



基于混合DNN的牵引系统温度场预测技术研究

宗振龙^{1,2}, 刘冠芳^{1,2}, 杨柳青^{1,2}, 庞 聪^{1,2}

(1. 中车永济电机有限公司, 山西 永济 044502;

2. 轨道交通牵引电机山西省重点实验室, 山西 永济 044502)

摘 要: 牵引系统各部件温度变化呈现非线性动态模式, 单一维度建模难以同步获取温度场的空间分布规律与长时依赖关系。针对牵引系统温度场预测中的时空耦合建模技术难题, 文章提出一种基于混合深度神经网络(DNN)的温度场预测方法。通过构建牵引系统高保真、多工况的温度场仿真数据集, 结合重采样和标准化数据处理、参数化几何建模及多物理场耦合仿真技术, 生成高质量时空样本; 同时, 设计融合图注意力机制与时序模块的双分支网络架构, 在空间维度精准刻画部件间的热传导路径与分布规律, 在时间维度增强对非线性动态模式及关键突变特征的捕捉能力, 从而实现牵引系统温度场的准确预测。试验结果表明, 在5 min预测场景下的训练损失为0.003, 关键位置预测误差在 $\pm 0.5^{\circ}\text{C}$ 以内。

关键词: 牵引系统; 温度场; 傅里叶变换; 图神经网络; 堆叠GRU; ITA模块; 仿真

中图分类号: U264; TK123 **文献标志码:** A **文章编号:** 1000-128X(2026)01-0043-08

0 引言

牵引系统作为车辆实现牵引与制动、电能与动能转换的核心能量系统, 其运行可靠性备受关注^[1-2]。据统计, 牵引系统故障率占列车总故障的32.33%, 其中由热失效导致的故障占比最高。在长期高负荷运行下, 电机、变流器等高热部件持续产热, 导致系统温度不断上升^[3], 过大的温升变化会加速材料老化, 甚至引发绝缘击穿和器件损坏等故障, 直接威胁列车运行安全^[4]。为保障产品的可靠性, 通常在设计初期建立系统级仿真模型进行方案验证, 然而传统仿真计算周期较长, 难以满足快速设计和方案迭代需求。因此, 亟需探索高效精准的方法, 以替代或辅助传统仿真计算过程, 实现牵引系统内部温度场分布的准确预测, 对列车稳定运行、维护策略优化及设备寿命延长具有重要意义^[5-6]。

文献[7]基于电磁学和热力学的物理定律及简化假设, 建立了牵引电机温度场分析的数学模型, 通过迭代耦合确定稳定状态下的温度场分布。该方法需要精确的电磁参数和热力学边界条件, 但在实际工程中这些参数往往难以准确获取, 导致模型预测精度受限。文献[8]采用支持向量回归(SVR)预测器捕捉温度变化与各影响因素之间的关系, 利用鲸鱼优化算法确定最优预测器参数, 并结合集成学习策略提高温度场预测精度。然而, 该方法在表征复杂非线性关系和捕捉深层时空依赖方面的能力相对较弱, 尤其在处理高维强耦合数据时, 暴露出特征工程和模型容量的瓶颈。近年来, 深度学习技术凭借其强大的非线性拟合能力以及从复杂数据中自动提取特征的能力^[9], 有望克服传统方法在牵引系统温度场预测问题上的不足。文献[10]利用循环神经网络(RNN)处理车辆运行过程中各关键部位的历史温度数据与运行工况数据, 实现对未来时刻温度的预测。但该方法在处理超长数据序列时,

基金项目: 山西省科技重大专项计划“揭榜挂帅”项目(202401110101001)

通信作者: 宗振龙, 男, 硕士, 高级工程师, 中车技术专家, 中车仿真专家组成员, 主要从事电机仿真技术和测试技术研究工作;
E-mail: yjdjzong@163.com

引用格式: 宗振龙, 刘冠芳, 杨柳青, 等. 基于混合DNN的牵引系统温度场预测技术研究[J]. 机车电传动, 2026(1): 43-50. DOI:10.13890/j.issn.1000-128X.2026.01.006.

Citation: ZONG Zhenlong, LIU Guanfang, YANG Liuqing, et al. Research on temperature field prediction technology for traction systems based on hybrid DNN[J]. Electric drive for locomotives, 2026(1): 43-50. DOI:10.13890/j.issn.1000-128X.2026.01.006.

仍存在梯度消失问题, 导致模型难以全面捕捉长时间跨度下的温度变化趋势; 另外, 该方法在空间特征建模能力上存在不足, 难以充分理解和利用不同关键部位之间温度变化的相互影响和空间关联性, 可能导致对温度场整体空间分布演变规律的预测精度较低。

针对现有时空耦合预测模型构建和预测方法的局限性, 本文提出一种基于混合深度神经网络 (DNN) 的双分支牵引系统温度场预测模型。该模型融合了图注意力机制和时序模块的网络架构, 能够更全面、更精确地刻画牵引系统温度场随时间和空间变化的复杂动态规律, 从而提升预测模型的准确性与鲁棒性。

1 牵引系统温度场预测方法

1.1 牵引系统温度场仿真数据集的构建

列车牵引系统是机械部件与电气控制技术高度集成的复杂系统^[1], 拓扑结构如图 1 所示, 其关键在于各组件之间的协同运作, 以确保列车高效稳定运行。




图 1 列车牵引系统基本动力单元拓扑结构

Fig. 1 Topological structure of basic power unit in train traction system

为构建和验证预测模型, 本文结合高保真多物理场耦合仿真、线路实测及产品试验数据, 构建了牵引系统温度场仿真训练数据集。同时, 采用数据清洗、重采样等算法对数据集进行评估与分类, 进而建立参数化仿真模型库, 生成覆盖不同系统型号、不同工况组合的高质量时空数据, 为混合 DNN 预测模型的搭建提供训练与验证基础。

建立部件几何模型库, 通过结构特征参数 g 控制型号差异, 如式(1)。

$$\Omega_{\text{model}} = \mathcal{G}(g), g \sim u(g_{\min}, g_{\max}) \quad (1)$$

式中: $\mathcal{G}$ 为参数化 CAD 生成器; u 为均匀分布采样; $(g_{\min}, g_{\max})$ 为结构特征参数范围。

从每次成功的仿真计算中, 提取并结构化存储以

下核心数据, 构成数据集的一个样本。设单次仿真生成的第 i 个数据样本为 x_i , 由输入特征 D_i 和输出标签 y_i 共同构成, 如式(2)。

$$\left. \begin{aligned} x_i &= \{D_i, y_i\}, i = 1, 2, \dots, N_{\text{sample}} \\ D_i &= [g_i, M_i, u_{0,i}, S_i] \in \mathbb{R}^{4 \times T \times N_{\text{node}} \times d_{\text{feat}}} \end{aligned} \right\} \quad (2)$$

式中: g_i 为结构特征编码; M_i 为材料属性向量; $u_{0,i}$ 为初始激励, 包括环境温度 u_{temp} 、冷却液初温 u_{cool} 、初始损耗功率 u_{loss} ; S_i 为工况时序, 包括电流 S_I 、转矩 S_T 、冷却流量 S_{flow} 。

结合刻画牵引系统工作特征的运行工况数据, 获取牵引系统温度场每种工况下的数据集样本, 但原始数据可能存在采样频率不一致、数据量纲差异大的问题。为确保数据质量, 对上述数据进行重采样处理, 设定统一的采样频率, 使数据在时间维度上具有可比性。进一步通过标准化处理, 消除量纲影响, 计算公式为

$$\Delta x_i = (x_i - \mu) / \delta \quad (3)$$

式中: Δx_i 为标准化处理后的数据; x_i 为仿真生成的原始数据样本; μ 、 δ 分别为数据的均值与标准差。

1.2 混合深度神经网络模型构建

通过傅里叶变换和图注意力网络的联合建模, 将测点位置与频域特征结合, 有效解决空间相关性建模难题。同时, 采用堆叠门控循环单元 (gated recurrent unit, GRU) 和时序间注意力 (inter-temporal attention, ITA) 模块, 克服传统循环神经网络 (recurrent neural network, RNN) 的梯度消失问题, 并增强了对关键时间特征的捕捉能力。

1.2.1 模型架构

针对温度数据具备的时空特性, 构建双分支牵引系统温度场预测模型, 其架构如图 2 所示。




图 2 双分支牵引系统温度场预测模型架构

Fig. 2 Architecture of dual-branch temperature field prediction model

在空间分支中, 首先对采集的历史温度场数据序列进行傅里叶变换, 提取其频域特征; 然后, 将其与各热电偶的位置信息作为图节点构建图数据; 最后, 利用图注意力网络学习每个热电偶测点温度与其邻居节点温度之间的空间依赖关系, 从而有效提取温度场在空间上的分布特征。

在时间分支中, 以采集的温度场数据作为输入, 利用堆叠 GRU 模块学习历史温度场数据中的复杂时间

模式;同时引入注意力机制,使模型在预测每个时间步的温度时,能够自适应捕捉对温度预测任务最为关键的时间动态,完成时间特征的提取。随后,将两支提取的特征进行融合,并通过全连接层对融合后的特征进行映射,最终输出牵引系统温度场预测结果。

1.2.2 图数据生成

在牵引系统温度场数据集的图数据生成过程中,首先利用傅里叶变换将采集的温度场数据转换为用频域特征表示,以捕捉温度变化的本质规律与周期模式^[12]。将提取的频域特征作为图数据中节点的特征向量,可显著提升对温度场数据结构化信息的编码效率与表达能力。相较于直接使用原始温度场数据序列,基于频域特征的节点表示能够更稳定地刻画各测点温度的内在变化特性。以经过频域转换并融入空间关系的图数据作为空间分支网络的输入,有助于模型更好地理解牵引系统不同部件、不同位置之间的热关联性^[13]。基于上述思路,对每个测点温度序列进行傅里叶变换后,得到频域-几何结构双模态融合的图数据。

假设分布于牵引系统各部件不同位置上的测点总数量为 N ,牵引系统温度场数据集中 t 时刻下每个样本的数据序列表示为 $\Delta x_i(t), i=1,2,\dots,N, t=1,2,\dots,T$ 。利用式(4)对每个样本的数据序列 $\Delta x_i(t)$ 进行傅里叶变换,可得到其频域特征表示 $X_i(\omega)$ 。

$$X_i(\omega) = \sum_{t=1}^T \Delta x_i(t) e^{-j(2\pi/T)\omega t} \quad (4)$$

式中: ω 为频率参数; j 为虚数单位。

将每个测点的位置信息与其温度序列的频域特征相结合,构建图节点 v_i ,其公式描述如下:

$$v_i = [X_i(\omega_1), X_i(\omega_2), \dots, X_i(\omega_K), p_i]^T \quad (5)$$

式中: K 为所选频率分量的数量; p_i 为第 i 个测点的位置信息向量。

根据图节点之间的关系构建图数据 $G(V, E)$,其中 $V = \{v_1, v_2, \dots, v_N\}$ 为所有图节点构成的集合,节点之间连接边所在集合为 E ,每条边 $e_{ij} \in E$ 代表节点 v_i, v_j 之间的连接关系,可通过邻接矩阵 A 进行定义。牵引系统温度场数据集的图数据构建如下:

$$A_{ij} = \begin{cases} 1, v_i \text{与} v_j \text{存在邻居关系} \\ 0, \text{otherwise} \end{cases} \quad (6)$$

邻接矩阵 A 的具体构建依赖于牵引系统的物理拓扑与热传导路径。本研究基于部件间几何距离与热耦合强度进行定义:若两个测点 i 与 j 位于同一部件内部或通过导热部件直接相连,且其欧氏距离小于设定阈值 $d_{th}=0.5 \text{ mm}$,则 $A_{ij}=1$,否则 $A_{ij}=0$;对于电机定子等特殊部件间的热关系,则依据电磁-热耦合仿真结果构建虚拟连接边,从而确保图结构能够真实反映系统内潜在的热量传递路径。

按上述方法完成图数据计算后,可为牵引系统温

度场预测提供兼具空间语义和结构信息的特征表示。

1.2.3 图注意力网络

在图神经网络处理阶段,将融合几何拓扑与频域特征的图数据输入空间分支网络。采用几何信息神经算子中的图神经算子模块实现多尺度空间特征提取。该模块通过动态图注意力机制自适应计算节点间的热传导权重,并结合图卷积操作逐层聚合邻居节点信息,在保留原始温度场频域特征的同时,显式建模各部件间的几何热耦合关系。相较于传统图神经网络,本模块引入了可学习的几何距离衰减函数,强化了对复杂曲面温度梯度变化的建模能力,使节点特征矩阵的更新过程同时满足物理空间邻近性与热力学关联性双重约束^[14-15]。通过多层消息传递,最终得到的节点特征矩阵同时编码了局部测点的频域特性和全局结构的热传导模式,从而能精准刻画牵引系统温度场在空间维度上的分布特征与变化规律。经过图卷积计算,获取节点特征矩阵的公式如下:

$$F^{(l+1)} = \sigma \left(A^{-\frac{1}{2}} \hat{A} A^{-\frac{1}{2}} F^l W^l \right) \quad (7)$$

式中: F^l 为对应第 l 个图卷积层的节点特征矩阵; W^l 为对应第 l 个图卷积层的图神经网络; σ 为激活函数 Sigmoid; $\hat{A}=A+I$, I 为单位矩阵; A 为 $\hat{A}$ 对角节点的度矩阵; $A^{-\frac{1}{2}} \hat{A} A^{-\frac{1}{2}}$ 为对 A 的标准化处理,以此提高图卷积神经网络的训练效率。

通过引入空间注意力机制,增强模型对温度场预测任务中关键特征的关注度^[16-17]。 W^l 的计算公式为

$$W^l = \sigma \left(F_{l-1} \theta_1 \theta_2 (\theta_3 F_{l-1})^T + b' \right) \quad (8)$$

式中: F_{l-1} 为第 $l-1$ 个图卷积层处理后的特征图; $\theta_1, \theta_2, \theta_3$ 为待训练参数; b' 为偏置项。

1.2.4 GRU堆叠模块

在时间分支网络中,以采集的历史温度场数据序列作为输入,利用堆叠GRU模块捕捉数据在时间维度上的长期依赖关系。将频域-几何双模态融合特性引入GRU,使时间分支能够同时捕捉温度场的动态演变规律与空间几何约束。此外,将动态图注意力机制嵌入GRU,使时间分支可自适应调整各测点间的时间依赖权重。GRU的计算过程如下:

$$\left. \begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \\ r_t &= \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \\ h'_t &= \tanh(W \cdot [h_{t-1}, x_t] + b) \\ h_t &= (1 - z_t) * h_{t-1} + z_t * h'_t \end{aligned} \right\} \quad (9)$$

式中: W 为权重参数; W_z, W_r 分别为更新门和重置门的权重矩阵; x_t 为 t 时刻下输入至GRU的温度数据序列; r_t 为重置门的处理结果; z_t 为更新门的处理结果; h_t, h_{t-1} 分别为当前时间状态和上一时间状态的记忆单元状态向量; h'_t 为隐藏状态向量; b 为偏置参数; b_z, b_r

$$L_{\text{MSE}} = M^{-1} \sum_{i=1}^M (\hat{y}_i - y_i)^2 \quad (15)$$

式中: M 为训练样本总量; $\hat{y}_i$ 为第 i 个样本的预测温度; y_i 为实际温度。

利用Adam优化器的自适应调节特性, 引入指数衰减机制对学习率进行持续修正, 确保模型能够快速且稳定地达到收敛状态, 如式(16)。

$$g_1 = g_0 \cdot \gamma^\lambda \quad (16)$$

式中: g_0 为初始学习率; γ 为衰减率; λ 为迭代次数。

在构建基于混合DNN的牵引系统温度场预测模型时, 参数选择对模型性能和预测精度至关重要。具体参数设置如下: ①网络架构参数: 空间分支采用2层图注意力网络, 每层设置4个注意力头, 以在保持计算效率的同时充分捕捉空间维度上的热传导路径与分布规律。时间分支则采用3层GRU堆叠模块, 隐藏状态维度设为128, 以有效处理温度场数据中的时序特征并捕捉长时间依赖关系。ITA模块中的一维卷积核大小设为3, 以在保持较强特征提取能力的同时避免过拟合。②学习率与优化器参数: 初始学习率设为经验值0.001, 以取得良好的收敛效果。学习率衰减率设为0.9且衰减步长设为每1 000次迭代衰减一次, 使学习率随训练逐渐减小, 以助于模型在训练后期进行精细调整, 同时采用Adam优化器的默认参数, 以提供稳定的优化效果。③正则化与防止过拟合措施: 在GRU堆叠模块及全连接层中引入Dropout机制, 并将Dropout率设为0.5以降低过拟合风险。此外, 根据验证集性能设置早停机制, 当验证损失连续多个epoch不再下降时停止训练, 防止模型在训练集上过拟合。通过上述参数选择与优化措施, 保证了预测模型的准确性和鲁棒性。

2 试验验证

2.1 试验设置

选取某列车牵引系统作为试验对象, 在图4所示环境下采用热电偶监测其运行过程中的温度变化, 并通




图4 试验环境

Fig. 4 Experimental environment

过数据采集装置收集各部件温度数据及运行工况数据。试验数据集中包含19个测试点的温度数据和电机运行工况数据, 共9.8万条样本, 时间跨度为3个月。以最后5天的数据作为测试样本, 其余数据均为训练样本。

模型关键结构超参数设置如下: 空间分支的图注意力网络包含2层, 每层使用4个注意力头, 节点特征维度为64; 时间分支的堆叠GRU模块为3层结构, 隐藏状态维度设置为128; ITA模块中的一维卷积核 $k=3$, 以确保模型在保持较强特征提取能力的同时避免过拟合。

2.2 消融试验

为分析预测模型的准确性, 设计了5种消融方案进行对比试验。方案1为本文提出的双分支温度场预测模型; 方案4、方案5分别为采用单一分支的温度场预测模型; 方案2、方案3在方案4、方案5的基础上去掉注意力机制。在5 min、15 min、25 min 3种预测场景下, 对比5种消融方案的训练损失差异, 试验结果如图5所示。


试验表明, 随着训练进行, 各方案的损失曲线整体呈稳定下降趋势。在消融试验对比中, 方案2与方案3由于采用单分支网络架构且未集成注意力机制, 导致模型特征提取能力受限, 训练损失值较高(大于0.04); 方案4与方案5虽引入基础注意力模块, 有效增强了模型对关键特征的捕捉能力, 但受限于仅考虑空间或时间单一维度的特征建模方式, 模型收敛效果仍不理想, 训练损失维持在较高水平。

方案1通过构建时空双维度特征融合机制, 同步捕捉牵引系统温度场在空间分布与时间演化上的耦合特性, 使模型训练损失显著降低。在对未来5 min温度场的预测中, 训练损失值低至0.003量级。试验结果表明, 本文提出的预测模型损失值较其他模型降低一个数量级, 温度预测结果较为准确。


2.3 对比试验

为进一步验证本文方法的有效性, 选取文献[8]基于支持向量回归预测器的预测方法、文献[10]基于循环神经网络的预测方法作为对比方法, 与本文方法进行对比测试。采用均方误差(MSE)、平均绝对误差(MAE)及确定系数(R^2)作为评价指标, 进一步验证研究方法的实际应用性。其中, MSE作为评估预测模型逼近真实温度场的核心指标, 其数值越小反映模型稳定性越强; MAE则直观表征预测值与实测值的平均偏离程度, 数值越低意味着预测精度越高; R^2 作为模型拟合优度的关键度量, 其值越接近1表示模型对数据的解释能力越强。试验结果如表1所示。


表1的量化分析表明, 在3种预测场景下, 本文提



(a) 5 min 预测场景



(b) 15 min 预测场景



(c) 25 min 预测场景

图5 不同预测场景下5种消融方案训练损失对比分析

Fig. 5 Comparative analysis of training losses in five ablation schemes under different prediction scenarios

出的方法在MSE、MAE和 R^2 指标上均显著优于对比方法，充分验证了其在牵引系统温度场预测中的稳定性优势与精度提升。具体而言，在5 min短时预测场景下，本文方法的MSE低至1.342，MAE仅为0.761， R^2 达到0.965，相较于15 min与30 min的中长期预测场景，其误差指标降低约一个数量级。

表1 不同方法性能对比

Table 1 Performance comparison of different methods

方法	指标	5 min	15 min	25 min
文献[8]方法	MAE	1.427	1.852	2.751
	MSE	3.563	6.318	14.194
	R^2	0.952	0.928	0.904
文献[10]方法	MAE	1.158	1.732	2.445
	MSE	2.574	5.619	10.889
	R^2	0.957	0.932	0.808
本文研究方法	MAE	0.761	0.962	1.062
	MSE	1.342	1.701	2.066
	R^2	0.965	0.960	0.927

2.4 多监测点温度场预测对比

以测试样本作为预测模型的输入，在5 min预测场景下，温度场预测结果如表2所示。

表2 牵引系统温度场预测结果

Table 2 Results of temperature field prediction for traction

system		°C	
牵引系统 关键部件	温度监测点	预测温度	实际温度
牵引 变流器	冷却水管进口位置 (4个热电偶测量平均值)	50.1	49.7
	冷却水管出口位置 (4个热电偶测量平均值)	62.3	61.9
牵引电机	转子B段特定磁钢位置	120.5	121.0
	转子D段特定磁钢位置	119.8	120.3
	转子E段特定磁钢位置	121.2	121.7
	定子槽底	105.6	105.2
	定子轭部	108.1	107.7
	定子槽内绕组	115.4	114.9
	端部绕组 (3个热电偶测量平均值)	122.5	122.0

根据预测结果，各部件监测点处的温度预测值与实际值误差均低于0.5 °C，表明本文提出的预测模型具有较高的准确性，能够较好地捕捉到不同关键部件在5 min时间尺度上的温度变化趋势。

3 结论

针对牵引系统温度场预测的时空耦合建模难题，本文提出一种基于混合DNN的预测方法，通过构建高质量时空样本数据集，设计融合图注意力机制与时序模块的双分支网络架构，实现了温度场的高精度预测。结果表明，该方法在5 min预测场景下训练损失低至0.003，关键位置温度预测误差控制在±0.5 °C以内，为轨道交通、新能源汽车等领域牵引系统的智能运维与热管理优化提供了有效技术支撑。后续将结合更多实

际运行工况数据进一步优化模型, 并拓展多物理场耦合分析。

参考文献:

- [1] 张雨晨, 戴贤春, 刘敬辉, 等. 预测动车组牵引系统故障率的TSOBP-ARIMA-Prophet组合模型[J]. 中国铁道科学, 2024, 45(4): 147-157.
ZHANG Yuchen, DAI Xianchun, LIU Jinghui, et al. TSOBP-ARIMA-Prophet combined model for predicting the failure rate of EMU traction system[J]. China railway science, 2024, 45(4): 147-157.
- [2] 李群湛. 新型轨道交通工频AC 3 kV制式: 列车牵引系统与牵引供电系统[J]. 中国科学(技术科学), 2024, 54(1): 107-118.
LI Qunzhan. Novel rail transit power frequency AC 3 kV mode: a train traction system and traction power supply system[J]. Scientia sinica(technologica), 2024, 54(1): 107-118.
- [3] 郭蕾, 蔡丰林, 袁帅, 等. 动车组干式车载牵引变压器质量-热点温升均衡优化[J]. 交通运输工程学报, 2023, 23(5): 152-162.
GUO Lei, CAI Fenglin, YUAN Shuai, et al. Mass and hot spot temperature rise balance optimization of dry-type on-board traction transformers for EMUs[J]. Journal of traffic and transportation engineering, 2023, 23(5): 152-162.
- [4] 王成涛, 韦敬, 韩伟, 等. 高速铁路动车组网侧变流器的温升特性仿真[J]. 城市轨道交通研究, 2025, 28(2): 121-125.
WANG Chengtao, WEI Jing, HAN Wei, et al. Simulation of temperature rise characteristics of high-speed railway EMU grid-side converters[J]. Urban mass transit, 2025, 28(2): 121-125.
- [5] 王运明, 李明阳, 陈梦华, 等. 基于MultiCNN-GRU-ITA的动车组牵引电机温度预测模型[J]. 铁道科学与工程学报, 2025, 22(5): 2367-2379.
WANG Yunming, LI Mingyang, CHEN Menghua, et al. Temperature prediction model of traction motors in EMUs based on MultiCNN-GRU-ITA[J]. Journal of railway science and engineering, 2025, 22(5): 2367-2379.
- [6] 王韬, 张壮, 赵康发, 等. 强迫油循环风冷式牵引变压器的动态温度场模型[J]. 西南交通大学学报, 2022, 57(5): 976-981.
WANG Tao, ZHANG Zhuang, ZHAO Kangfa, et al. Numerical modeling of dynamic temperature field for air-cooling traction transformers with forced oil circulation[J]. Journal of southwest jiaotong university, 2022, 57(5): 976-981.
- [7] 李闯, 陈永艳, 宋力, 等. 基于磁-热双向耦合的牵引电机温度场分析[J]. 微电机, 2024, 57(8): 48-55.
LI Chuang, CHEN Yongyan, SONG Li, et al. Temperature field analysis of traction motor based on magnetic-thermal bidirectional coupling[J]. Micromotors, 2024, 57(8): 48-55.
- [8] 韩建军, 张梦琪, 赵道松, 等. 基于Bagging-WOA-SVR的粮堆温度场预测模型[J]. 中国粮油学报, 2024, 39(6): 7-12.
HAN Jianjun, ZHANG Mengqi, ZHAO Daosong, et al. Prediction model of grain pile temperature field based on Bagging-WOA-SVR[J]. Journal of the Chinese cereals and oils association, 2024, 39(6): 7-12.
- [9] 武晨雨, 陶银罗, 曾九孙. 引入注意力机制时空深度神经网络的再热器温度偏差预测方法[J]. 中国测试, 2024, 50(1): 151-159.
WU Chenyu, TAO Yinluo, ZENG Jiusun. Prediction method of reheater temperature deviation based on attention mechanism spatiotemporal deep neural network[J]. China measurement & testing technology, 2024, 50(1): 151-159.
- [10] 杨永, 王瑞锋. 基于循环神经网络的动车组温度数据预测研究[J]. 大连交通大学学报, 2024, 45(3): 53-57.
YANG Yong, WANG Ruifeng. Research on temperature data prediction of EMU based on cyclic neural network[J]. Journal of Dalian jiaotong university, 2024, 45(3): 53-57.
- [11] 丁荣军, 宋文胜, 麻宸伟. 列车电力牵引系统控制与状态监测综述及展望[J]. 中国电机工程学报, 2024, 44(17): 6973-6990.
DING Rongjun, SONG Wensheng, MA Chenwei. Overview and prospect of control and condition monitoring of train electric traction systems[J]. Proceedings of the CSEE, 2024, 44(17): 6973-6990.
- [12] 黄权, 阮建高. 一种基于神经网络的离散傅里叶矩阵重构方法研究[J]. 电子设计工程, 2022, 30(16): 1-5.
HUANG Quan, RUAN Jiagao. Research on a reconstruction method of discrete Fourier matrix based on neural network[J]. Electronic design engineering, 2022, 30(16): 1-5.
- [13] 贾澎涛, 张杰, 郭风景. 基于GAT-Informer的采空区煤自燃温度预测模型[J]. 工矿自动化, 2024, 50(11): 92-98.
JIA Pengtao, ZHANG Jie, GUO Fengjing. Coal spontaneous combustion temperature prediction model for goaf area based on GAT-Informer[J]. Industry and mine automation, 2024, 50(11): 92-98.
- [14] 刘家辉, 梅平, 刘长征, 等. 基于GRU-CNN模型的云南地区短期气温预测[J]. 计算机仿真, 2023, 40(9): 472-476.
LIU Jiahui, MEI Ping, LIU Changzheng, et al. Short-term temperature prediction in Yunnan region based on GRU-CNN model[J]. Computer simulation, 2023, 40(9): 472-476.
- [15] 闫方, 吕梦娜, 杨文艺, 等. 运用Dropout-GRU模型的短期负荷预测[J]. 电子设计工程, 2024, 32(24): 124-128.
YAN Fang, LYU Mengna, YANG Wenyi, et al. Short-term load forecasting by using Dropout-GRU[J]. Electronic design engineering, 2024, 32(24): 124-128.
- [16] 闭永雷, 吴爱中, 翁琳. 地铁车辆弓网静态电接触的多场耦合模型及温升分析[J]. 机车电传动, 2023(1): 138-143.
BI Yonglei, WU Aizhong, WENG Lin. Multi-field coupling modeling and temperature rise analysis for the static pantograph-catenary electrical contact of metro trains[J]. Electric drive for locomotives, 2023(1): 138-143.

- [17] 王景妍, 李秀芬, 张永学, 等. 基于 CFD 水冷式牵引电机不同工况下温度场分析[J]. 机械设计与制造, 2022, 380(10): 196-200.
WANG Jingyan, LI Xiufen, ZHANG Yongxue, et al. Temperature field analysis of the water-cooled traction motor under different working conditions based on computational fluid dynamics[J]. Machinery design & manufacture, 2022, 380(10): 196-200.
- [18] 史向文, 林飞, 王超, 等. 基于量化状态时间离散的城轨牵引供电系统动态仿真方法[J]. 机车电传动, 2022(5): 151-158.
SHI Xiangwen, LIN Fei, WANG Chao, et al. A dynamic simulation method of urban rail traction power supply system based on quantized state time discretization[J]. Electric drive for locomotives, 2022(5): 151-158.
- [19] 侯鑫尧, 孟洋, 丁峰, 等. 基于数据驱动的列车牵引系统多温度测量回路故障诊断方法[J]. 电气工程学报, 2025, 20(3): 368-377.
HOU Xinyao, MENG Yang, DING Feng, et al. Data-driven based fault diagnosis method for multi-temperature measurement circuit in train traction system[J]. Journal of electrical engineering, 2025, 20(3): 368-377.
- [20] 冯江华, 胡云卿, 袁贤珍, 等. 高速磁悬浮列车牵引系统建模与仿真研究[J]. 铁道学报, 2025, 47(7): 127-135.
FENG Jianghua, HU Yunqing, YUAN Xianzhen, et al. Research on modeling and simulation of traction system for high-speed maglev trains[J]. Journal of the China railway society, 2025, 47(7): 127-135.

Research on temperature field prediction technology for traction systems based on hybrid DNN

ZONG Zhenlong^{1,2}, LIU Guanfang^{1,2}, YANG Liuqing^{1,2}, PANG Cong^{1,2}

(1. CRRC Yongji Electric Co., Ltd., Yongji, Shanxi 044502, China;

2. Shanxi Key Laboratory of Traction Motor for Rail Transit, Yongji, Shanxi 044502, China)

Abstract: Since the temperature changes of various components in a traction system exhibit nonlinear dynamic pattern, a one-dimensional modeling method is difficult to simultaneously obtain the spatial distribution patterns and long-term dependencies of temperature fields. A temperature field prediction method based on hybrid deep neural networks (DNNs) is proposed to address the technical challenges of spatiotemporal coupling modeling in temperature field prediction for traction systems. This method constructed a high-fidelity and multi-condition temperature field simulation dataset for traction systems and, when integrated with resampling and standardized data processing, parameterized geometric modeling, and multi-physics coupling simulation techniques, generated high-quality spatiotemporal samples. Moreover, this method designed a dual-branch network architecture that integrated graph attention mechanisms and temporal modules to accurately depict the thermal conduction paths and distribution patterns of traction system components in the spatial dimension, and to enhance the ability to capture nonlinear dynamic patterns and key abrupt features in the temporal dimension, thus realizing the temperature field prediction for traction systems. The experimental results show that the training loss in the 5-minute prediction scenario is 0.003, and the prediction error at key positions is within ± 0.5 °C.

Keywords: traction system; temperature field; Fourier transform; graph neural network; stacked GRU; ITA module; simulation