})$, $\mathbf{v}_k \sim N(0, \mathbf{R})$ 在给定 $\mathbf{Q}$ 和 $\mathbf{R}$

时, KF 按预测-更新递推获得最优估计 $\hat{\mathbf{x}}_k$ 。因此,问题转化为如何自适应求解最优 $\mathbf{Q}$ 和 $\mathbf{R}$ 。

首先,如式(3)所示将 $\mathbf{Q}$ 和 $\mathbf{R}$ 参数转化为待优选向量。

$$\boldsymbol{\theta} = [q_1, \dots, q_m, r_1, \dots, r_n] \quad (3)$$

为保证正定性与数值稳定,如式(4)采用对角形式。

$$\mathbf{Q} = \text{diag}(q_1, \dots, q_m), \mathbf{R} = \text{diag}(r_1, \dots, r_n), q_i, r_i > 0 \quad (4)$$

为了同时兼顾降噪能力与特征保持能力,如式(5)所示构建多目标加权适应度。

$$\min_{\boldsymbol{\theta}} F(\boldsymbol{\theta}) = \alpha \cdot \text{MSE}(\mathbf{x}, \hat{\mathbf{x}}) - \beta \cdot \text{SNR}(\hat{\mathbf{x}}) + \gamma \cdot \text{TV}(\hat{\mathbf{x}}) \quad (5)$$

其中, MSE 为重构误差; SNR 为信噪比; TV 为总变差, α, β, γ 分别为重构误差项、信噪比项以及总变差项对应权重系数。其中, MSE 最重要, SNR 次之, TV 用于平滑约束。因此,本文设置权重参数 $\alpha = 0.5, \beta = 0.3, \gamma = 0.2$ 。

为验证本文所设置权重参数的优越性,设计权重敏感性分析如表2所示。

表2 权重敏感性分析

Table 2 Weight sensitivity analysis

权重组合	SNR/dB
0.3, 0.4, 0.3	23.80
0.4, 0.4, 0.2	24.70
0.5, 0.3, 0.2	25.31
0.6, 0.2, 0.2	24.90

从表2结果可以看出,本文设置的权重参数组合对比其他3组组合体现出了明显的优越性。

2.2 改进杜鹃鲶鱼算法优化的卡尔曼滤波降噪方法

KF 在弓网电弧信号降噪中具有良好的实时性与递推特性,但其性能高度依赖于过程噪声协方差矩阵 $\mathbf{Q}$ 与观测噪声协方差矩阵 $\mathbf{R}$ 的设定。传统方法多采用经验或固定取值,难以适应不同工况下信号统计特性的变化,易导致过度平滑或滤波不足。

为此,本文提出一种基于 ICCO 优化的自适应 KF 方法。通过将 $\mathbf{Q}$ 与 $\mathbf{R}$ 作为待优化参数,引入基于多样性与收敛速率驱动的自适应策略切换,实现对 KF 关键参数的全局寻优,从而提升降噪性能与鲁棒性。

首先,针对杜鹃鲶鱼算法(cuckoo catfish optimization algorithm, CCO)^[14]初始化阶段,采用佳点集策略进行改进。改进前后的种群初始化结果如图3和4所示。

从图3和4中可以看出经佳点集初始化后的种群对比原算法生成的种群,随机性大幅减少。




图 3 佳点集初始化结果

Fig. 3 Good point set initialization results




图 4 随机初始化结果

Fig. 4 Random initialization results

其次,针对传统 CCO 在搜索过程中策略切换缺乏自适应性的问题,本文提出一种基于种群状态感知的自适应策略切换机制 (adaptive strategy switching, ASS)。该方法通过引入种群多样性指标与收敛速度指标,动态评估当前搜索状态,并据此调整全局探索与局部开发策略的选择概率。改进策略如下。

首先,在改进之前先定义两个指标,定义如式(6)和(7)所示。

种群多样性指标:

$$D(t) = \frac{1}{N} \sum_{i=1}^N \|X_i - X_{\text{best}}\| \quad (6)$$

收敛速度指标:

$$C(t) = \frac{|X_{\text{best}} - X_i^{\text{new}}|}{|X_i^{\text{new}}|} \quad (7)$$

如式(8)和(9)所示,定义自适应策略切换机制和策略选择概率。

$$P_{\text{explore}} = \alpha \cdot \frac{D(t)}{D_{\text{max}}} + \beta(1 - C(t)) \quad (8)$$

$$P_{\text{exploit}} = 1 - P_{\text{explore}} \quad (9)$$

此外,为避免算法在搜索过程中陷入局部最优,本文

引入停滞检测机制。当连续 k 代最优适应度变化小于阈值 ε 时,判定算法进入停滞状态,其判定条件如式(10)所示。

$$|f_{\text{best}}(t) - f_{\text{best}}(t - k)| < \varepsilon \quad (10)$$

其中, $f_{\text{best}}(t)$ 为第 t 次最优适应度值。

如图 5 所示为 ICCO 流程图。




图 5 改进杜鹃鲶鱼算法流程

Fig. 5 Flowchart of the improved cuckoo catfish optimization algorithm

首先进行初始化,利用佳点集策略生成初始种群,并通过适应度函数进行评价,确定当前最优解。随后在迭代过程中不断更新种群状态,并计算个体适应度与群体信息。在此基础上引入 ASS 自适应策略切换机制,使算法在“全局探索阶段”和“局部开发阶段”之间动态切换,从而平衡全局搜索能力与局部寻优能力。

在迭代过程中设置停滞检测机制:当算法性能提升不明显时,判定为停滞状态,此时对部分维度施加随机扰动以增强种群多样性,避免陷入局部最优;若未达到停滞条件,则保持正常更新。随后对卡尔曼或相关滤波参数进行更新优化,并进入下一轮迭代。

不断循环上述过程,直到达到最大迭代次数或满足终止条件,最终输出全局最优解。

为进一步验证上述改进策略在全局寻优能力、收敛

速度及稳定性方面的有效性与优越性,有必要通过标准测试函数对算法性能进行系统评估。因此,为检验 ICCO 的性能,采用 ICCO 与蜣螂优化算法 (dung beetle optimization algorithm, DBO)^[15]、霜冰优化算法 (rime optimization algorithm, RIME)^[16]、人工旅鼠优化算法

(artificial lemming optimization algorithm, ALOA)^[17]、鹈鹕优化算法 (pelican optimization algorithm, POA)^[18] 和 CCO 算法在 CEC2022 测试集上进行对比实验,维度 (dim) 为 20,种群规模 N 为 30,最大迭代次数为 1 000,测试结果适应度曲线如图 6 所示,计算结果如表 3 所示。




图 6 测试函数收敛曲线
Fig. 6 Convergence curve of test function

表 3 不同算法测试结果
Table 3 Test results of different algorithms

函数	指标	ICCO	CCO	ALOA	POA	RIME	DBO
F1	最优值	626. 870 2	6 989. 420 4	11 777. 666 4	3 548. 439 2	19 324. 538 3	24 220. 340 8
	标准差	2 589. 634 9	4 515. 331 3	11 817. 934 1	3 372. 875 7	7 452. 411 7	10 862. 160 7
	平均值	5 427. 079 2	16 737. 403 1	31 785. 332 1	11 771. 955 3	35 251. 806 5	40 225. 833 6
F2	最优值	428. 936 6	491. 341 7	476. 826 4	534. 959 2	587. 014 8	787. 403 8
	标准差	11. 664 7	155. 004 6	49. 733 8	126. 353 5	139. 933 3	530. 589 3
	平均值	449. 383 4	655. 120 7	562. 854 5	695. 722 7	784. 034 1	1 550. 050 9
F3	最优值	632. 044 9	625. 367 0	643. 592 1	630. 450 1	626. 736 9	639. 393 1
	标准差	7. 512 1	13. 314 4	9. 136 7	9. 489 0	14. 535 4	10. 054 8
	平均值	653. 887 9	648. 513 2	666. 337 1	654. 426 0	663. 586 5	655. 427 2
F4	最优值	878. 601 5	868. 796 5	864. 580 5	861. 280 4	898. 779 0	905. 873 7
	标准差	8. 425 2	15. 174 1	15. 714 6	12. 479 3	20. 945 7	18. 627 8
	平均值	891. 181 0	897. 292 7	889. 053 9	888. 961 2	961. 950 3	938. 255 8

从适应度曲线及表格统计结果可以看出,ICCO 算法在 F1~F4 测试函数上整体表现出最优性能。其收敛速度明显快于其他对比算法,在迭代初期即可迅速降低适应度值,并在后期保持稳定收敛,表现出良好的全局搜索与局部开发能力。从最优值来看,ICCO 在各函数上均取得最小或接近最小的结果,说明其优化精度更高;同时,其标准差整体较小,表明算法具有较强的稳定性与鲁棒性。

综合来看,ICCO 在收敛速度、优化精度及稳定性方

面均优于其他算法,验证了所提出改进策略的有效性。因此,ICCO 可以作为 KF 的优化算法。

为进一步验证 ICCO 优化 KF 的降噪性能,以暴风机气流速度为 89.3 km/h,接触压力为 40 N 的电弧电流波形为例,利用 KF、CCO-KF 和 ICCO-KF 对电流波形进行降噪处理,并通过计算各算法降噪后的信噪比(signal-to-noise ratio, SNR),均方误差(mean squared error, MSE)和相关系数 R 来判断各算法的降噪效果,降噪后的波形对比图和计算结果如图 7 和表 4 所示。




图 7 各算法降噪后电流波形

Fig. 7 Current waveform after noise reduction by each algorithm

表 4 各方法降噪效果对比

Table 4 Comparison of noise reduction effects of various methods

方法	SNR/dB	MSE	相关系数 R	综合评价
KF	18.72	0.084	0.912	较差
CCO-KF	22.85	0.052	0.945	一般
ICCO-KF	25.31	0.042	0.955	较好

从图 7 可以看出,3 种方法均具备一定的电流噪声滤除能力。图 7 中方框区域为局部放大图,可见 ICCO 优化的 KF 在光滑性方面表现最佳。并且,从表 4 计算结果也可以看出佳点集初始化提高了种群多样性,自适应策略切换增强了搜索能力,使 ICCO-KF 相较 CCO-KF 信噪比提高 10.77%。

3 马尔可夫时频转换过程

MTF 是一种基于马尔可夫状态转移思想的时间序列二维编码方法^[17],其核心思想是将时间序列在不同时间节点上的状态变化过程描述为马尔可夫随机过程,从而实现时间序列的可视化表达。

设电弧电流信号 $\mathbf{X} = (x_1, x_2, x_3, \cdots, x_t)$, 其中 $x_t = 1, 2, 3, \cdots, T$, 表示对应时刻电压信号的幅值。然后,根据幅值的大小将时间序列 $X(t)$ 分为 Q 个分位箱。将时间序列 $X(t)$ 中每一个数据映射到不同的分位箱中,生成大小为 $Q \times Q$ 的马尔科夫转移矩阵 $\mathbf{W}$,如式(11)和(12)所示。

$$\mathbf{W} = \begin{pmatrix} w_{11} & \cdots & w_{1Q} \\ \vdots & \ddots & \vdots \\ w_{Q1} & \cdots & w_{QQ} \end{pmatrix} \tag{11}$$

$$w_{ij} = p\{x_{t+1} \in q_j \mid x_t \in q_i\} \tag{12}$$

其中, q_i 为 x_i 对应的分位箱序号, w_{ij} 为分位箱 q_i 转移到分位箱 q_j 的逼近概率。

传统马尔可夫转移矩阵仅关注相邻时刻之间的状态变化关系,难以充分反映时间序列在长时间尺度上的动态演化特征,因此 MTF 在此基础上进行了扩展。通过将转移概率映射回时间维度,构建跨时间尺度的动态概率转移矩阵 $\mathbf{M}$,其表达形式如式(13)和(14)所示。

$$\mathbf{M} = \begin{pmatrix} m_{11} & \cdots & m_{1Q} \\ \vdots & \ddots & \vdots \\ m_{Q1} & \cdots & m_{QQ} \end{pmatrix} \tag{13}$$

$$m_{ij} = p\{x_{t+1} \in q_j \mid x_t \in q_i\} \tag{14}$$

其中, m_{ij} 为分位箱 q_i 转移到分位箱 q_j 的概率。

在本文当中设置 $Q=8$, 原因是: $Q<8$ 会出现电弧信息不足; 而 $Q>8$ 会导致矩阵稀疏。同时在后文中将分析不同 Q 值对识别准确率的影响。

经过 MTF 编码后, 矩阵中的每个元素均对应图像中的一个像素点, 而不同状态之间转移概率的差异会导致

像素值产生变化, 因此能够有效地将一维电弧电压信号转换为具有纹理特征的二维图像。同时, MTF 不仅保留了时间序列的状态转移信息, 还维持了原始序列的时间关联特性, 从而减少了关键时序信息在转换过程中的丢失。其时序图像化流程如图 8 所示。




图 8 时频转换过程

Fig. 8 Time-frequency conversion process

如图 8 所示, 在正常状态下, 由于波形呈现正弦波, 因此, MTF 图像其节点分布密集且连接路径规则对称, 分布均匀, 形成规则网格结构, 表现出低熵状态, 反映了电流的周期性和平稳性; 在燃弧状态下, 电流波形具有明显的零休现象、高频扰动及非平稳演化特征, 因此, MTF 图像节点稀疏, 连接路径呈现扭曲与断裂, 节点分布不均匀, 整体模式紊乱, 呈现高熵状态, 体现电流的非平稳突变及异常频率特征。

4 改进生成对抗网络模型的构建

由于弓网电弧信号在实际运行环境中具有强随机性、非平稳性及高噪声干扰特性, 即使经过 ICCO 优化 KF 处理后, 其信号在 MTF 过程中仍存在电弧特征边缘模糊以及局部结构不清晰等问题。传统基于 CNN 的方法虽然能够在一定程度上提取空间特征, 但其输入特征质量直接决定模型的性能。因此, 仅依赖判别模型难以进一步突破性能瓶颈。生成对抗网络 (generative adversarial network, GAN)^[19] 通过学习数据分布, 可以实现从“数据层面”对特征进行优化与增强。

然而, GAN 更适用于自然图像生成任务, 由于弓网电弧在燃弧过程中具有明显的零休现象、高频扰动及非平稳演化特征。经过 MTF 编码后, 其物理特征主要表现为边缘连续性特征、局部纹理周期特征、频域能量聚集特征以及时频耦合变化特征。所以在面对 MTF 转换的电弧图像时, 无法保证时序图像化的稳定进行。

因此, 为了克服这些问题, 本文提出一种面向弓网电弧任务的 SA-GAN, 通过在损失函数与网络结构层面引入多维约束, 实现对 MTF 特征的定向增强。

在损失函数方面, 提出了一种多约束结构感知损失函数。

首先, 如式 (15) 所示, 定义总损失函数:

$$L_{\text{total}} = L_{\text{adv}} + \lambda_1 L_{\text{rec}} + \lambda_2 L_{\text{structure}} + \lambda_3 L_{\text{freq}} \quad (15)$$

其中, 对抗损失定义为如式 (16) 所示。

$$L_{\text{adv}} = \mathbb{E}[D(x) - 1]^2 + \mathbb{E}[D(G(z))]^2 \quad (16)$$

为保证生成图像与原始 MTF 一致性, 如式 (17) 所示定义重构损失。

$$L_{\text{rec}} = \|X_{\text{real}} - X_{\text{fake}}\|_1 \quad (17)$$

为保持电弧的边缘特征以及强化时间-空间的耦合信息, 如式 (18) 所示定义结构保持损失。

$$L_{\text{structure}} = \|\nabla X_{\text{real}} - \nabla X_{\text{fake}}\|_1 \quad (18)$$

同时, 为保证转换过程中电弧冲击特征不丢失, 因此根据式 (19) 定义频域一致性损失。

$$L_{\text{freq}} = \|F(X_{\text{real}}) - F(X_{\text{fake}})\|_1 \quad (19)$$

本文所构建的 SA-GAN 采用编码器-解码器结构作为生成器, 其中下采样阶段用于提取全局结构特征, 上采样阶段用于恢复局部纹理信息。同时, 在中间层引入残差结构以增强特征传播能力。判别器采用 PatchGAN 思想, 通过局部判别方式增强对电弧边缘与纹理结构的辨识能力。

相比传统 GAN, 所提出 SA-GAN 不仅关注生成图像真实性, 还通过结构损失与频域损失约束电弧物理特征, 从而提升特征增强稳定性与下游分类性能。

5 融合对抗特征增强与时空特征融合的弓网电弧检测模型

5.1 基于结构感知生成对抗网络与感受野注意力机制融合的残差神经网络

针对弓网电弧特征在复杂噪声环境下难以有效表征的问题,本文在传统残差神经网络^[20]的基础上,引入 SA-GAN 与感受野注意力机制 (receptive field attention, RFA)^[21],构建一种融合“特征增强-多尺度建模-注意力选择”的改进残差网络模型。该方法通过在输入层引入 SA-GAN 进行特征重构与增强,同时在残差网络内部嵌入 RFA 模块,对多尺度特征进行自适应加权,从而实现电弧关键特征的高效提取与表达。

1) 结构感知生成对抗网络驱动的输入特征增强机制

在传统 ResNet50 中,模型直接以 MTF 图像作为输入,容易受到噪声与特征模糊的影响。为此,本文首先利用 SA-GAN 对输入特征进行增强,其过程可表示为如式 (20) 所示。

$$\mathbf{X}' = G(\mathbf{X}) \quad (20)$$

其中, $\mathbf{X}$ 表示原始 MTF 图像; $G(\cdot)$ 表示生成器网络; $\mathbf{X}'$ 为增强后的特征图。

与传统 GAN 不同,SA-GAN 通过引入结构损失与频域约束,使生成结果在增强电弧特征的同时保持原始信号的物理一致性。该过程本质上实现了从“原始特征分布”到“优化特征分布”的映射,使后续残差网络能够在更优特征空间中进行学习。

2) 基于多尺度卷积的残差特征建模

本文将 RFA 模块嵌入 ResNet50 的 BottleNeck 残差块内部,并置于多尺度卷积特征融合之后、残差连接之前。该方式能够在完成多尺度特征提取后,对不同感受野特征进行自适应加权,从而增强关键电弧区域响应能力。

在获得增强特征 $\mathbf{X}'$ 后,将其输入改进 ResNet50 进行深层特征提取。为提升模型对电弧多尺度特征的感知能力,本文将传统单一卷积扩展为多尺度卷积结构,其残差映射如式 (21) 所示。

$$F(x_i) = \sum_{i=1}^K \phi_i(\mathbf{W}_i * \mathbf{X}') \quad (21)$$

其中, K 表示卷积分支数; $*_{d_i}$ 表示不同空洞率的卷积操作; $\phi_i(\cdot)$ 表示非线性变换。该结构能够同时捕捉局部细粒度特征和全局结构信息从而更好地适应电弧信号中突变与连续结构并存的特点。

在多尺度特征提取基础上,进一步引入 RFA 模块对特征进行自适应加权。设多尺度融合特征为 F_i , 则 RFA 过程可如下进行描述:

首先,如式 (22) 所示通过多尺度池化提取上下文信息。

$$\mathbf{Z}_i = \text{Pool}_{k_i}(\mathbf{F}_i) \quad (22)$$

如式 (23) 所示进行融合。

$$\mathbf{Z} = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_s] \quad (23)$$

随后,如式 (24) 所示生成注意力权重。

$$\mathbf{M} = \sigma(f(\mathbf{Z})) \quad (24)$$

最终,如式 (25) 所示输出。

$$\mathbf{F}_i^{\text{att}} = \mathbf{M} \odot \mathbf{F}_i \quad (25)$$

该机制能够根据不同感受野信息动态调整特征权重,使模型更加关注电弧关键区域。

结合多尺度卷积与 RFA 注意力机制,改进后的残差块输出可如式 (26) 所示。

$$y_i = \text{ReLU}(\mathbf{F}_i^{\text{att}} + \mathbf{F}(x_i)) \quad (26)$$

该结构在保留残差连接优势的同时,实现了 GAN、多尺度建模与 RFA 的有机融合。

从优化角度来看,本文方法不仅在结构上进行改进,还在训练过程中实现了生成模型与判别模型的协同优化,其整体目标函数可如式 (27) 所示。

$$\min_{\theta} \max_{\phi} L_{\text{GAN}} + \lambda L_{\text{cls}}(R(G(\mathbf{X})), y) \quad (27)$$

其中, L_{GAN} 为对抗损失; L_{cls} 为分类损失; $R(\cdot)$ 为改进 ResNet50。

该联合优化机制使得生成器不仅关注数据真实性,还需满足下游分类任务需求,从而实现特征分布与判别性能的协同提升。结构如图 9 所示。

5.2 Transformer 时序特征提取分支

弓网电弧信号本质上属于典型的非平稳时间序列,其特征不仅体现在瞬时突变,还表现为跨时间尺度的动态演化规律。尽管基于 MTF 编码的二维特征能够有效刻画局部结构信息,但其在长时序依赖关系建模方面仍存在一定局限性。因此,仅依赖空间特征难以充分挖掘电弧信号的全局时序特征。

为此,本文在空间特征提取分支的基础上,引入 Transformer 结构^[21]构建时序特征建模分支,从而实现对电弧信号长程依赖关系与全局动态特征的建模,进一步提升模型整体表达能力。

首先对其进行线性映射,根据式 (28) 将输入映射至高维特征空间。

$$\mathbf{Z}_0 = \mathbf{X}\mathbf{W}_e + \mathbf{b}_e \quad (28)$$

其中, $\mathbf{W}_e$ 与 $\mathbf{b}_e$ 分别为嵌入层权重与偏置。

由于 Transformer 本身不具备序列顺序感知能力,如式 (29) 进一步引入位置编码。

$$\mathbf{Z} = \mathbf{Z}_0 + \mathbf{P} \quad (29)$$

其中, $\mathbf{P}$ 表示位置编码,用于保留时间序列的顺序信息。

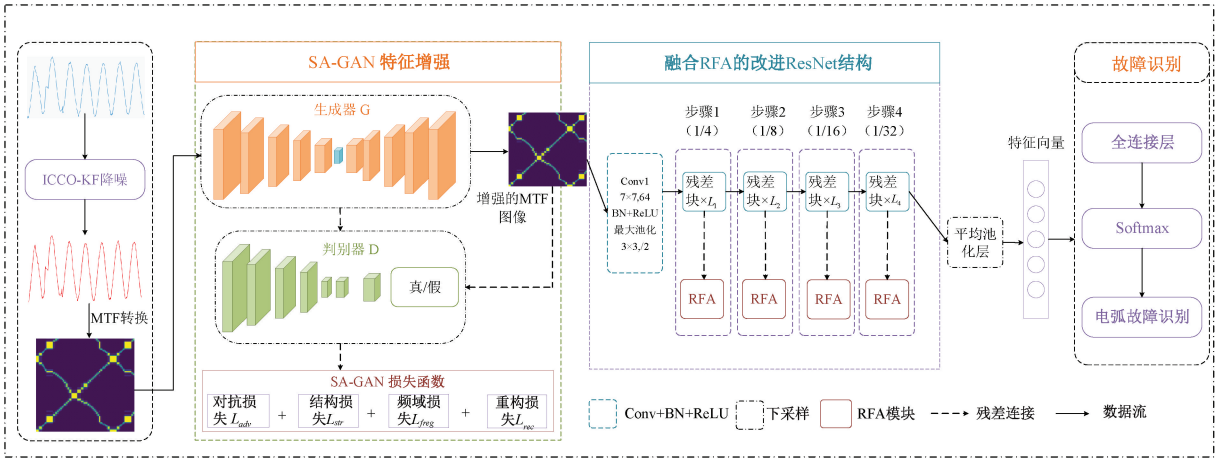


图9 结构感知生成对抗网络与感受野注意力机制融合的残差神经网络

Fig. 9 Residual neural network integrating structure-aware generative adversarial network and receptive field attention mechanism

Transformer 的核心在于自注意力机制,其能够动态捕捉序列中任意位置之间的依赖关系。

对于输入特征 $\mathbf{Z}$,通过式(30)线性映射得到查询(Query, $\mathbf{Q}$)、键(Key, $\mathbf{K}$)和值(Value, $\mathbf{V}$)。

$$\begin{cases} \mathbf{Q} = \mathbf{Z}\mathbf{W}_Q \\ \mathbf{K} = \mathbf{Z}\mathbf{W}_K \\ \mathbf{V} = \mathbf{Z}\mathbf{W}_V \end{cases} \quad (30)$$

注意力计算如式(31)所示。

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (31)$$

其中, d_k 为缩放因子。

为了提升模型表达能力,如式(32)采用多头机制。

$$\text{MultiHead}(\mathbf{Z}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}_0 \quad (32)$$

该结构能够从不同子空间中学习特征关系,从而增强模型对复杂电弧动态模式的建模能力。

在每个 Transformer 编码层中,自注意力模块如式(33)后接前馈神经网络。

$$\text{FFN}(\mathbf{Z}) = \max(0, \mathbf{x}\mathbf{W}_1 + \mathbf{b}_1) \mathbf{W}_2 + \mathbf{b}_2 \quad (33)$$

同时,如式(34)和(35)引入残差连接与归一化。

$$\mathbf{Z}' = \text{LayerNorm}(\mathbf{Z} + \text{MultiHead}(\mathbf{Z})) \quad (34)$$

$$\mathbf{Z}'' = \text{LayerNorm}(\mathbf{Z}' + \text{FFN}(\mathbf{Z}')) \quad (35)$$

通过堆叠多个编码器层,模型能够逐层提取更高层次的时序特征表示。Transformer 结构如图10所示。

经过多层 Transformer 编码后,得到时序特征如式(36)表示。

$$\mathbf{F}_{\text{time}} = \text{Transformer}(\mathbf{X}) \quad (36)$$

该特征向量包含了电弧突变信息、周期性变化特征以及长程依赖关系。

5.3 Transformer 与 SA-GAN-ResNet 分支的融合机制

为提高模型的最终的识别准确率,本文采用双分




图10 Transformer 结构

Fig. 10 Transformer structure diagram

支结构。

空间分支定义为如式(37)所示。

$$\mathbf{F}_{\text{space}} = R(G(\mathbf{X})) \quad (37)$$

时序分支定义为如式(38)所示。

$$\mathbf{F}_{\text{time}} = T(\mathbf{X}) \quad (38)$$

最终进行根据式(39)特征融合。

$$F_{\text{fusion}} = \text{Concat}(F_{\text{space}}, F_{\text{time}}) \quad (39)$$

在弓网电弧检测任务中,引入时序分支与空间分支的双分支融合结构,能够从本质上弥补单一模型在特征表达上的局限性。

本文采用 Concat 方式而非加权融合或注意力融合,主要基于以下考虑:

- 1) 空间分支与时序分支特征维度差异较大,Concat 能够最大程度保留原始特征信息;
- 2) 加权融合需要引入额外可训练参数,在小样本条件下易造成模型过拟合;
- 3) Concat 结构实现简单、训练稳定性较高,更适用于复杂工况下的弓网电弧检测任务。

具体而言,基于 SA-GAN 与 RFA 改进的 ResNet50 侧重于对 MTF 图像进行空间特征提取,能够有效捕捉电弧放电过程中的局部纹理信息、边缘结构及多尺度空间分布特征;而 Transformer 时序分支则直接作用于原始一维信号,擅长建模电弧信号随时间演化的动态规律及长程依赖关系。二者在特征维度上具有显著互补性:前者强调“形态与结构”,后者关注“变化与趋势”。通过特征融合策略,将两类特征在高维空间进行联合表示,使模型不仅能够识别瞬时电弧突变,还能理解其前后演化过程,从而显著提升对复杂工况下电弧模式的判别能力。

5.4 融合迁移学习策略

考虑到弓网电弧数据获取成本较高、样本规模有限,本文引入迁移学习策略^[22]以提升模型训练效率与泛化能力。具体而言,在空间分支中选用在大规模图像数据集(ImageNet)^[23]上预训练的 ResNet50 模型作为基础网络,并将其作为 RFA-ResNet50 的初始化权重。在此基础上,仅对高层特征提取模块及分类层进行微调训练,从而使模型能够快速适应弓网电弧数据分布。

5.5 总体模型设计思路

本文整体模型基于“信号预处理-特征增强-双分支建模-特征融合”的思路构建。首先,利用 ICCO 优化 KF 对原始弓网电弧信号进行降噪处理,并通过 MTF 将一维信号映射为二维图像;随后引入 SA-GAN 对图像特征进行增强,以提升关键电弧特征的可分性。在特征提取阶段,构建空间-时序双分支结构,其中空间分支采用引入 RFA-ResNet50 对 MTF 图像进行多尺度特征提取,并基于 ImageNet 预训练权重进行迁移学习初始化,以提升模型收敛速度与泛化能力;时序分支则利用 Transformer 对原始信号进行长程依赖建模。最后,通过特征融合模块对两分支输出进行联合表示,实现对弓网电弧信号的高精度识别。整体设计思路如图 11 所示。




图 11 本文模型结构
Fig. 11 Structure diagram of the proposed model

5.6 模型与弓网电弧物理机理对应关系分析

弓网电弧是受电弓与接触网之间发生接触不稳定或瞬时离线时产生的放电现象,其形成过程受到接触压力变化、接触网振动、列车运行速度以及空气介质击穿等因素影响。电弧产生后,电流信号通常会表现出零休现象、高频扰动以及明显的非平稳特征。因此,本文所构建的 SA-GAN、RFA-ResNet50 和 Transformer 双分支模型并非简单的网络结构组合,而是针对弓网电弧不同物理特征进行有针对性的建模与表征。

1)从电弧高频扰动特征来看,电弧在燃烧过程中伴随着大量高频脉冲和能量突变现象,这些特征在 MTF 图像中通常表现为边缘突变区域、纹理细节区域以及局部能量聚集区域。传统深度网络在特征提取过程中容易受到噪声干扰,导致部分关键特征被削弱。为此,本文引入 SA-GAN 对输入特征进行增强处理,通过保持原始结构信息并强化局部细节特征,使电弧相关纹理更加清晰,从而提高后续网络对高频扰动特征的识别能力。

2)从电弧局部放电特征来看,弓网电弧往往集中出现在接触状态发生变化的瞬间,其对应信号通常具有明显的局部异常特征。在 MTF 图像中,这些特征表现为局部纹理增强区域或异常结构区域。传统卷积网络采用固定感受野提取特征,容易忽略不同尺度下的重要信息。本文在 ResNet50 中引入 RFA 机制,通过多尺度感受野对不同区域特征进行自适应选择,使网络能够更加关注与电弧相关的关键区域,从而增强对局部放电特征的提取能力。

3)从电弧动态演化过程来看,弓网电弧并非瞬时随机现象,而是经历产生、发展和熄灭等多个阶段。电弧产生前通常伴随接触状态变化,形成过程中会出现高频振荡和能量释放,熄灭后则逐渐恢复正常受流状态。因此,电弧信号具有明显的时间关联特征和动态演化规律。本文引入 Transformer 构建时序特征提取分支,通过全局建模能力学习不同时刻之间的关联关系,从整体上刻画电弧形成与发展的动态过程,提高模型对复杂工况下电弧信号的表征能力。

4)从时空特征融合角度来看,弓网电弧同时具有空间结构特征和时间演化特征。空间分支重点描述电弧对应的纹理结构、边缘变化以及局部能量分布;时序分支重点刻画电弧产生、发展和熄灭过程中的动态变化规律。通过融合两类特征信息,模型能够同时利用电弧的结构特征与演化特征进行判别,实现对弓网电弧更加全面和准确的识别。

综上所述,SA-GAN 主要负责强化电弧高频扰动和局部突变特征,RFA-ResNet50 主要负责提取电弧关键区域的空间结构信息,Transformer 主要负责建模电弧动态演化规律。三者共同构建了从物理特征到深度特征的映射关系,实现了对弓网电弧特征的全面表征,这也是本文

模型能够在复杂工况下保持较高识别精度和良好鲁棒性的主要原因。

5.7 模型参数设置

为保证实验结果的可重复性,并验证所提模型参数配置的合理性,本文对 ICCO、MTF 编码过程以及深度学习网络中的关键超参数进行了统一设置。各参数均结合相关文献经验和预实验结果确定,具体参数配置如表 5 所示。

表 5 模型关键参数设置
Table 5 Key parameter settings of the proposed model

参数类别	参数名称	取值
Transformer	编码器层数	4
	注意力头数	8
	隐藏层维度	128
网络训练	Batch Size	32
	Learning Rate	0.000 1
	Dropout	0.1

Transformer 层数和注意力头数直接影响模型时序特征提取能力。层数过少难以充分学习长时序依赖关系,而层数过多会增加模型复杂度并提高过拟合风险。综合考虑识别性能和计算效率,最终采用 4 层编码器结构,每层包含 8 个注意力头,隐藏层维度设置为 128。

模型训练采用 Adam 优化器,初始学习率设置为 0.000 1。较大的学习率容易导致训练过程震荡,而较小的学习率会降低收敛速度。Batch Size 设置为 32,在显存占用和训练稳定性之间取得较好平衡。Dropout 系数设置为 0.1,以降低过拟合风险并提高模型泛化能力。

6 实验设计与结果分析

考虑到弓网电弧数据获取成本较高,样本规模相对有限,若进一步划分验证集将导致训练样本数量减少,从而影响模型学习能力。因此,本文未单独设置验证集,而是在训练过程中采用多种策略替代验证集的功能,以确保模型训练的稳定性与泛化能力。

因此,为充分利用有限样本数据,本文采用训练集与测试集划分方式,4 组实验条件每组采集正常和故障数据分别为 250 组,每组实验条件共 500 组,将数据集按照 8:2 的比例划分为训练集与测试集,其中 80% 的数据用于模型训练,20% 的数据用于模型性能评估。测试集在整个训练过程中保持独立,仅在模型训练完成后用于最终性能验证,以保证实验结果的客观性与公平性。

实验采样频率设置为 5 kHz,即每秒采集 5 000 个数据点。考虑到弓网系统工频为 50 Hz,一个完整工频周期对应 20 ms,因此本文选取 100 个采样点作为滑动窗口长

度,对应时间长度为 20 ms。该窗口长度能够完整覆盖一个工频周期内电弧产生、发展和熄灭过程中出现的电流波动、高频扰动以及过零畸变等典型特征,既保证了电弧信息的完整性,又避免了窗口过长导致特征冗余。

本文数据预处理流程主要包括信号分割、归一化、降噪处理以及时频编码 4 个阶段。首先对原始电流信号进行滑窗分割,然后采用 Min-Max 方法完成归一化处理;随后利用 ICCO-KF 进行自适应降噪,以抑制背景噪声;最

后通过 MTF 将一维时间序列映射为二维图像,并输入后续深度学习模型进行训练与识别。

6.1 消融实验结果分析

为进一步分析各模块对模型性能的贡献,本文设计消融实验,通过逐步引入 SA-GAN、RFA 及 Transformer 模块,对模型性能变化进行评估。图 12 为仅在暴风机气流速度为 89.3 km/h,接触压力为 40 N 的实验条件下,各模型的识别结果。




图 12 消融实验对比

Fig. 12 Comparison of ablation experiments

从混淆矩阵可以看出本文模型识别结果最佳。然而,为避免实验结果的偶然性,将各模型对其他 3 种实验条件下电弧电流信号进行识别,计算 4 次识别结果的平均准确率和 F1 分数,计算结果如表 6 所示。

表 6 消融实验对比结果

Table 6 Comparative results of ablation experiments		
模型结构	准确率/%	F1 分数/%
ResNet50	92.0	92
RFA-ResNet50	93.0	93
GAN-ResNet50	94.5	94
GAN-RFA-ResNet50	95.0	95
RFA-ResNet50-Transformer	96.0	96
本文	97.5	97

从结果可以看出,引入 RFA 模块后,模型准确率由 92% 提升至 93%,说明注意力机制能够有效增强关键特征提取能力;引入 SA-GAN 后,模型性能进一步提升,表明特征增强有助于提高数据可分性;融合 Transformer 后,模型准确率达到 97.5%,说明时序建模对电弧信号识别具有重要作用;最终融合全部模块后,模型性能达到最优,验证了各模块之间的协同作用。

6.2 分类性能对比

为验证本文方法在弓网电弧识别任务中的整体性能,选取多种传统机器学习方法及深度学习模型进行对比实验。为保证实验结果的公平性与可重复性,所有模型均在相同实验平台、相同训练集与测试集划分条件下进行训练,并统一采用 Adam 优化器、Batch Size 为 32、初始学习率为 0.000 1 以及相同训练轮数设置。各模型分

别对 4 种实验条件下的电弧信号进行识别,并计算各模型的平均准确率、平均精确率、平均召回率及 $F1$ 分数。对比模型参数配置和实验结果如表 7 和 8 所示。

表 7 对比模型参数配置

Table 7 Parameter settings of comparative models	
模型	主要参数配置
SVM	RBF 核函数, $C=10, \gamma=0.01$
CNN	Conv(32)-Conv(64)-Conv(128), FC(256)
ResNet50	标准 ResNet50 结构
LSTM	Hidden Size = 128, Layers = 2
Transformer	Layers = 4, Heads = 8, Hidden = 128
CNN-Transformer	CNN 特征提取+Transformer(4 层, 8 头)
本文	ICCO-KF+SA-GAN+RFA-ResNet50+Transformer

表 8 不同模型对比

Table 8 Comparison of different models (%)				
模型	平均准确率	平均精确率	平均召回率	$F1$ 分数
SVM	85	83	85	84
CNN	91	90	90	90
ResNet50	92	91	92	92
LSTM	91	90	91	91
Transformer	93	92	93	93
CNN-Transformer	95	94	95	95
本文	97.5	97	97	97

表 8 给出了不同模型在测试集上的分类性能对比结果。结果表明,传统机器学习方法 SVM 整体性能较低,而深度学习方法具有明显优势。其中, ResNet50 与 Transformer 相比基础 CNN 模型和长短期记忆网络(long short-term memory, LSTM)均有一定提升,说明深层特征提取与时序建模对电弧检测具有重要作用。相比之下,本文提出的 SGRT-Net 在各项指标上均取得最优性能,其中准确率达到 97.5%, $F1$ 分数达到 97%, 显著优于所有对比模型。这表明所提出的多模块融合结构能够有效提升模型对弓网电弧特征的识别能力。

6.3 不同融合策略对比分析

为验证融合策略的合理性,本文进一步比较加权融合、注意力融合、交叉注意力融合以及拼接融合 4 种融合方式。比较结果如图 13 所示。

结果表明,交叉注意力融合虽然能够实现跨模态特征交互,但需要额外引入大量可训练参数,在小样本条件下容易产生过拟合现象。加权融合依赖人工设定权重,难以充分反映不同模态特征的重要程度。相比之下,拼




图 13 不同融合策略性能比较

Fig. 13 Performance comparison of different fusion strategies

接融合能够完整保留空间分支与时序分支特征信息,并通过后续全连接层自动学习最优特征组合关系,因此获得最佳识别性能。

6.4 不同 Q 值效果对比

为验证前文 Q 值选择的优越性,进行不同 Q 值对模型识别准确率的影响,不同 Q 值效果对比结果如表 9 所示。

表 9 不同 Q 值效果对比

Table 9 Performance comparison under different Q values	
Q 值	准确率/%
4	95.0
8	97.5
16	97.0
31	96.0

从结果可以看出, Q 值的选择过大或者过小都会导致模型识别准确率下降,当 Q 值为 8 时,模型的识别准确率最佳。

6.5 迁移学习效果分析

为验证迁移学习策略对模型性能的影响,分别对比无迁移学习、采用预训练 ResNet50 以及本文完整模型的训练效果。重点分析模型收敛速度及最终识别精度。

图 14 是实验条件为暴风机气流速度为 89.3 km/h, 接触压力为 40 N 时各模型识别结果。从结果可以看出进行迁移学习后的模型的识别准确率相较于无迁移学习有所提高。为进一步避免识别结果的偶然性,分别对其他 3 种实验条件下的电弧信号进行识别并计算各指标平均值。计算结果如表 10 所示。

从表 10 可以看出,引入迁移学习后,模型收敛速度明显加快,训练轮数由 78 轮减少至 39 轮,同时准确率由 95% 提升至 97.5%。说明预训练模型能够提供更优初始化参数,有效提升模型在小样本条件下的泛化能力。




图 14 迁移学习结果对比

Fig. 14 Comparison of transfer learning results

表 10 迁移学习效果对比		
Table 10 Comparison of transfer learning effects		
方法	准确率/%	收敛 Epoch
无迁移学习	95.0	78
迁移学习(预训练)	96.0	52
本文模型(结合迁移学习)	97.5	39

6.6 抗噪性能分析

为进一步评估模型在复杂噪声环境下的鲁棒性,在不同信噪比条件下对模型进行测试,对比 ResNet50、Transformer 及本文方法的识别性能。考虑到高速铁路弓网系统实际运行过程中受到电磁干扰、设备测量误差以及环境随机扰动等因素影响,其噪声特性通常表现为随机分布特征。因此,本文抗噪实验采用加性高斯白噪声(additive white gaussian noise, AWGN)模拟实际环境噪声。在 4 种实验条件下进行抗噪性能对比,计算在 4 种实验条件下的平均识别准确率,实验结果如表 11 所示。

表 11 抗噪性能对比结果				
Table 11 Comparative results of anti-noise performance				
模型	SNR			
	0 dB	5 dB	10 dB	15 dB
ResNet50	78.0	85	89	92.0
Transformer	80.5	87	91	93.0
本文	86.0	90	94	97.5

实验结果表明,随着噪声强度增加,各模型性能均有所下降,但本文方法始终保持最高准确率。在低信噪比条件下,本文方法仍达到 86%,显著优于对比模型,说明该方法具有较强的抗干扰能力。

通过多组对比实验验证了所提出方法的有效性。实验结果表明,SA-GAN 能够有效提升特征表达质量;RFA-ResNet50 增强了关键特征提取能力;Transformer 分支提升了时序建模能力;迁移学习进一步提高了模型泛化性能。各模块协同作用,使得本文方法在复杂工况下仍能实现高精度、稳定的弓网电弧检测。

6.7 模型复杂度分析

为进一步评估本文模型在实际工程中的部署可行性,对不同模型的参数量、计算量以及推理速度进行分析,结果如表 12 所示。

表 12 模型复杂度结果			
Table 12 Comparison of model complexity			
模型	参数量/M	FLOP/G	单样本推理时间/ms
ResNet50	23.5	4.1	12.7
Transformer	18.2	3.6	10.8
CNN-Transformer	31.6	6.3	17.5
本文	34.8	6.9	19.2

实验平台采用 RTX3060 GPU 进行测试。结果表明,虽然本文模型参数量与计算量略有增加,但单样本推理时间仍控制在 20 ms 以内,能够满足弓网电弧在线检测任务的实时性需求。各模块复杂度贡献分析见后文。

本文模型主要由 ICCO-KF 降噪模块、SA-GAN 特征增强模块、RFA-ResNet50 空间特征提取模块以及 Transformer 时序建模模块组成。不同模块对模型性能提升和计算开销的贡献存在明显差异。

因此,为深度分析各模块对本文模型的模型性能提升和计算开销的贡献,进行各模块复杂度贡献分析,分析结果如表 13 所示。

表 13 各模块复杂度贡献分析

Table 13 Complexity contribution analysis of different modules

模块	参数/M
RFA	1.2
SA-GAN	4.5
Transformer	5.1

表 13 给出了本文模型主要功能模块对整体参数数量的贡献情况。从表中可以看出,Transformer 模块参数数量最高,达到 5.1 M,是模型复杂度增加的主要来源。这是由于 Transformer 需要通过多头自注意力机制建立长距离时序依赖关系,从而实现对弓网电弧动态演化过程的全局建模。

SA-GAN 模块参数数量为 4.5 M,主要用于电弧特征增强。该模块通过生成对抗学习强化 MTF 图像中的纹理细节和局部结构特征,提高电弧特征的可分性。虽然增加了一定参数数量,但能够有效改善原始样本质量,为后续特征提取提供更加丰富的特征信息。

RFA 模块参数数量仅为 1.2 M,在整体模型中占比较小。该模块通过多尺度感受野建模实现关键区域特征增强,能够引导网络更加关注电弧局部放电区域和异常纹理区域,在较小参数开销下显著提升空间特征提取能力。

综合来看,本文模型新增参数主要来源于 SA-GAN 和 Transformer 模块。其中,SA-GAN 负责提升输入特征质量,Transformer 负责建立全局时序关联,而 RFA 则进一步增强关键区域特征表达能力。三者共同构建了完整的“特征增强-空间建模-时序建模”框架,使模型在复杂工况下仍能够保持较高识别精度。

7 结 论

本文针对弓网电弧信号强噪声、非平稳及特征难以表征等问题,提出了一种融合 ICCO 优化卡尔曼滤波、SA-GAN 特征增强、RFA-ResNet50 空间特征提取与 Transformer 时序建模的双分支检测方法,并结合迁移学习提升模型泛化能力。

1) 针对传统卡尔曼滤波参数依赖经验设定的问题,提出 ICCO 优化卡尔曼滤波方法。通过佳点集初始化和自适应策略切换机制实现滤波参数自适应寻优,在保留电弧突变特征的同时有效抑制背景噪声,提高了信号质量,为后续特征提取提供了可靠数据基础;

2) 针对弓网电弧特征弱、易受噪声干扰的问题,构建 SA-GAN 特征增强模型。通过保持电弧关键结构信息并增强局部纹理特征,提高了 MTF 图像中电弧特征的可分

性,为深度网络学习提供更加清晰的特征表达;

3) 针对单一特征难以全面表征电弧信息的问题,构建 RFA-ResNet50 与 Transformer 双分支时空特征融合模型。空间分支负责提取电弧纹理结构和局部异常特征,时序分支负责建模电弧产生、发展和熄灭过程中的动态变化规律。通过时空特征融合实现对电弧特征的全面表征,最终识别准确率达到 97.5%,优于各类对比模型;

4) 针对弓网电弧样本数量有限的问题,引入迁移学习策略。利用 ImageNet 预训练权重初始化空间特征提取网络,提高模型收敛速度和泛化能力。实验结果表明,引入迁移学习后模型收敛轮数由 78 轮降低至 39 轮,同时识别准确率进一步提升。

实验结果表明,本文方法在信号降噪、特征增强、分类识别以及抗噪性能等方面均取得较好效果,在复杂工况和低信噪比条件下仍能实现稳定准确的弓网电弧检测,验证了所提方法的有效性和工程应用价值。

未来研究将重点围绕以下 3 个方面展开:(1) 结合轻量化网络和模型压缩技术降低计算复杂度,提高边缘端部署能力;(2) 研究跨线路、跨运行工况条件下的迁移学习方法,提高模型泛化性能;(3) 进一步结合实际高速铁路运行环境开展在线检测验证,为弓网状态智能监测与故障预警提供技术支持。

参考文献

[1] 甄敬怡. “八纵八横”高铁网“关键一横”贯通[N]. 中国改革报, 2025-12-24(001).

ZHEN J Y. The “key horizontal” of the “eight vertical and eight horizontal” high-speed railway network has been completed[N]. China Reform Daily, 2025-12-24(001).

[2] 樊曦, 张斌. 再上新台阶! 中国高铁运营里程突破 5 万公里[N]. 新华每日电讯, 2025-12-27(001).

FAN X, ZHANG B. On to a new level ! China’s high-speed rail operation mileage exceeded 50 000 kilometers[N]. Xinhua Daily Telegraph, 2025-12-27(001).

[3] 吴广宁, 钱鹏宇, 刘汶信, 等. 高速铁路弓网电弧研究进展:影响因素与防治方法[J]. 物理学报, 2025, 74(23): 8-28.

WU G N, QIAN P Y, LIU W J, et al. Research progress of high-speed railway pantograph arc: Influencing factors and prevention methods[J]. Acta Physica Sinica, 2025, 74(23): 8-28.

[4] 蔡智超, 王健芬, 程宏波, 等. 基于多模成像融合的弓网电弧检测方法研究[J]. 仪器仪表学报, 2025, 46(11): 124-135.

CAI ZH CH, WANG J F, CHENG H B, et al. Research

- on pantograph-catenary arc detection via multimodal imaging fusion [J]. Chinese Journal of Scientific Instrument, 2025, 46(11): 124-135.
- [5] 李斌, 娄璟, 杜典松. 基于 SOA-SVM 的弓网电弧识别方法[J]. 电子测量与仪器学报, 2022, 36(10): 83-91.
- LI B, LOU J, DU D S. Pantograph-catenary arc recognition method based on SOA-SVM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 83-91.
- [6] 李斌, 阎君宇. 基于 GAF-CNN 的弓网电弧识别方法研究[J]. 电子测量与仪器学报, 2022, 36(1): 188-195.
- LI B, YAN J Y. Research on pantograph-catenary arc recognition method based on GAF-CNN [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 188-195.
- [7] 李斌, 舒嘉辉, 严灵潇, 等. 改进黑翅鸢算法的 1D-2D-GAF-PCNN-GRU-MSA 弓网电弧检测应用[J]. 电子测量与仪器学报, 2024, 38(10): 201-211.
- LI B, SHU J H, YAN L X, et al. 1D-2D-GAF-PCNN-GRU-MSA pantograph arc detection application based on improved black-winged kite algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 201-211.
- [8] YANG G, KONG G W, SHEN X. Arc recognition for pantograph-catenary system of railway using current[J]. Measurement, 2025, 251: 117304.
- [9] QUAN W, XU X Q, LIU X L, et al. ArcSE: A dual-branch semantic segmentation model for robust pantograph-catenary arcing detection in complex environments[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 74: 2502814.
- [10] YAN Y, LIU H, GAN L F, et al. A novel arc detection and identification method in pantograph-catenary system based on deep learning[J]. Scientific Reports, 2025, 15(1): 3511.
- [11] 刘兴华, 董思文, 田佳强. 基于卡尔曼滤波分解的配电网安全状态估计[J]. 系统仿真学报, 2023, 35(6): 1191-1202.
- LIU X H, DONG S W, TIAN J Q. Distribution network security state estimation based on Kalman filter decomposition[J]. Journal of System Simulation, 2023, 35(6): 1191-1202.
- [12] 刘建锋, 范一凡, 宋伊宁, 等. 基于改进连续变分模态分解和深度残差网络及漏磁信号的变压器绕组故障诊断[J]. 电网技术, 2025, 49(10): 4428-4437.
- LIU J F, FAN Y F, SONG Y N, et al. Transformer winding fault diagnosis based on improved continuous variational mode decomposition, deep residual network, and leakage flux signal [J]. Power System Technology, 2025, 49(10): 4428-4437.
- [13] 李明光, 陶重霖. 基于 Transformer 的特征频率解耦融合三维目标检测方法[J]. 仪器仪表学报, 2025, 46(7): 345-357.
- LI M G, TAI C H B. Feature frequency decoupling and fusion for 3D object detection with Transformer [J]. Chinese Journal of Scientific Instrument, 2025, 46(7): 345-357.
- [14] WANG T L, GU S H W, LIU R J, et al. Cuckoo catfish optimizer: A new meta-heuristic optimization algorithm[J]. Artificial Intelligence Review, 2025, 58(10): 326.
- [15] XUE J, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization[J]. Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [16] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization [J]. Neurocomputing, 2023, 532: 183-214.
- [17] XIAO Y N, CUI H, KHURMA R A, et al. Artificial lemming algorithm: A novel bionic meta-heuristic technique for solving real-world engineering optimization problems [J]. Artificial Intelligence Review, 2025, 58(3): 84.
- [18] TROJOVSKY P, DEGHANI M. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications [J]. Sensors, 2022, 22(3): 855.
- [19] 张效天, 王雪, 强振峰. 边缘计算生成式对抗网络差分进化滚动轴承特征识别方法[J]. 仪器仪表学报, 2023, 44(1): 112-120.
- ZHANG X T, WANG X, QIANG Z H F. An edge computing method for differential evolution of generative adversarial networks rolling bearing feature recognition [J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 112-120.
- [20] 刘桂雄, 廖普, 杨宁祥. 基于深度学习主动视觉压力容器焊缝质量参数检测方法[J]. 仪器仪表学报, 2023, 44(5): 1-9.
- LIU G X, LIAO P, YANG N X. Active vision pressure

vessel weld quality parameter detection method based on deep learning [J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 1-9.

[21] 于豪, 蒋锦霞, 赖晓翰, 等. 基于自适应感受野的电力设备表面缺陷检测方法[J]. 系统仿真学报, 2023, 35(7): 1572-1580.

YU H, JIANG J X, LAI X H, et al. Surface defect detection of power equipment using adaptive receptive field network[J]. Journal of System Simulation, 2023, 35(7): 1572-1580.

[22] 尹超, 肖博, 李孝斌, 等. 基于多源域加权迁移学习的滚动轴承开集故障诊断方法[J]. 计算机集成制造系统, 2025, 31(12): 4695-4707.

YIN CH, XIAO B, LI X B, et al. Open-set fault diagnosis of rolling bearings based on multi-source domain weighted transfer learning [J]. Computer Integrated Manufacturing Systems, 2025, 31(12): 4695-4707.

[23] 李斌, 郑睦译. 基于马尔可夫转移场与改进梦境优化算法的弓网电弧故障检测研究[J]. 电子测量与仪器学报, 2026, 40(4): 51-67.

LI B, ZHENG M Y. Research on pantograph-catenary are fault detection based on Markovtransition field and improved dream optimization algorithm [J]. Journal of Electronic Measurement and Instrument, 2026, 40(4): 51-67.

作者简介



李斌, 分别在 2003 年、2006 年和 2012 年于辽宁工程技术大学获得学士学位、硕士学位和博士学位。现为辽宁工程技术大学副教授, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。

E-mail:25992816@qq.com

Li Bin received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Liaoning Technical University in 2003, 2006 and 2012, respectively. He is currently an associate professor in Liaoning Technical University. His main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.



齐慧(通信作者), 2022 年于辽宁工程技术大学获得学士学位。现为辽宁工程技术大学硕士研究生, 主要研究方向为电接触理论及应用、智能电器与智能电网技术。

E-mail:1503612505@qq.com

Qi Hui (Corresponding author) received her B. Sc. degree from Liaoning Technical University in 2022. She is currently an M. Sc. candidate at Liaoning Technical University. Her main research interests include electrical contact theory and application, intelligent appliances and smart grid technology.