

# 物理知识引导下覆冰迭代自迁移预测

王振国<sup>1</sup>, 李特<sup>1</sup>, 郑文哲<sup>1</sup>, 王燕<sup>2</sup>, 侯慧<sup>2</sup>, 林湘宁<sup>3</sup>

(1. 国网浙江省电力有限公司电力科学研究院, 浙江 杭州 310014; 2. 武汉理工大学自动化学院, 湖北 武汉 430070;  
3. 华中科技大学电气与电子工程学院, 湖北 武汉 430074)

**摘要:** 高影响覆冰事件对电力系统的稳定运行构成威胁。然而, 在小样本场景下, 传统的物理知识引导和数据模型驱动的预测效果欠佳。因此, 将物理信息神经网络(physics-informed neural network, PINN)与自迁移学习(self-transfer learning, STL)融合, 提出一种物理知识引导下覆冰迭代自迁移(physics knowledge guided iterative self-transfer learning, PKG-ISTL)模型。首先, 将数据划分为源域及目标域, 构建包含空间、特征与时间维度的三维张量, 实现滑动窗口覆冰预测。其次, 将 PINN 与 STL 融合搭建模型。在源域分支, 训练具备物理知识的 PINN 指导模型。在自迁移分支, 应用多核最大均值差异进行域自适应处理。在目标域分支, 运用知识蒸馏将专家模型中的物理知识自迁移至受训模型。最后, 利用广西省某区段多个输电线路的历史覆冰数据进行算例仿真, 并通过可解释性分析, 揭示气象、力学、线路及覆冰因素等对线路覆冰的影响程度。结果表明, 相比传统数据模型驱动, PKG-ISTL 模型预测精度提升 47.69%, 验证了其在小样本场景的有效性。

**关键词:** 覆冰预测; 物理信息神经网络; 自迁移学习; 知识蒸馏; 三维张量

## Physics knowledge guided iterative self-transfer learning for icing prediction

WANG Zhenguo<sup>1</sup>, LI Te<sup>1</sup>, ZHENG Wenzhe<sup>1</sup>, WANG Yan<sup>2</sup>, HOU Hui<sup>2</sup>, LIN Xiangning<sup>3</sup>

(1. Research Institute of State Grid Zhejiang Electric Power Company, Hangzhou 310014, China; 2. School of Automation, Wuhan University of Technology, Wuhan 430070, China; 3. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract:** High impact icing events pose a threat to the stable operation of power systems. However, under small-sample scenarios, traditional physics-knowledge guidance and data-driven prediction methods often have poor performance. Therefore, a physics knowledge guided iterative self-transfer learning (PKG-ISTL) model is proposed, integrating physics informed neural network (PINN) with self-transfer learning (STL). First, the data is divided into source and target domains, and a three-dimensional tensor containing spatial, feature, and temporal dimensions is constructed to achieve sliding-window-based icing prediction. Second, the model is built by combining PINN and STL. In the source domain branch, a PINN is trained to guide the model using physics knowledge. In the self-migration branch, multi-kernel maximum mean discrepancy is applied for domain adaptation. In the target domain branch, knowledge distillation is used to transfer physics knowledge from the expert model to the trained model. Finally, historical icing data from transmission lines in Guangxi province are used for simulation. Through interpretability analysis, the influence of meteorological, mechanical, line, and icing factors on line icing is revealed. Results show that compared to traditional data-driven models, the PKG-ISTL model improves prediction accuracy by 47.69%, verifying its effectiveness in small-sample scenarios.

This work is supported by the Key Program of National Natural Science Foundation of China (No. U22B20106).

**Key words:** icing prediction; physics-informed neural network; self-transfer learning; knowledge distillation; three-dimensional tensor

**基金项目:** 国家自然科学基金重点项目资助 (U22B20106); 浙江省自然科学基金项目资助 (LZJMY25D050006); 国网浙江省电力有限公司科技项目资助 (B311DS24001A)

## 0 引言

极端天气事件频发,覆冰频率呈现上升趋势,其影响程度愈发显著<sup>[1-4]</sup>。2024年2月,大范围冻雨事件对我国中东部地区电力系统的可靠性造成威胁<sup>[5]</sup>,凸显灾前覆冰预测的重要性<sup>[6]</sup>。针对低频率高影响的覆冰事件,覆冰与非覆冰样本比例严重失衡,预测模型往往性能受限<sup>[7]</sup>。因此,亟须开发适应于小样本场景的预测模型,实现对覆冰事件的预测与评估。

目前覆冰预测建模主要有2种方法:物理知识引导与数据模型驱动<sup>[8-10]</sup>。1)物理知识引导融入覆冰机理,建立如Imai、Goodwin及Makkonen等模型模拟覆冰形成过程<sup>[11-12]</sup>,具有较强的可解释性,但参数选择复杂,限制了其在小样本场景中的应用效果。2)数据模型驱动方法利用机器学习和深度学习技术进行预测。传统机器学习方法,如线性回归(linear regression, LR)、决策树(decision tree, DT)、随机森林(random forest, RF)、自适应增强算法(adaptive boosting, AdaBoost)与多层感知器(multilayer perceptron, MLP)等<sup>[13]</sup>,依赖大量标记数据,难以在小样本场景中取得理想效果;深度学习方法,如卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory, LSTM)、门控循环单元(gated recurrent units, GRU)、双向循环神经网络(bidirectional recurrent neural network, Bi-RNN)、与双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)等<sup>[14-16]</sup>,虽在小样本场景中表现优异,但缺乏物理知识引导,可解释性较差。

为兼顾预测精度与模型可解释性,物理信息神经网络(physics-informed neural network, PINN)被提出<sup>[17]</sup>,广泛应用于流体力学、热传导等领域。文献[18]提升了油藏流体的预测精度,文献[19]有效重构了传热模拟中的未知热边界条件,文献[20]实现了复杂应力环境下材料疲劳寿命的精准预测。综上所述, PINN在覆冰预测领域具有潜在优势,既能保持深度学习的高预测能力,又能增强模型的可解释性。然而, PINN在小样本场景中的应用仍面临挑战,尤其是在处理不同区域数据时,如何应对空间差异性以及区域独立建模带来的分布差异性问题仍需进一步研究。

另外,自迁移学习(self transfer learning, STL)已在覆冰预测、图像识别与故障检测等领域证实其有效性<sup>[21]</sup>。STL在小样本场景中,显著提升模型性能。文献[22]显示STL在有限结冰图像数据集上依然能够实现有效识别。文献[23]通过静态叶片模型的自迁移,提高旋转叶片覆冰状态预测准确性。文

献[24]应用STL实现了风力涡轮机故障检测。STL在小样本场景中显著提升模型性能,通过域自适应技术如多核最大均值差异(multi-kernel maximum mean discrepancy, MK-MMD)等,适配源域与目标域的分布差异<sup>[25-26]</sup>。为提升小样本场景的泛化能力,可选择基于样本、特征或模型的STL类型等<sup>[27]</sup>,并融合知识蒸馏<sup>[28]</sup>,以减少模型参数,提升模型在小样本场景下的性能。

在小样本场景中,物理知识引导方法对小样本数据适应性差,参数选择复杂;数据驱动方法缺乏可解释性,且依赖大量标记数据;PINN和STL虽在小样本场景中展现出潜力,但在处理空间差异性和分布差异性方面仍需改进。针对上述问题,本文提出物理知识引导下覆冰迭代自迁移(physics knowledge guided iterative self-transfer learning, PKG-ISTL)模型,通过融合物理机理与数据驱动方法,在提升预测精度的同时增强模型可解释性,并利用STL技术解决小样本场景中的分布差异性问题,为覆冰预测提供了一种新的解决方案。

## 1 研究框架

本文提出的PKG-ISTL模型的研究框架如图1所示。在三维张量构建部分,覆冰数据集划分为源域与目标域。构建三维张量 $\mathbf{X}$ ,如式(1)所示。

$$\mathbf{X} \in \mathbf{R}^{N \times M \times K} \quad (1)$$

式中: $\mathbf{X}$ 为三维张量中数据; $N$ 为空间维度,表示不同监测杆塔观测点; $M$ 为特征维度,表示每个数据点包含的特征; $K$ 为时间维度,表示每个时间点上的覆冰厚度。采用滑动窗口法,后移时间步,用新数据进行预测。

在模型框架搭建部分,首先,在源域分支,输入三维张量,并利用PINN进行训练, PINN结合物理规律和数据驱动方法,在损失函数中引入物理约束,训练物理知识引导的PINN专家模型。其次,在自迁移分支,使用MK-MMD来适配模型,以适应目标域特性。最后,在目标域分支,运用知识蒸馏,实现专家模型到受训模型的自迁移,并通过迭代优化受训模型。在算例仿真中,对PKG-ISTL模型进行显著性分析、收敛性分析、稳定性分析与适用性分析,验证其应对不同情况的能力。

## 2 物理信息神经网络

### 2.1 物理信息神经网络结构

PINN的基本结构包括神经网络部分及物理约束部分如图2所示。PINN结合了卷积层和密集层的优势,卷积层用于提取输入数据中的空间特征,

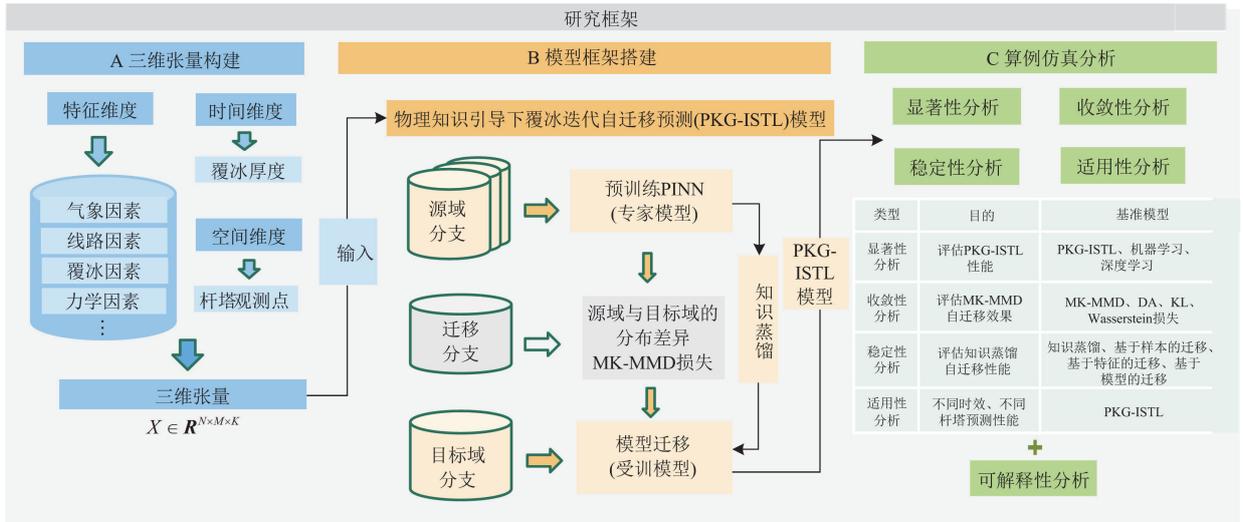


图 1 研究框架

Fig. 1 Research framework

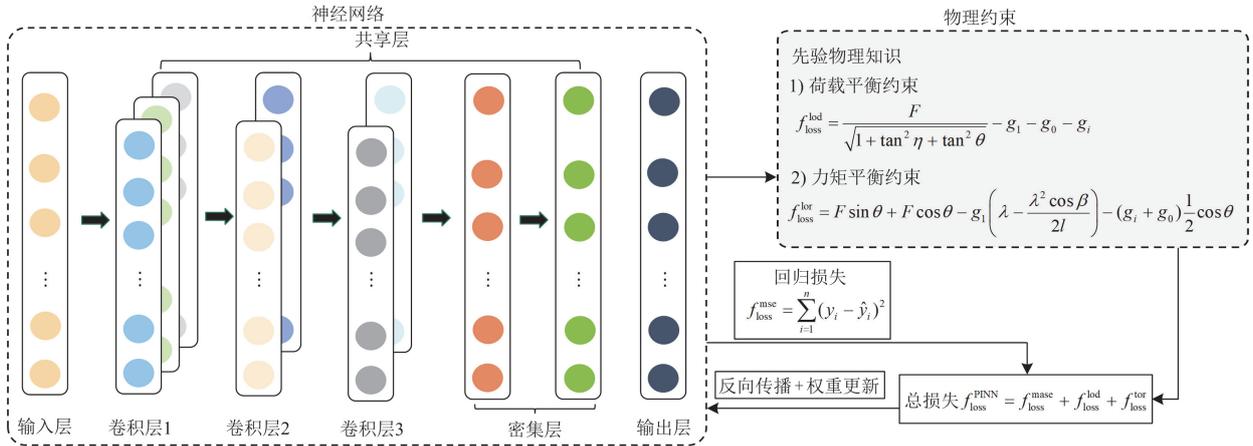


图 2 PINN 的基本结构

Fig. 2 Basic architecture of PINN

而密集层则进一步处理这些特征。

PINN 网络结构如表 1 所示<sup>[19]</sup>, 卷积层和池化层逐步提取和压缩特征, 密集层则负责特征的融合和输出。PINN 的卷积层部分采用了一系列卷积操作及最大池化操作<sup>[18]</sup>, 用于提取输入三维张量中的空间信息, 识别出不同监测点与时间点的特征模式。接着, 通过最大池化操作降低特征图的空间维度, 同时保留关键特征信息。在密集层部分, PINN 采用共享与特定任务两个分支。通过共享的全连接层, 将卷积层提取的空间特征映射到高维空间。接着, 在全连接层处生成预测结果<sup>[20]</sup>。

## 2.2 物理约束

综合利用拉力传感器与角度传感器的监测数据, 采用角度与力学参数结合的物理约束。PINN 物理约束损失  $f_{\text{loss}}^{\text{PINN}}$  包含两部分: 回归损失  $f_{\text{loss}}^{\text{mse}}$  及物

理损失  $f_{\text{loss}}^{\text{phy}}$ , 如式(2)一式(4)所示。

$$f_{\text{loss}}^{\text{PINN}} = f_{\text{loss}}^{\text{mse}} + f_{\text{loss}}^{\text{phy}} \quad (2)$$

$$f_{\text{loss}}^{\text{mse}} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

$$f_{\text{loss}}^{\text{phy}} = f_{\text{loss}}^{\text{lod}} + f_{\text{loss}}^{\text{tor}} \quad (4)$$

式中:  $n$  为观测样本总数;  $y_i$  为第  $i$  个观测点的真实值;  $\hat{y}_i$  为第  $i$  个观测点的模型预测值;  $f_{\text{loss}}^{\text{lod}}$  为载荷平衡约束;  $f_{\text{loss}}^{\text{tor}}$  为力矩平衡约束。

### 1) 载荷平衡约束 $f_{\text{loss}}^{\text{lod}}$

载荷平衡约束确保导线悬挂点水平力平衡性以及导线拉力与综合载荷之间的关系<sup>[29]</sup>。根据静力学平衡方程<sup>[30]</sup>, 载荷平衡约束推导如附录 A 式(A1)所示, 得到载荷平衡约束  $f_{\text{loss}}^{\text{lod}}$  如式(5)所示。

表 1 PINN 网络结构

Table 1 PINN network architecture

模型部分	层类型	参数	数据
卷积层	卷积层 1	输入通道数	1
		输出通道数	16
		卷积核大小	3
	最大池化层 1	池化核大小	2
	卷积层 2	输入通道数	16
		输出通道数	32
		卷积核大小	3
	最大池化层 2	池化核大小	2
	卷积层 3	输入通道数	32
输出通道数		64	
卷积核大小		3	
最大池化层 3	池化核大小	3	
密集层	密集层 1	输入大小	64
		输出大小	32
	密集层 2	输入大小	32
		输出大小	1

$$f_{\text{loss}}^{\text{lod}} = \frac{F}{\sqrt{1 + (\tan \eta)^2 + (\tan \theta)^2}} - g_1 - g_0 - \frac{\rho g \pi [(2b + d)^2 - d^2]}{4} \quad (5)$$

式中： $F$  为拉力； $\eta$  为绝缘子串风偏角； $\theta$  为绝缘子串偏角； $g_1$  为绝缘子串与金具自重，为已知量； $g_0$  为主杆塔所承受的导线自重，为已知量； $\rho$  为覆冰密度； $g$  为重力加速度常数； $b$  为覆冰厚度； $d$  为导线直径。

### 2) 力矩平衡约束 $f_{\text{loss}}^{\text{tor}}$

力矩平衡约束描述导线悬挂点的水平力与绝缘子串拉力、综合载荷、档距与其他参数之间的关系<sup>[31]</sup>。对悬挂点 A 取力矩，给定导线悬挂点水平力矩平衡条件<sup>[30]</sup>，推导如附录 A 式(A2)所示，最终得到线路力矩平衡约束  $f_{\text{loss}}^{\text{tor}}$  如式(6)所示。

$$f_{\text{loss}}^{\text{tor}} = F \sin \theta - \frac{l(g_1 + g_0)}{2 \cos \theta} - g_i \left( \lambda - \frac{\lambda^2 \cos \beta}{2l} \right) - F \cos \theta \quad (6)$$

式中： $l$  为线路档距； $g_i$  为第  $i$  个观测点承受的线路冰载荷， $i > 1$ ； $\lambda$  为耐张绝缘子串长度； $\beta$  为高差角，即导线两端悬挂点之间由高度差引起的倾斜角度。

## 2.3 训练步骤

针对覆冰预测问题，PINN 训练步骤如下所述。

1) 构建三维张量：将空间维度、特征维度与时间维度整合，保留时间及空间的关联性。利用时间窗口，采用滑动窗口预测未来时刻各个监测杆塔观测点的覆冰情况，实现覆冰厚度按时间序列输出。

2) 构建物理约束部分：考虑到覆冰预测的特殊

性，综合考虑回归损失及物理损失，确保构建 PINN 符合覆冰物理知识。

3) 反向权重调整：在训练过程中，通过最小化损失函数来进行反向传播与权重更新，得到预训练的 PINN 专家模型。

## 3 物理知识引导下覆冰迭代自迁移模型

### 3.1 物理知识引导下覆冰迭代自迁移框架

如图 1 所示，PKG-ISTL 框架采用知识蒸馏机制，属于模型压缩方法<sup>[28]</sup>，其核心思想是在源域上训练一个复杂且性能优异的专家模型，并将该模型的知识迁移到一个轻量化、计算成本更低的受训模型中。下面将对 PKG-ISTL 模型进行详细解释。

#### 1) 源域分支

源域分支是 PKG-ISTL 模型的上层分支，专注于源域数据的处理与训练专家模型。在源域分支中，根据输入的三维张量，在大规模数据集上训练 PINN 专家模型，经过多层卷积层与密集层处理，适应源域数据的特征表示需求。

#### 2) 自迁移分支

自迁移分支是 PKG-ISTL 模型的中部分支，负责进行源域和目标域之间的域自适应处理。网络的上层参数通过 MK-MMD 约束，减少源域与目标域之间的特征分布差异，增强两者的可比性。

MK-MMD 是对 MMD 的一种扩展形式，使用核映射算法，将特征嵌入高维再生核希尔伯特空间，并度量其分布距离<sup>[26]</sup>。

#### 3) 目标域分支

目标域分支位于 PKG-ISTL 模型的下层，用于处理目标域的数据。目标域分支经过相似的网络层处理，采用交叉熵的知识蒸馏损失  $f_{\text{loss}}^{\text{KD}}$ <sup>[26]</sup>，如式(7)所示，得到适应目标域的受训模型。

$$f_{\text{loss}}^{\text{KD}} = -T^2 \sum_c p_c \log_e(q_c) \quad (7)$$

式中： $T$  为温度参数； $c$  为类别总数； $p_c$  为专家模型的软化输出中第  $c$  类的概率； $q_c$  为受训模型的软化输出第  $c$  类的概率，控制着软化输出的平滑程度。交叉熵损失函数的值越小，表示预测结果越接近真实值。

综上所述，在 PKG-ISTL 框架中，STL 损失  $f_{\text{loss}}^{\text{STL}}$  包含了 3 个主要部分：PINN 物理约束损失  $f_{\text{loss}}^{\text{PINN}}$ 、源域与目标域之间的特征损失  $f_{\text{loss}}^{\text{MK-MMD}}$  以及知识蒸馏损失  $f_{\text{loss}}^{\text{KD}}$ ，如式(8)所示。

$$f_{\text{loss}}^{\text{STL}} = f_{\text{loss}}^{\text{PINN}} + f_{\text{loss}}^{\text{MK-MMD}} + f_{\text{loss}}^{\text{KD}} \quad (8)$$

### 3.2 模型训练

在覆冰预测中, 源域与目标域的数据分布可能存在差异, 将源域训练模型直接应用于目标域可能会导致性能下降。因此, 迭代在源域与目标域上进行训练, 主要包括以下步骤。

#### 步骤 1: 源域训练

在模型构建中, PINN 神经网络以三维张量作为输入, 并引入物理约束以增强泛化能力。通过在源域上联合最小化回归损失与物理约束损失, 优化模型参数, 使网络同时满足数据拟合与物理规律, 从而获得专家模型。

#### 步骤 2: 域自适应

在域自适应阶段, 模型通过微调全连接层权重, 最小化源域与目标域间的特征分布差异, 采用 MK-MMD 损失函数实现跨域特征对齐。

#### 步骤 3: 目标域微调

在目标域微调阶段, 通过交叉熵的知识蒸馏损失函数, 构建适应目标域特征的受训模型。对比专家模型与受训模型的软化输出概率分布来计算损失, 设置不同的温度参数, 在平衡模型的精度及泛化性之间找到折中点。

#### 步骤 4: 迭代训练

重复执行步骤 2 与步骤 3, 微调模型参数与损失函数, 提高模型在目标域上的性能及稳定性, 获得最终的受训模型。

### 3.3 模型分析

#### 3.3.1 可解释性分析

可解释性分析 (shapley additive explanations, SHAP) 借鉴了博弈论中的 Shapley 值概念, 理解特征对预测结果的贡献<sup>[32]</sup>。每个特征视为一个玩家, 模型的预测输出为收益, SHAP 的目标是解释每个特征对模型预测的贡献。

$$\phi_j(f) = \sum_{S \subseteq N_{\setminus j}} \left( \frac{|S|! \cdot (|N| - |S| - 1)!}{|N|!} N_{\setminus j} \cdot [f(S \cup \{j\}) - f(S)] \right) \quad (9)$$

式中:  $\phi_j(f)$  为特征  $j$  的 SHAP 值;  $S$  为不包含特征  $j$  的所有特征子集;  $N$  为特征的集合,  $S \subseteq N_{\setminus j}$ ,  $N_{\setminus j}$  为所有不包含特征  $i$  的子集  $S$  的集合, 即对所有满足  $S \subseteq N$  且  $j \notin S$  的子集进行遍历;  $|S|$  为集合  $S$  的元素个数;  $|N|$  为特征集合  $N$  的元素个数;  $f(S \cup \{j\})$  为模型在子集  $S$  加上特征  $j$  后的期望预测值;  $f(S)$  为模型对于特征组合  $S$  的输出。

#### 3.3.2 评价指标

常用的误差评估指标有:  $P_e^{\text{MAE}}$  为平均绝对误

差, 表示预测值与真实值之间误差绝对值的平均值;  $P_e^{\text{MSE}}$  为均方误差, 表示误差平方的平均值;  $P_e^{\text{R}^2}$  为决定系数, 表示模型拟合优度, 反映预测结果对真实数据的解释能力<sup>[15]</sup>。  $P_e^{\text{MAE}}$ 、 $P_e^{\text{MSE}}$ 、 $P_e^{\text{R}^2}$  的计算公式分别如式(10)一式(12)所示。

$$P_e^{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

$$P_e^{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

$$P_e^{\text{R}^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (12)$$

式中:  $\bar{y}_i$  为真实数据均值。

## 4 算例仿真

选取广西省某区段输电线路在 2021—2022 年间的覆冰监测数据, 将样本划分为源域与目标域, 各变量构成如图 3 所示。覆冰数据集存在高度不平衡的情况, 其中零值样本 785 420 个, 占总样本的 96%, 非零样本 29 025 个, 占比 4%。柳州局数据集为源域, 局部区域易受到寒潮影响, 该区域覆冰厚度的变化幅度较大, 进行初始预训练。而梧州局数据集作为目标域, 受到潮湿和湿气的影响, 其覆冰特性与柳州局相比有所不同, 完成 STL 过程以及性能评估。柳州局数据结合如表 2 所示固定线路参数,

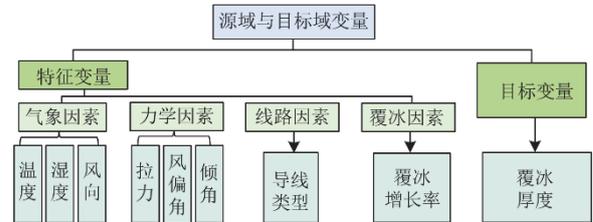


图 3 源域与目标域变量

Fig. 3 Source and target domain variables

表 2 柳州局的线路参数

Table 2 Line parameters of Liuzhou Bureau

线路参数	数值
电压等级/kV	500
档距 /m	53.56
高差 h/m	2.50
高差角 $\beta$ (°)	1.40
绝缘子串单位长度自重 $g_i$ /(kg/m)	25.00
导线单位长度自重 $g_w$ /(kg/m)	20.00
导线直径 d/mm	15.00
覆冰密度 $\rho$ /(g/cm)	0.90

进行模型训练。算例在 TensorFlow-GPU 平台下，基于 Keras 2.4.3 实现模型训练。

#### 4.1 算例设置

算例依据表 3 所示的实验设置，涵盖以下 5 个方面：1) 显著性分析，对比了数据模型驱动中机器学习、深度学习与 PINN 等在本文提出模型下自迁移前后效果；2) 收敛性分析，探讨 MK-MMD 损失函数的迭代收敛；3) 稳定性分析，评估知识蒸馏与不同 STL 类型的稳定性；4) 适用性分析，研究 PKG-ISTL 在不同杆塔不同时间尺度的预测效果；5) 采用 SHAP 解释特征对模型的贡献，量化特征的影响程度。模型超参数如表 4 所示。

表 3 实验设置

Table 3 Experimental setup

分析类型	时间尺度/h	目的	源域	目标域	基准模型
显著性	2	评估 PKG-ISTL 性能	柳州局	梧州局 103#	PKG-ISTL; 机器学习: DT、GBR、RF、AdaBoost、MLP; 深度学习: LSTM、GRU、Bi-RNN、CNN、Bi-LSTM
收敛性	2	评估 MK-MMD 自迁移效果	柳州局	梧州局 103#	MK-MMD、DA、KL、Wasserstein 损失
稳定性	2	评估知识蒸馏自迁移性能	柳州局	梧州局 103#	知识蒸馏、基于样本的迁移、基于特征的迁移、基于模型的迁移
适用性	2,3,8, 15,18	不同时效不同杆塔	柳州局	梧州局 108#、110#、118#	PKG-ISTL

表 4 超参数设置

Table 4 Hyperparameter settings

算法	最优参数
DT	最大深度为 5，最小分裂样本数为 2
GBR	学习率为 0.1，树数量为 100，最大深度为 3
RF	树数量为 100，最大深度为 5，最小分裂样本数为 2
AdaBoost	基学习器：决策树回归(最大深度为 3)，估计器数量为 50
MLP	隐藏层结构为(100,50)，初始学习率为 0.001
LSTM/GRU	
Bi-LSTM/ Bi-RNN	层数为 2，每层神经元个数为 50，激活函数为 ReLU
CNN	滤波器数量为 64，滤波器大小为 2，池化窗口大小为 2，全连接层神经元个数为 50，激活函数为 ReLU

#### 4.2 数据准备

在数据准备中，选择地理位置不同的区域作为实验数据。受自然因素的干扰，原始数据集包含异

常点。根据如附录 B 图 B1 所示的数据预处理环节，包括数据清洗、转换与平衡等步骤，处理后的数据在 0~1 内均有分布，确保数据具有代表性。

以梧州局 351#杆塔数据为例，经处理后获得 883 条样本，其中零值样本 709 条，数据稀疏性对小样本场景下的模型性能构成挑战。为有效刻画覆冰过程的复杂特性，采用三维张量构建方法，将多源异构数据进行结构化表征。在每个时间窗口内，基于目标杆塔的实时监测信息，提取气象、力学、线路及覆冰相关特征，构建包含时间、特征与空间维度的三维输入张量，用于预测该杆塔未来某一时刻的覆冰厚度。

#### 4.3 算例分析

将构建的三维张量作为输入，输入到本文构建的 PKG-ISTL 框架中，进行 3.2 节所示的模型训练，得到相应覆冰厚度输出，并进行以下算例分析。

##### 4.3.1 显著性分析

在显著性分析中，比较数据模型驱动中，机器学习与深度学习模型与 PINN 在覆冰预测中的表现，使用本文提出的模型自迁移前后的  $P_e^{MAE}$ 、 $P_e^{MSE}$ 、 $P_e^{R^2}$  评价指标值如表 5 所示。 $P_e^{R^2}$  越高表示拟合度越好，而  $P_e^{MSE}$  与  $P_e^{MAE}$  越低表示预测精度越高。结果显示，本文提出的 PKG-ISTL 框架在引入自迁移学习后，整体性能显著优于传统数据驱动模型(如 DT、GBR、RF、AdaBoost 和 MLP)和深度学习模型(如 LSTM、GRU、Bi-RNN、CNN 和 Bi-LSTM)。部分模型(如 LR)在迁移后性能有所提升， $P_e^{R^2}$  从 0.25 提高至 0.59。但相比之下，PKG-ISTL 模型在相同条件下， $P_e^{MAE}$  和  $P_e^{MSE}$  分别达到 0.17 和 0.12，表现出更强的泛化能力与稳定性。

相比之下，PINN 在迁移学习后  $P_e^{R^2}$  从 0.65 提升至 0.96，提升了 47.7%，不仅增幅可观，且达到了较高的预测精度，表明其在融合物理机理与数据驱动方面的强大建模能力。传统机器学习模型和深度学习模型，虽在一定程度上受益于迁移学习，但在小样本条件下普遍存在过拟合、泛化能力弱及对数据分布不敏感等问题，限制了其应用潜力。

##### 4.3.2 收敛性分析

为评估不同损失函数在域自适应中的收敛特性，本文定义 4 种域对齐损失：MK-MMD、域自适应(domain adaptation, DA)、Kullback-Leibler 散度(KL)与 Wasserstein 距离<sup>[32-33]</sup>，其迭代过程如图 4(a)所示。结果表明，MK-MMD 能更高效地对齐源域与目标域的特征分布，在保持源域有效知识迁移的同时，显著增强对目标域数据结构的建模能力。相较其他

表 5 数据模型驱动与 PINN 对比

Table 5 Comparison between data-driven models and PINN

模型	迁移学习之前			迁移学习之后		
	$P_e^{MAE}$	$P_e^{MSE}$	$P_e^{R^2}$	$P_e^{MAE}$	$P_e^{MSE}$	$P_e^{R^2}$
LR	5.29	2.85	0.25	2.69	12.14	0.59
DT	3.37	30.34	0.56	0.62	0.5	0.87
GBR	3.69	23.96	0.43	0.28	0.42	0.84
RF	2.73	21.99	0.61	0.92	0.61	0.93
AdaBoost	4.36	25.47	0.41	0.78	0.99	0.83
MLP	3.01	11.28	0.32	2.05	8.64	0.71
LSTM	2.43	9.63	0.44	2.38	9.96	0.67
GRU	3.06	21.07	0.23	1.25	6.72	0.39
Bi-RNN	3.69	5.04	0.48	2.57	4.91	0.74
CNN	3.7	15.07	0.43	1.09	8.85	0.61
Bi-LSTM	3.32	17.33	0.56	4.11	7.83	0.89
PINN	2.56	6.01	0.65	0.17	0.12	0.96

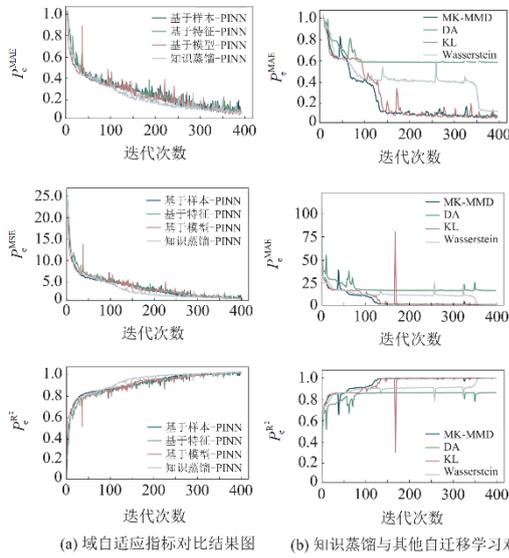


图 4 算例分析

Fig. 4 Case analysis

方法, MK-MMD 在收敛速度、适应能力均表现最优, 表现出更强的稳定性与泛化优势。

### 4.3.3 稳定性分析

为了更客观地测试知识蒸馏的稳定性, 与其他自迁移学习方法进行对比, 迭代过程如图 4(b)所示。

自迁移学习类型可以归纳为以下 3 类, 如表 6 所示。1) 基于样本的迁移中, 迁移自适应增强 (transfer adaboost, Tradaboost)通过迭代, 调整源域与目标域样本的权重<sup>[27]</sup>; 2) 基于特征的迁移中, 边缘分布自适应方法(transfer component analysis, TCA)在共享特征空间中, 对齐源域与目标域分布<sup>[27]</sup>; 3) 基于模型的迁移中, 微调参数在目标域数据上微调预训练模型参数等<sup>[27]</sup>。综合比较表明, 知识蒸馏在迭代过程中收敛更快, 性能波动小; 而其他方法因对参数初始化敏感, 易出现收敛振荡现象。

表 6 常用自迁移学习类型

Table 6 Common transfer learning types

类型	方法	思路	原理
基于样本	Tradaboost-PINN	加权自迁移	在源域构建分类器, 特征转换与加权提升性能
基于特征	TCA-PINN	特征空间自迁移	将源域与目标域数据映射到共享特征空间
基于模型	微调参数-PINN	微调自迁移	在源域上预训练模型, 在目标域上进行微调

### 4.3.4 适用性分析

在适用性分析中, 使用 PKG-ISTL 模型对不同杆塔不同时间尺度下的数据进行分析, 结果如表 7

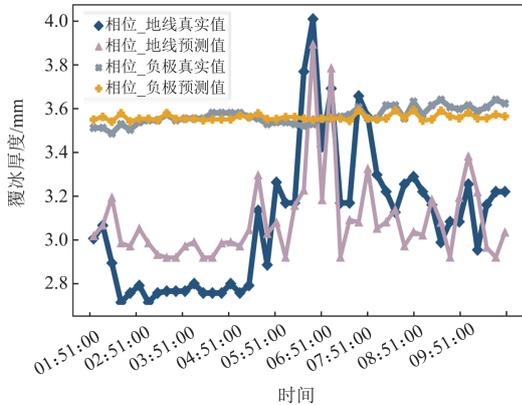
表 7 不同杆塔不同时间尺度下数据分析结果

Table 7 Data analysis results for different towers at various time intervals

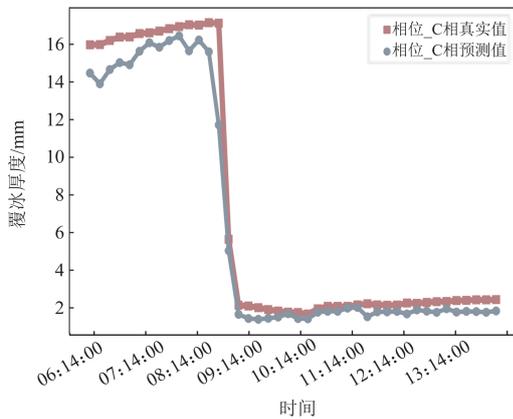
杆塔	时间尺度/h	评价指标		
		$P_e^{MAE}$	$P_e^{MSE}$	$P_e^{R^2}$
108#	2	0.44	0.28	0.98
	3	0.18	0.04	0.99
	8	0.04	0	0.98
	15	0.05	0.01	0.92
	18	0.05	0.02	0.95
110#	2	1.56	8.41	0.83
	3	2.34	15.04	0.74
	8	2.91	20.41	0.69
	15	3.54	23.44	0.49
	18	3.47	24.63	0.21
118#	2	0.74	0.69	0.94
	3	0.83	1.24	0.59
	8	0.99	1.72	0.56
	15	1.34	3.01	0.33
	18	1.98	5.73	0.1
103#	2	0.24	0.08	0.95
	3	0.27	0.17	0.89
	8	0.61	0.48	0.73
	15	0.54	0.57	0.59
	18	0.67	0.85	0.58

所示。以 110#杆塔为例，在较短时间尺度，比如 2 h 可准确地预测覆冰变化趋势。然而，随着时间尺度增加，模型预测性能逐渐下降。在较长时间尺度，如 18 h 时间尺度， $P_e^{R^2}$  值降至 0.21。

图 5 为典型杆塔真实值与预测值对比图，验证了 PKG-ISTL 模型在不同导线类型下有效性。此外，不同杆塔之间在相同时间尺度下的评价指标存在差异，这可能是由于杆塔位置、环境条件等因素导致数据差异。由表 7 可见，108#杆塔预测精度最高，与预测覆冰序列高度吻合，表明该工况下数据稳定性强、时序特征清晰。综上所述，PKG-ISTL 在多杆塔与多时间尺度场景下表现出较好的适用性，但当预测时长超过 8 h 后，精度明显下降，时序建模能力仍需改进。



(a) 103#预测对比图



(b) 118#预测对比图

图 5 典型杆塔真实与预测值对比图

Fig. 5 Comparison of actual and predicted values for typical transmission towers

#### 4.3.5 可解释性分析

可解释性分析通过对气象因素、力学因素、线路因素与覆冰因素等特征进行 SHAP 值分析，量化

它们对线路的影响，如图 6 所示。

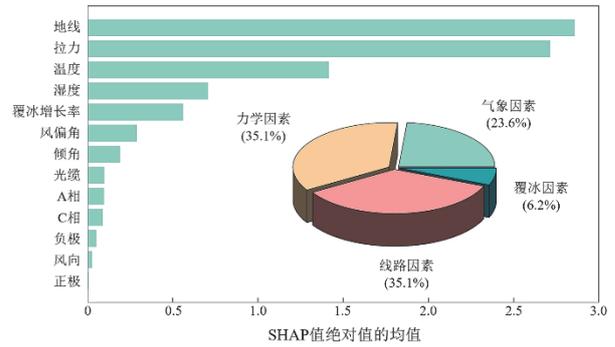


图 6 特征变量 SHAP 排序

Fig. 6 Ranking of feature variable SHAP

气象因素在影响输电线路覆冰行为中占据主导地位，其 SHAP 均值达 23.6%，其中温度与湿度贡献突出。力学因素占比 35.1%，其中拉力表现出较强的敏感性，SHAP 值显著高于其他力学变量。线路因素占比 35.1%，在不同杆塔间差异明显，尤其以导线类型对电场分布与覆冰积累的影响最为显著。覆冰增长率作为覆冰因素中的核心变量，SHAP 值较高，反映了在持续低温、高湿条件下的累积效应。综合来看，温度与湿度作用具有瞬时性，而拉力与导线类型之间的协同作用在长期覆冰过程中持续显著，体现了结构与环境耦合作用在覆冰演化中的驱动作用。

## 5 结论

本文提出了 PKG-ISTL 模型，有效提升覆冰精度与适用性，具体结论如下所述。

1) PINN 模型的性能显著优于数据模型驱动。通过融合 PINN 与 STL，使用 MK-MMD 损失函数，运用知识蒸馏进行迭代训练，构建出 PKG-ISTL 模型，实现预测精度显著提升，达到 47.69%。

2) 经过算例分析，验证 PKG-ISTL 模型优越性，解决源域与目标域数据分布不一致问题，在收敛性、稳定性、适用性上表现良好，在多种情景下展现快速的收敛速度，突出了模型对数据波动的稳定性，性能优势得到了证明。

3) 通过可解释性分析对气象因素、力学因素、线路因素与覆冰因素等特征进行 SHAP 值分析，量化其对线路影响。其中，不同区域环境条件及线路配置差异，对输电线路产生不同程度影响。

尽管热学因素对覆冰过程有一定影响，但由于数据限制，本研究暂未纳入热学约束。未来可通过引入热学约束等提高复杂气象条件下的覆冰预测精

度。此外, 可以将 PKG-ISTL 模型与电力系统应急响应机制相结合, 利用 IEEE 标准算例进行多层次、多场景的测试与验证。加入更多时序特征, 融合时序预测模型, 并加强物理建模, 有望进一步提升模型长期预测精度。

## 附录 A

荷载平衡约束推导如式(A1)所示。

$$\begin{cases} F_v = g_1 + g_0 + g_i \\ g_i = \frac{\rho g \pi [(2b + d)^2 - d^2]}{4} \\ \cos \theta' = \frac{1}{\sqrt{1 + (\tan \eta)^2 + (\tan \theta)^2}} \\ F_v = F \cos \theta' = \frac{F}{\sqrt{1 + (\tan \eta)^2 + (\tan \theta)^2}} \end{cases} \quad (A1)$$

式中:  $F_v$  为绝缘子串轴向拉力  $F$  在垂直方向的分量;  $\theta'$  为绝缘子串与垂直方向的夹角。

力矩平衡约束如式(A2)所示。

$$\begin{cases} V_a = F \sin \theta \\ H_a = F \cos \theta \\ V_a l + H_a h - \frac{lg_1}{\cos \beta} \frac{l}{2} - \lambda g_1 (l - \frac{\lambda_a \cos \beta}{2}) = 0 \\ V_a = \frac{lg_2}{2 \cos \beta} + g_1 (\lambda - \frac{\lambda^2 \cos \beta}{2l}) - \frac{h}{l} H_a F_a \end{cases} \quad (A2)$$

式中:  $V_a$  为  $F$  垂直方向的分力;  $H_a$  为  $F$  的水平分量;  $h$  为悬挂点的高差。

## 附录 B

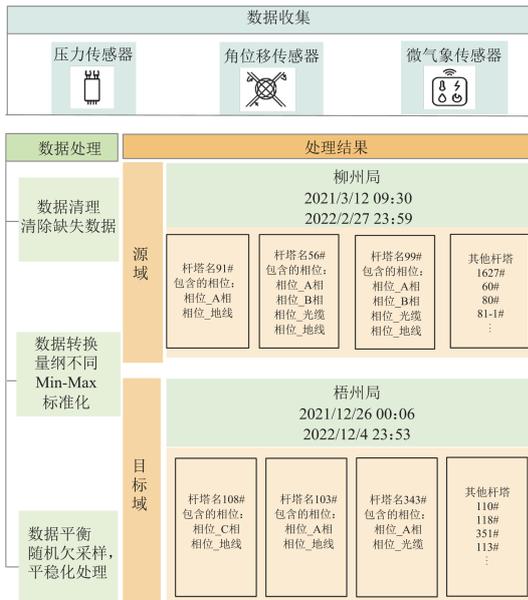


图 B1 数据预处理过程

Fig. B1 Data preprocessing

## 参考文献

- [1] 许守东, 王建, 李铭益, 等. 极端气象灾害下考虑 MESS 主动调控的配电网故障恢复策略[J]. 电力系统保护与控制, 2024, 52(12): 45-57.  
XU Shoudong, WANG Jian, LI Mingyi, et al. Distribution network fault recovery strategy considering active control of an MESS in extreme weather[J]. Power System Protection and Control, 2024, 52(12): 45-57.
- [2] 文屹, 陈易飞, 毛先胤, 等. 500 kV 输电铁塔覆冰风险评估与加固措施[J]. 电力工程技术, 2023, 42(2): 250-257.  
WEN Yi, CHEN Yifei, MAO Xianyin, et al. Icing risk assessment and reinforcement measures of 500 kV transmission tower[J]. Electric Power Engineering Technology, 2023, 42(2): 250-257.
- [3] 杜涵, 汤赐, 罗敏, 等. 基于 NSGA-II 的高频融冰电源参数优化设计[J]. 电力科学与技术学报, 2024, 39(5): 36-45, 57.  
DU Han, TANG Ci, LUO Min, et al. Optimized design of high frequency ice melting power supply parameters based on NSGA-II[J]. Journal of Electric Power Science and Technology, 2024, 39(5): 36-45, 57.
- [4] 朱永灿, 舒新, 田毅, 等. 微地形区 OPGW 地线不均匀覆冰计算模型改进方法[J]. 中国电力, 2023, 56(3): 55-63.  
ZHU Yongcan, SHU Xin, TIAN Yi, et al. Research on the improvement method of OPGW ground uneven icing calculation model under micro-terrain[J]. Electric Power, 2023, 56(3): 55-63.
- [5] 国家电网有限公司: [聚焦民生 保障保供]国家电网全力奋战寒潮电力保供一线[EB/OL]. [2024-02-28]. <http://yssp.net.sasac.gov.cn/n2588025/n2588124/c30144430/content.html>  
State Grid Corporation of China: [Focusing on people's livelihoods, ensuring warmth and power supply] State Grid Corporation of China fully engages in the frontline battle of power supply during cold wave[EB/OL]. [2024-02-28]. <http://yssp.net.sasac.gov.cn/n2588025/n2588124/c30144430/content.html>
- [6] 葛延峰, 邱雨, 张云旭, 等. 计及多种灵活性资源的园区智能配电网灾时弹性提升策略[J]. 电力系统保护与控制, 2024, 52(17): 139-149.  
GE Yanfeng, QIU Yu, ZHANG Yunxu, et al. Disaster resilience enhancement strategy of an intelligent distribution

- network in parks considering a variety of flexibility resources[J]. *Power System Protection and Control*, 2024, 52(17): 139-149.
- [7] 曹璞璘, 黄美琴, 王云龙, 等. 交流线路避雷线融冰故障电磁暂态分析与间接式行波故障定位方法[J]. *电力系统保护与控制*, 2023, 51(10): 11-21.
- CAO Pulin, HUANG Meiqin, WANG Yunlong, et al. Electromagnetic transients analysis and indirect traveling wave fault location for ground wires of AC transmission line amid de-icing[J]. *Power System Protection and Control*, 2023, 51(10): 11-21.
- [8] HU Z, HE T, ZENG Y, et al. Fast image recognition of transmission tower based on big data[J]. *Protection and Control of Modern Power Systems*, 2018, 3(2): 1-10.
- [9] HUANG B, WANG J. Applications of physics-informed neural networks in power systems—a review[J]. *IEEE Transactions on Power Systems*, 2022, 38(1): 572-588.
- [10] 黄力, 宋爽, 刘闯, 等. 基于 IHHO-HKELM 输电线路覆冰预测模型[J]. *电力科学与技术学报*, 2024, 39(4): 33-41.
- HUANG Li, SONG Shuang, LIU Chuang, et al. Icing prediction model of transmission line based on IHHO-HKELM[J]. *Journal of Electric Power Science and Technology*, 2024, 39(4): 33-41.
- [11] GOODWIN E J, et al. Predicting ice and snow loads for transmission lines[C] // *Predicting Ice & Snow Loads for Transmission Line Design*, 1983: 267-273.
- [12] MAKKONEN L. Modeling power line icing in freezing precipitation[J]. *Atmospheric Research*, 1998, 46(1): 131-142.
- [13] WANG Y, HOU H, BAI X, et al. Review on icing growth model for overhead transmission lines[C] // *2023 3rd Power System and Green Energy Conference (PSGEC)*, August 24-26, 2023, Shanghai, China.
- [14] LI Z, WU G, HUANG G, et al. Study on icing prediction for high-speed railway catenary oriented to numerical model and deep learning[J]. *IEEE Transactions on Transportation Electrification*, 2025, 11(1): 1189-1200.
- [15] TAO C, TAO T, HE S, et al. Wind turbine blade icing diagnosis using B-SMOTE-Bi-GRU and RFE combined with icing mechanism[J]. *Renewable Energy*, 2024, 221.
- [16] YAN X, JI X, MENG Q, et al. A hybrid prediction model of improved bidirectional long short-term memory network for cooling load based on PCANet and attention mechanism[J]. *Energy*, 2024, 292.
- [17] CUOMO S, DI COLA V S, GIAMPAOLO F, et al. Scientific machine learning through physics-informed neural networks: where we are and what's next[J]. *Journal of Scientific Computing*, 2022, 92(3).
- [18] FANG Z. A high-efficient hybrid physics-informed neural networks based on convolutional neural network[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(10): 5514-5526.
- [19] SOIBAM J, ASLANIDOU I, KYPRIANIDIS K, et al. Inverse flow prediction using ensemble PINNs and uncertainty quantification[J]. *International Journal of Heat and Mass Transfer*, 2024, 226.
- [20] ZHANG X, GONG J, XUAN F. A physics-informed neural network for creep-fatigue life prediction of components at elevated temperatures[J]. *Engineering Fracture Mechanics*, 2021, 258.
- [21] LI D, ZHAO Y, ZHAO Y. A dynamic-model-based fault diagnosis method for a wind turbine planetary gearbox using a deep learning network[J]. *Protection and Control of Modern Power Systems*, 2022, 7(2): 1-14.
- [22] JEONG I, CHO H, SON C, et al. Sustainable data-driven framework via transfer learning for icing-detection of high aspect ratio blades[J]. *Cold Regions Science and Technology*, 2022, 201.
- [23] JIA L, LIU J, CHONG A, et al. Deep learning and physics-based modeling for the optimization of ice-based thermal energy systems in cooling plants[J]. *Applied Energy*, 2022, 322.
- [24] MAO W, ZHANG W, FENG K, et al. Tensor representation-based transferability analytics and selective transfer learning of prognostic knowledge for remaining useful life prediction across machines[J]. *Reliability Engineering & System Safety*, 2024, 242.
- [25] 吴艳梅, 陈红坤, 陈磊, 等. 基于改进 MMD-GAN 的可再生能源随机场景生成[J]. *电力系统保护与控制*, 2024, 52(19): 85-96.
- WU Yanmei, CHEN Hongkun, CHEN Lei, et al. Stochastic scenario generation for renewable energy based on improved MMD-GAN[J]. *Power System Protection and Control*, 2024, 52(19): 85-96.
- [26] ZHAO W, ZENG T, LIU Z, et al. Automatic generation control in a distributed power grid based on multi-step reinforcement learning[J]. *Protection and Control of*

- Modern Power Systems, 2024, 9(4): 39-50.
- [27] ZHANG H, SUN H, KANG L, et al. Prediction of health level of multiform lithium sulfur batteries based on incremental capacity analysis and an improved LSTM[J]. Protection and Control of Modern Power Systems, 2024, 9(2): 21-31.
- [28] ANNARNRAJU A, NANDIRAJU S. Robust frequency control in a renewable penetrated power system: an adaptive updates fractional order-fuzzy approach[J]. Protection and Control of Modern Power Systems, 2019, 4(3): 1-15.
- [29] 蒋兴良, 韩兴波, 胡玉耀, 等. 绝缘子湿增长动态覆冰模型研究[J]. 中国电机工程学报, 2018, 38(8): 2496-2503.
- JIANG Xingliang, HAN Xingbo, HU Yuyao, et al. The study of dynamic wet-growth icing model of insulator[J]. Proceedings of the CSEE, 2018, 38(8): 2496-2503.
- [30] 于童, 李英娜. 物理引导的 SSA-BiGRU 输电线路覆冰厚度预测模型[J]. 电力科学与工程, 2022, 38(2): 28-36.
- YU Tong, LI Yingna. Physical-guided SSA-BiGRU prediction model of ice thickness on transmission lines[J]. Electric Power Science and Engineering, 2022, 38(2): 28-36.
- [31] 蒋兴良, 吴建国, 邓颖, 等. 垭口微地形下档内线路不均匀覆冰研究[J]. 中国电机工程学报, 2024, 44(6): 2462-2475.
- JIANG Xingliang, WU Jianguo, DENG Ying, et al. Research on uneven icing of lines in adjacent towers under pass micro-topography[J]. Proceedings of the CSEE, 2024, 44(6): 2462-2475.
- [32] 刘永光, 谭赣江, 刘型志, 等. 基于域自适应的二屏电能表显示屏质量检测方法[J]. 电力系统保护与控制, 2022, 50(23): 180-186.
- LIU Yongguang, TAN Ganjiang, LIU Xingzhi, et al. Display quality detection method for a two-screen watt-hour meter based on domain adaptation[J]. Power System Protection and Control, 2022, 50(23): 180-186.
- [33] LIU L, HU X, CHEN J, et al. Embedded scenario clustering for wind and photovoltaic power, and load based on multi-head self-attention[J]. Protection and Control of Modern Power Systems, 2024, 9(1): 122-132.

收稿日期: 2024-12-17; 修回日期: 2025-03-24

作者简介:

王振国(1989—), 男, 博士, 高级工程师, 研究方向为电网防灾减灾; E-mail: wangzhenguo1229@163.com

王燕(2001—), 女, 通信作者, 硕士研究生, 研究方向为电力系统风险评估。E-mail: 302867@whut.edu.com

(编辑 张颖)