

基于改进 CNN-BiLSTM 模型和地磁监测数据的多时间长度 GIC 预测*

蓝东亮¹ 陈延云¹ 吴影¹ 赵森¹
王亮² 吴伟丽^{2,3} 黄冲³

1(中国大唐集团科学技术研究总院有限公司 华东电力试验研究院 合肥 230088)

2(安徽正广电电力技术有限公司 合肥 231299)

3(西安科技大学电气与控制工程学院 西安 710054)

摘要 太阳风暴在电力系统网络中驱动产生的 GIC 会影响电力设备和系统的安全运行, 严重时还会引发大面积停电事件. 预测电网 GIC 水平能够为电力系统保护措施提供重要参考, 然而对这方面的研究仍显不足. 为了解决该问题, 将卷积神经网络 (CNN) 与双向长短时记忆 (BiLSTM) 以及注意力机制相结合, 利用空间天气的相关监测信息, 提出了大规模电网 GIC 多时间长度的预测方法. 本文在分析太阳风暴驱动产生电网地磁感应电流 (Geomagnetically Induced Current, GIC) 基础上, 构建了 GIC 预测模型; 提出了基于多头注意力机制的 CNN-BiLSTM 改进模型, 对 GIC 进行预测, 并给出了预测流程. 采用 CNN 捕获地磁扰动局部信息, 根据 BiLSTM 综合地磁扰动信息的全局特征, 综合利用多头注意力机制评估对 GIC 关键作用的地磁信息片段, 实现电网 GIC 的预测. 利用 2004 年 11 月 8 日 00:00 LT–20:00 LT 巨型磁暴期间 DED 地磁台站和 QGZH 地磁台监测数据, 应用所提方法对岭澳 500 kV 变电站 GIC 进行回归预测. 经过训练后, GIC 预测相对误差均在 12% 以内, 精度高于其他模型的预测结果.

关键词 太阳风暴, GIC 预测, 卷积神经网络, 地磁数据

中图分类号 P353

Multiscale GIC Prediction Based on Improved CNN-BiLSTM Model and Geomagnetic Monitoring Data

LAN Dongliang¹ CHEN Yanyun¹ WU Ying¹ ZHAO Miao¹
WANG Liang² WU Weili^{2,3} HUANG Chong³

1(East China Electric Power Research Institute of China Datang Group Science and Technology Research Institute Co., Ltd., Hefei 230088)

* 国家电网科技项目 (SGXJCJ00KJJS2100582) 和合肥市关键共性技术研发项目 (2021GJ039) 共同资助

2023-08-10 收到原稿, 2024-03-11 收到修定稿

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

2(Anhui ZGD Electric Power Technology Co. Ltd., Hefei 231299)

3(School of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054)

Abstract The GIC generated by solar storms driving in power system networks can affect the safe operation of power equipment and systems, and even lead to major power outages. Predicting the level of GIC in power grids can provide an important reference for power system protection measures, but research in this area continues to be insufficient. In order to solve this problem, a multi-scale GIC prediction method for large-scale power grids is proposed by combining Convolutional Neural Networks (CNN), Bidirectional Long and Short Term Memory (BiLSTM), and attention mechanisms, using relevant monitoring information of spatial weather. Firstly, based on the analysis of the mechanism of GIC generated by solar storms, a GIC prediction model is constructed; Secondly, a dual-channel GIC prediction architecture based on CNN-BiLSTM is proposed: first, local geomagnetic disturbance information is captured using CNN, then the global characteristics of geomagnetic storm disturbance information are synthesized using BiLSTM, and finally, the geomagnetic information fragments that play a key role in GIC are comprehensively evaluated using the multi-head attention mechanism, achieving the prediction of the power grid GIC. Using monitoring data of the DED geomagnetic station and the QGZH geomagnetic station during the giant magnetic storm from 00:00 LT—20:00 LT on 8 November 2004, the proposed method was applied to regression prediction of the GIC of the 500 kV Ling'ao substation. After 220 rounds of training, the relative error of GIC prediction is within 12%, the accuracy is higher than the prediction results of other models.

Key words Solar storm, GIC prediction, Convolutional Neural Networks (CNN), Geomagnetic data

0 引言

地磁感应电流 (Geomagnetically Induced Currents, GIC) 是空间天气在大地表面技术系统中产生的最重要的影响因素之一, 由于可能会损坏电网或设备, 高水平 GIC 还会导致电力系统大面积停电, 因此, 准确预测电网 GIC 对防御空间天气带来的电网故障灾害具有重要意义。

以往的研究更多关注 GIC 的计算, 对 GIC 预测方面的研究相对较少。相关研究基本可以分为两大类, 一类研究认为太阳风暴是驱动电网 GIC 的根源, 因此这类研究从太阳活动开始, 先利用高能粒子、行星际物质、太阳总磁场强或日冕物质抛射 (Coronal Mass Ejection, CME) 等太阳风历史监测数据, 对其进行预测^[1], 再对太阳风与地磁场之间的关系模型加以构建^[2,3], 对磁暴感应地磁场和地电场进行预测, 最终实现对 GIC 的评估^[4,5]。如使用卫星观测的实测太阳风数据为模型输入参数, 对地球磁层-电离层电流体系进行计算, 进而计算这些电流体系引起的地磁扰动, 再采用常规算法对电网 GIC 进行计算, 或者直接利用磁流体动力学理论 (Magnetohydrodynamics,

MHD) 模型对 GIC 进行建模^[6], 最后利用 GIC 实测数据进行比对, 验证预测精度。例如文献^[7]利用 Elman 神经网络, 根据 ACE 太阳风数据预测了 30 min 内磁暴感应地磁场最大水平分量随时间的变化率, 并以此为基础进行了 GIC 预测。这种研究利用了太阳风监测数据将空间天气与 GIC 直接关联, 在芬兰已经纳入了空间天气监测框架^[8], 由于地磁场的北向分量和东向分量对行星际磁场的依赖性不同, 因此这种方法会因地理位置的区别而存在不可避免误差; 另有研究认为, GIC 强度取决于磁暴感应地电场的强度, 而由于地电场监测数据没有地磁场监测数据丰富, 因此这类方法先是利用地磁场实测数据, 结合前馈神经网络^[9]、长短时间记忆网络 (Long Short-Term Memory, LSTM) 等算法对地磁数据加以预测^[10], 再结合大地电性结构和 GIC 常规计算方法, 实现对电网 GIC 的预测。但是基于单链结构的 LSTM 仅能学习正向时序关系, 当处理时间跨度长的大规模数据时, 对历史数据的全局信息学习不够充分, 影响预测结果的准确性。双向长短期记忆网络 (Bi-directional Long Short-Term memory, Bi-LSTM) 是 LSTM 模型的扩展, 包括前向 LSTM 和后向 LSTM, 弥补了单向

LSTM 对前后数据关联性挖掘的不足, 可望能够捕捉太阳风暴监测序列的全局特征^[11].

太阳风暴有 11 年左右的周期, 若对 GIC 进行长期预测时, 监测数据规模庞大, 仅采用 BiLSTM 预测将消耗大量的计算机资源. 为了解决该问题, 可以采用卷积神经网络 (Convolution Neural Network, CNN) 先对数据进行局部特征提取^[12], 再利用 BiLSTM 进行全局关联性挖掘, 最后利用注意力机制评估对 GIC 输出贡献突出的信息, 可望得到较高的预测准确率.

目前, GIC 预测方面的研究尚未全面展开, 对 GIC 预测的时间长度还没有明确的划分, 结合电力系统安全稳定控制的需求, 对 GIC 进行以小时为单位的预测可用于电力系统对地磁暴引发电力事故的安全防御策略的部署和实施, 对 GIC 以分钟为单位的预测则可以应用于电力系统继电保护、自动控制等系统的阈值制定和装置启动. 对 GIC 进行两种不同时间长度的预测, 对电力系统的安全防控都具有重要的意义. 有鉴于此, 提出一种同时考虑时间与空间因素的卷积-双向长短期记忆 (CNN-BiLSTM) 改进模型, 将具有空间局部特征提取能力的卷积神经网络 (CNN) 和具有能同时考虑前后方向长时间信息的双向长短期记忆 (BiLSTM) 相结合, 并利用多头注意力机制加以引导与融合, 凸显对预测有关键作用的特征, 以提高预测精度, 最后利用 2004 年强磁暴期间的地磁扰动信息对电网 GIC 加以预测, 并用 GIC 实测数据验证了所提模型的准确性. 本文将深度学习方法引入地磁-电网耦合作用领域, 有助于估测未来太阳风暴期间的大规模 GIC 水平, 为电力部门提供重要

的地磁暴灾害预警与防御提供参考.

1 GIC 预测模型

1.1 太阳风驱动 GIC 机理

电网 GIC 是太阳风在大地表面技术系统造成影响的表现形式, 其驱动过程如图 1 所示.

根据太阳风驱动 GIC 过程^[13,14], 构建 I_{GIC} 预测模型, 具体如下:

$$I_{\text{GIC}} = f(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n). \quad (1)$$

式中, $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ 为驱动 GIC 产生的太阳风及其过程的参数向量, 参数可分为三种, 第一种是太阳风数据, 第二种是电离层电流数据, 第三种是地磁台监测数据. 本文采用第三种参数对电网 GIC 进行预测.

1.2 基于多头注意力机制的 CNN-BiLSTM 改进模型

磁暴一般分为初始相、主相和恢复相, 不同阶段地磁扰动变化特征也有所不同. 鉴于此, 利用地磁监测数据进行预测时, 不仅需要对整个地磁暴期间的地磁扰动信息进行全局特征提取, 还需要对地磁扰动不同阶段的局部信息特征进行提取. 为解决上述问题, 对原有的 CNN-BiLSTM 模型加以改进^[15-18], 在 CNN-BiLSTM 模型基础上引入多头注意力机制, 具体模型如图 2 所示.

图 2 中多头注意力机制建立在自我注意力机制模型基础上, 多角度多层次地将 CNN 和 BiLSTM 两个模型的特征输出进行综合评分, 筛选对 GIC 贡献的地磁特征信息, 减少其中非关键特征的影响, 降低计算的复杂性. 与原有自我注意力机制相比, 能够更加有效筛选卷积神经网络 (CNN) 和 BiLSTM 模块所




图 1 太阳活动驱动 GIC 全过程

Fig. 1 Entire process of solar activity driving GIC




图 2 CNN-BiLSTM-mAT 构建的 GIC 预测模型

Fig. 2 GIC prediction model constructed by CNN-BiLSTM-mAT

提取的局部和全局特征.

该预测模型中, CNN 对仍然包含卷积层、池化层和全连接层, 对单次地磁暴扰动重要的局部特征信息的提取仍然经历卷积、特征提取、最大池化和扁平化等过程, 其输出为由 $X_i = f(t_i p_i + \delta_i)$ 构成的序列向量 $\mathbf{H}_c = \{h_{c1}, h_{c2}, \dots, h_{cn}\}$, 其中 t_i, δ_i 分别为权重矩阵和偏差向量; BiLSTM 对全局信息特征提取也仍然经历两个信息输入方向相反的 LSTM 的运算后再综合的过程, 最终输出为向量 $\mathbf{H}_b = [h_{b1}, h_{b2}, \dots, h_{bt}]$. 在此仅阐述多头注意力机制对不同时间长度特征的合成过程.

1.3 多头注意力机制

经过 CNN 和 BiLSTM 捕获的地磁扰动特征向量均输入到自我注意力机制 (Self-Attention, AT) 模块后, 自我注意力机制自动学习和计算特征输入对 GIC 预测输出的贡献, 多头注意力机制 (Multi-head

Self-attention, MAT) 更进一步构建不同特征输入和 GIC 之间关联关系, 使得模型能够综合考虑各影响因素的相关性, 突出关键特征在预测过程中的贡献, 并且抑制不相关信息, 达到准确预测的效果. 具体过程如下. 自我注意力先对每个输入向量进行高维空间映射, 得到三组向量:

$$\begin{cases} \mathbf{Q} = \mathbf{W}_q \mathbf{H}, \\ \mathbf{K} = \mathbf{W}_k \mathbf{H}, \\ \mathbf{V} = \mathbf{W}_v \mathbf{H}. \end{cases} \quad (2)$$

式中, $\mathbf{H} = \begin{bmatrix} \mathbf{H}_c \\ \mathbf{H}_b \end{bmatrix}$, 为 CNN 和 BiLSTM 的输出特征向量, $\mathbf{W}_q, \mathbf{W}_k, \mathbf{W}_v$ 为映射参数矩阵, 表征权重, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 为映射向量矩阵, 分别由向量 $\mathbf{q}_i, \mathbf{k}_i, \mathbf{v}_i$ 组成.

经过上述映射后, 可以得到自注意力输出矩阵 $\mathbf{h}_{\text{ead}}$:

$$\mathbf{h}_{\text{ead}} = s \left(\frac{\mathbf{K}^T \mathbf{Q}}{\sqrt{d_k}} \right)_{\text{softmax}}. \quad (3)$$

式中, $s_{\text{softmax}}(\cdot)$ 为归一化函数, d_k 为输入的向量维数, T 表示转置操作.

将多次并行自注意力机制输出结果进行拼接、组合, 得到多头注意力输出, 即

$$M_{\text{ultiHead}}(Q, K, V) = C_{\text{oncat}}(h_{\text{ead}_1}, \dots, h_{\text{ead}_i}, \dots, h_{\text{ead}_h})W. \quad (4)$$

式中, h_{ead_i} 为自注意力输出结果, h 为拼接数量, 与特征参数向量数量一致.

多头注意力机制将对特征向量的评分结果输入全连接层, 进行加权处理后得到 GIC 预测, 输出 $\hat{Y} = [\hat{y}_1, \dots, \hat{y}_n]$.

2 基于 CNN-BiLSTM 和多头注意力机制的 GIC 预测流程

由 CNN, BiLSTM 和多头注意力机制构成的 GIC 预测流程如图 3 所示.

第 1 步 收集地磁监测数据和电网 GIC 数据, 根据预测算法的需求, 结合 GIC 采样频率对地磁扰动监测数据进行清洗与插补和归一化, 将样本数据分

为训练集和测试集.

第 2 步 搭建 CNN-BiLSTM-MAT 预测模型, 根据样本规模设置模型各环节参数.

第 3 步 将测试集样本序列输入 CNN, 经过卷积、最大池化, 挖掘地磁扰动序列的局部特征, 再经过扁平处理, 输出特征序列, 送入注意力机制.

第 4 步 将测试集样本序列送入 BiLSTM, 挖掘前后磁暴扰动序列样本之间的关联性, 并进一步获得磁暴扰动的全局特征, 并将其输出到多头注意力机制.

第 5 步 多头注意力机制提取对 GIC 预测有关键作用的输入特征, 利用训练集对模型进行训练, 并判断迭代次数和精度是否满足要求, 如果否, 重复第 2~5 步, 直至上述要求均达到满足, 如果是, 则转入第 6 步.

第 6 步 利用测试集样本对 GIC 进行预测, 分析其预测精度, 判断精度是否满足要求, 如果否, 重复第 2~4 步, 直至上述要求均达到满足; 如果是, 结束训练. 输出预测结果, 计算预测精度并对模型进行评价.




图 3 GIC 预测流程

Fig. 3 GIC prediction process

3 算例分析

3.1 地磁扰动数据

针对 2004 年 11 月 7—8 日强磁暴 ($Dst < -200$ nT) 事件, 选取琼州 (QGZ, 19.0°N , 109.8°E) 和德都 (DED, 48.6°N , 126.1°E) 两个地磁台 11 月 7 日 18:30 LT 至 11 月 8 日 23:00 LT 期间监测数据作为输入样本, 选取广东岭澳 500 kV 变电站 (22.9°N , 114.9°E) GIC 监测数据作为输出样本, 输入输出数据分辨率均为 s , 样本长度均为 93601。经过处理, 所有监测数据都已经转换为当地时间, 两个台站监测地磁数据包含 H , Z , D_3 分量, 具体如图 4 所示。

图 4(a) 中, DEDH, DEDD, DEDZ, QGZH, QGZD, QGZZ 分别为 DED 和 QGZ 两个台站对地磁三分量 H , D 和 Z 的监测序列, 图 4(b) 中为 GIC 监测数据。由于感应地电场与地磁扰动之间存在差分的关系, 即 $E \propto \frac{dB}{dt}$, 以及地电场和 GIC 之间存在线性关系, 为此先将地磁监测数据进行时间序列差分, 再进行归一化, 最终构建时间差分序列矩阵, 规模为 6×93601 , 具体如下:

$$\begin{bmatrix} \mathbf{x}_1 \\ \vdots \\ \mathbf{x}_6 \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1,93601} \\ \vdots & \vdots & \vdots \\ x_{61} & \cdots & x_{6,93601} \end{bmatrix}_{6 \times 93601}.$$

输出的 GIC 数据样本序列为 1×93601 。

3.2 预测模型与评价指标

实验编程环境为 MATLAB2022 b, 计算机配置处理器为 intelcore i7。构建 CNN-BiLSTM-MAT 混合神经网络预测模型, 在 CNN 模型中, 一维卷积核

取 128, 使用滑动时间窗口提取数据样本, 以从原始地磁数据信息组中捕获低层隐式特征, 优化器选用 Adam, 将 Batch_Size 设置为 256; 进行最大池化运算降维; 使用平坦层改变维度方向, 各层之间激活函数均使用 ReLU 函数。

BiLSTM 中每个 LSTM 模块设置 50 个神经元, 每个单元不仅从当前地磁扰动的前一项学习知识, 还从当前地磁扰动序列的后一项获得知识, 因此 BiLSTM 获取的特征可以看作地磁扰动信息的两种不同表示。学习率均取 0.001, MAT 对所传输的特征进行融合和分配权重, 激活函数取 $\tanh$, 最后输出预测 GIC 序列。

对预测结果的评价指标用平均绝对误差 E_{MA} (Mean Absolute Error, MAE)、均方根误差 E_{RMS} (Root Mean Square Error, RMSE) 和皮尔逊相关系数 C_P (Person's Correlation Coefficient, PCC) 进行评估, 计算方法分别如下:

$$\begin{aligned} E_{MA} &= \frac{1}{n} \sum_{i=1}^n |\hat{I}_{GICi} - I_{GICi}|, \\ E_{RMS} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{I}_{GICi} - I_{GICi})^2}, \\ C_P &= \frac{\sum_{i=1}^n (I_{GICi} - \bar{I}_{GIC}) (\hat{I}_{GICi} - \bar{I}_{GIC})}{\sqrt{\sum_{i=1}^n (I_{GICi} - \bar{I}_{GIC})^2} \sqrt{\sum_{i=1}^n (\hat{I}_{GICi} - \bar{I}_{GIC})^2}}. \end{aligned} \quad (5)$$

式中, I_{GICi} , $\hat{I}_{GICi}$ 分别为第 i 个 GIC 时间序列样本点的实测值和预测值; $\bar{I}_{GIC}$ 为 GIC 样本均值, 单位 A; N 为样本点个数。其中 E_{MA} 和 E_{RMS} 越小, 表示模型预测结果越准确, 而越接近 1 的 C_P 值表示 GIC 预测结




图 4 原始数据样本

Fig. 4 Raw data sample

果与测量值有越好的吻合程度.

考虑准确预测极端 GIC 水平更有意义, 定义 GIC 阈值统计峰值百分比如下:

$$P_{\text{PTS}}(\gamma) = \frac{1}{100 - \gamma} \frac{1}{n} \sum_{i=1}^G \left| \frac{I_{\text{GIC}i} - \hat{I}_{\text{GIC}i}}{I_{\text{GIC}i}} \times 100\% \right|. \quad (6)$$

式中, γ 为 GIC 水平降序排列后排名靠前的阈值; G 为 GIC 水平排名靠前百分之 γ 样本数. $P_{\text{PTS}}(\gamma)$ 越

小, 表明模型对 GIC 峰值预测的偏差越小.

3.3 结果分析

利用 11 月 8 日 00:00 LT—20:00 LT 期间的地磁暴数据对所搭建的 GIC 预测模型进行验证. 迭代次数设置为 1000, 将前 7500 个样本数据作为训练集, b 表征测试集长度/训练集长度, 则当 b 为 0.3, 1 和 1.7 时, 经过多轮训练与验证, 所提方法的 GIC 预测结果见图 5.




图 5 不同测试集长度的 GIC 预测结果

Fig. 5 GIC prediction results for different test set lengths

图 5 中相对误差 $E_r = \left| \frac{I_{GIC_i} - \hat{I}_{GIC_i}}{I_{GIC_i}} \right| \times 100\%$. 从图 5 可以看出, b 分别为 0.3, 1 和 1.7 时, 最大相对误差分别为 6.22%, 8.77% 和 11.21%. 与集中参数计算方法得到的 GIC 研究结果相比^[18,19], 所提方法对大规模电网 GIC 预测在精度方面有很大的提高和优势. 可见, 利用 7500 s (约 2 h) 的样本数据, 采用本文所提方法可以较为准确地提前获知 40 min 左右、2 h 左右和 3.5 h 左右的 GIC 水平, 满足电力部门应对地磁暴灾害的不同需求.

此外, 分析图 5 还可以发现, 3 种预测长度下, 相对误差较大时对应的 GIC 绝对值均较小, 且最大相对误差所对应的 GIC 真实水平接近于 0, 此时相对误差的数值较大, 很大程度因为计算时分母较小所致. 为了更全面衡量所提方法预测的准确度, 式 (7) 所示 MAE, RMSE 和 PCC 指标, 同时为了衡量所提方法对 GIC 峰值预测的精确度, 式 (8) 所定义的 $P_{PTS}(\gamma)$ 指标结果列于表 1.

从表 1 可以看出, 不同测试集长度下, 精度指标 MAE 和 RMSE 表明了所提方法的预测结果具有较高精度, PCC 在 $b=0.3, 1, 1.7$ 测试集长度时均接近 1, 表明了 GIC 预测值与测量值之间的吻合程度较高, 同时 $P_{PTS}(\gamma)$ 小于 20%, 表明了预测 GIC 峰值的精度可以接受.

将 11 月 8 日 00:00 LT–20:30 LT 监测样本划分为 7 个样本集合, 采用 7 折交叉验证法, 最终预测结果如图 6 所示, 为进行对比, 将 CNN-LSTM, CNN-

表 1 不同测试集长度时模型评价指标
Table 1 Model evaluation indicators for different test set lengths

训练集长度	测试精度		训练精度		C_P	$P_{PTS}(\gamma)$
	MAE	RMSE	MAE	RMSE		
$b=0.3$	0.02563	0.1223	0.0269	0.2101	0.9689	3.63%
$b=1$	0.0201	0.1025	0.0209	0.1767	0.9926	8.08%
$b=1.7$	0.0212	0.1114	0.0254	0.1960	0.9765	9.22%




图 6 4 种方法对 11 月 8 日 GIC 预测结果

Fig. 6 Prediction results of four methods

BiLSTM 和 CNN-LSTM-SAT3 种模型预测的结果也列于图 6 中。

从图 6 可以看出, 本文方法的最大相对误差为 11.21%; CNN-LSTM 最大相对误差为 15.09%, CNN-BiLSTM 最大相对误差为 13.97%; CNN-LSTM-SAT 最大相对误差为 13.98%。可见本文所提方法精度明显高于其他 3 种方法。不过分析图 6 可见, 4 种模型预测结果中, 仍存在因 GIC 真实平接近于 0 导致相对误差较大问题, 故对 4 种模型预测结果做进一步分析对比, 得到 GIC 预测值与测量值之间吻合程度如图 7 所示。

由图 7(a) 可见, CNN-LSTM 对 GIC 预测偏离实测值较多, 尤其是 GIC 在 ± 20 A 左右以及极端峰值时偏差较大, 由图 6(b) 可知, GIC 在 ± 20 A 左右也为一系列局部峰值, 可见 CNN-LSTM 模型对地磁扰动局部信息特征提取能力较弱, 导致对 GIC 峰值水平的预测效果较差; 类似地, 由图 7(b) 可以看出, CNN-LSTM-SAT 模型虽然自注意力模块融合了 CNN 与 LSTM 共同捕捉的特征, 增强了对局部峰值预测能力, 但仍对 GIC 极端峰值预测有明显的偏差; 由图 7(c) 可见, CNN-BiLSTM 模型利用了双向长短

时记忆网络, 充分挖掘了地磁扰动局部和全局信息, 相比前两种算法改善了对极端峰值的预测能力, 但仍然对 $-40 \sim 0$ A 水平的 GIC 预测效果欠佳, 而对比图 7(a)~(c) 和图 7(d) 可以看出, 本文所提方法中因为增加了多头注意力模块, 对出现频次较少的信息也能增强其特征, 所预测的 GIC 水平与 GIC 实测值吻合度明显高于其他三种方法。

为了全面对比预测精度和性能, 将 4 种模型预测结果的精度 MAE, RMSE, PCC 和 PPTS (5) 指标进行计算, 结果列于表 2。

由图 6、图 7 和表 2 可见, 对比预测相对误差、MAE 和 RMSE 3 个指标可以看出, 本文所提方法的精度明显比其他 3 种方法高; 更重要的是, 对 GIC 极端水平进行预测时, 本文方法 $P_{PTS}(\gamma)$ 最大值为 8.11%, 而 CNN-LSTM-SAT, CNN-BiLSTM 和 CNN-LSTM 模型的 PPTS 指标最大值分别为 16.13%, 16.44% 和 21.33%, 所提方法对 GIC 极端水平预测的准确度高出其他方法分别为 8.02%, 8.33% 和 13.22%。综合可见, 本文方法在预测准确性、预测性能和对极端 GIC 水平预测方面均优于其他 3 种方法。

11 月 7 日 GIC 数据从 18:00 LT 开始监测, 分辨




图 7 4 种方法预测值与测量值的吻合程度对比

Fig. 7 Comparison of the degree of agreement between predicted and measured values using four methods

表 2 4 种模型 GIC 预测评价指标
Table 2 GIC prediction evaluation indicators for four models

样本集(LT)	模型	Relative error/(%)	RMSE	MAE	PCC	PPTS (5)/(%)
00:00—03:00	CNN-BiLSTM-MAT	11.21	0.2314	0.0210	0.976	7.22
	CNN-BiLSTM	13.33	0.4871	0.0226	0.944	14.24
	CNN-LSTM-SAT	13.37	0.4614	0.0243	0.909	15.33
	CNN-LSTM	14.71	0.6385	0.0579	0.897	20.35
03:01—06:00	CNN-BiLSTM-MAT	11.10	0.2042	0.0198	0.987	7.80
	CNN-BiLSTM	13.22	—	0.0432	—	15.22
	CNN-LSTM-SAT	13.98	0.4348	0.0342	0.931	16.21
	CNN-LSTM	15.09	0.9590	0.0654	0.823	23.24
06:01—09:00	CNN-BiLSTM-MAT	10.07	0.2333	0.0208	0.993	8.11
	CNN-BiLSTM	13.08	0.3211	0.0299	0.945	15.33
	CNN-LSTM-SAT	14.13	0.4476	0.0566	0.912	14.56
	CNN-LSTM	14.34	0.9271	0.0579	0.899	21.22
09:01—12:00	CNN-BiLSTM-MAT	9.98	0.2242	0.0187	0.997	7.06
	CNN-BiLSTM	13.97	0.2499	0.0286	0.922	14.67
	CNN-LSTM-SAT	13.87	0.4681	0.0276	0.899	15.17
	CNN-LSTM	14.87	0.9433	0.0688	0.881	19.23
12:01—15:00	CNN-BiLSTM-MAT	10.79	0.2111	0.0211	0.987	7.89
	CNN-BiLSTM	13.09	0.2876	0.0321	0.901	16.44
	CNN-LSTM-SAT	13.98	0.4473	0.0453	0.892	16.13
	CNN-LSTM	14.91	0.9445	0.07651	0.879	21.08
15:01—18:00	CNN-BiLSTM-MAT	10.99	0.1923	0.0209	0.988	8.06
	CNN-BiLSTM	13.13	0.2980	0.0298	0.911	14.55
	CNN-LSTM-SAT	13.01	0.4091	0.4033	0.923	14.35
	CNN-LSTM	14.65	0.9374	0.0654	0.899	21.19
18:01—20:30	CNN-BiLSTM-MAT	11.13	0.2121	0.0214	0.981	7.98
	CNN-BiLSTM	12.99	0.3342	0.0329	0.908	15.18
	CNN-LSTM-SAT	13.54	0.4445	0.0332	0.911	14.23
	CNN-LSTM	14.54	0.9189	0.0561	0.891	21.33

注 黑体数字为最优指标.

率为秒, 样本长度为 19800, 利用所搭建模型对 11 月 7 日 18:30 LT—24:00 LT 期间的 GIC 进行预测, 采用简单交叉验证法, 选取前两个小时的样本为训练集, 其余数据为测试集, 结果如图 8 所示.

图 8 给出了 11 月 7 日 GIC 预测结果及局部放大结果. 由图 8 可以看出, GIC 测试集相对误差较小, 且从局部放大图可看出, 所提方法对局部 GIC 峰值的预测较好, 计算 $P_{PTS}(y)$ 可知不足 5%, 表明本文方

法对规模相对较小的 GIC 样本集也能够准确预测其变化趋势和峰值.

4 结论

利用地磁台监测数据, 提出了一种将卷积神经网络、双向长短期记忆网络相结合和注意力机制相融合的多时间长度 GIC 预测方法, 利用 2004 年 11 月 7 和 8 日实测磁暴扰动和 GIC 数据进行验证, 得到以




图 8 11月7日 GIC 预测结果

Fig. 8 GIC prediction results on 7 November

下结论.

(1) 结合卷积神经网络和双向长短期记忆网络提取局部和全局地磁扰动信息特征优势, 再利用多头注意力机制将特征融合, 并进一步凸显关键信息的作用, 所构建模型利用左右的两小时地磁台实测数据作为训练样本, 能够提前获知 40 min 及 3 h 和 3.5 h 的 GIC 变化趋势和水平, 且预测相对误差均不超过 12%, 能够满足电力部门防御地磁暴灾害风险的不同需求.

(2) 利用所提模型采用交叉验证方法对 11 月 8 日数据进行预测, 并与 CNN-LSTM、CNN-BiLSTM 和 CNN-LSTM-SAT 3 种算法对比发现, 在相同的预测时间长度下, 对比相对误差、MAE 和 RMSE 等指标, 表明本文方法在预测准确性和模型预测能力方面均比其他 3 种方法优越, 尤其是本文方法在预测 GIC 峰值时, 预测结果 GIC 阈值统计峰值百分比 PPTS(5) 仅为 CNN-LSTM 模型的 1/4, 为 CNN-BiLSTM 和 CNN-LSTM-SAT 模型的 1/2, 表明所提方法对 GIC 峰值的预测能力优于其他三种方法, 在地磁暴扰动时能够提前获知未来 GIC 峰值的准确水平对电力部门更为重要.

致谢 本文所用地磁台监测数据来源于国家卫星数据中心风云遥感数据服务网 (<http://www.nsmc.org.cn>) 和空

间环境预报中心 (<http://www.sepc.ac.cn/KIndex.php>).

参考文献

- [1] WINTOFT P, WIK M. Exploring three recurrent neural network architectures for geomagnetic predictions[J]. *Frontiers in Astronomy and Space Sciences*, 2021, **8**: 664483
- [2] ZHANG J J, WANG C, TANG B B. Modeling geomagnetically induced electric field and currents by combining a global MHD model with a local one-dimensional method[J]. *Space Weather*, 2012, **10**(5): S05005
- [3] WANG Kairang, LIU Lianguang, WEI Kai, *et al.* A GIC forecasting algorithm for power grid based on interplanetary solar wind information and three dimensional magnetohydrodynamics model[J]. *Proceedings of the CSEE*, 2015, **35**(24): 6341-6350 (王开让, 刘连光, 魏恺, 等. 基于行星际太阳风信息和三维磁流体力学模型预测电网 GIC 的计算方法[J]. *中国电机工程学报*, 2015, **35**(24): 6341-6350)
- [4] KEESEE A M, PINTO V, COUGHLAN M, *et al.* Comparison of deep learning techniques to model connections between solar wind and ground magnetic perturbations[J]. *Frontiers in Astronomy and Space Sciences*, 2020, **7**: 550874
- [5] ROSENQVIST L, HALL J O. Regional 3-D modeling and verification of geomagnetically induced currents in Sweden[J]. *Space Weather*, 2019, **17**(1): 27-36
- [6] PULKKINEN A, HESSE M, KUZNETSOVA M, *et al.* First-principles modeling of geomagnetically induced electromagnetic fields and currents from upstream solar wind to the surface of the Earth[J]. *Annales Geophysicae*, 2007, **25**(4): 881-893

- [7] WINTOFT P, WIK M, VILJANEN A. Solar wind driven empirical forecast models of the time derivative of the ground magnetic field[J]. *Journal of Space Weather & Space Climate*, 2015, **5**: A7
- [8] PULKKINEN A, HESSE M, HABIB S, *et al.* Solar shield: forecasting and mitigating space weather effects on high-voltage power transmission systems[J]. *Natural Hazards*, 2010, **53**(2): 333-345
- [9] BHASKAR A, VICHARE G. Forecasting of SYMH and ASYH indices for geomagnetic storms of solar cycle 24 including St. Patrick's Day, 2015 storm using NARX neural network[J]. *Journal of Space Weather and Space Climate*, 2019, **9**: A12
- [10] BAILEY R L, LEONHARDT R, MÖSTL C, *et al.* Forecasting GICs and geoelectric fields from solar wind data using LSTMs: application in Austria[J]. *Space Weather*, 2022, **20**(3): e2021SW002907
- [11] OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. *Power System Protection and Control*, 2023, **51**(2): 132-140 (欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多时间长度 CNN-BiLSTM-Attention 的短期电力负荷预测方法 [J]. *电力系统保护与控制*, 2023, **51**(2): 132-140)
- [12] AGGA A, ABOU A, LABBADI M, *et al.* CNN-LSTM: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production[J]. *Electric Power Systems Research*, 2022, **208**: 107908
- [13] REN L, DONG J B, WANG X K, *et al.* A data-driven Auto-CNN-LSTM prediction model for lithium-ion battery remaining useful life[J]. *IEEE Transactions on Industrial Informatics*, 2021, **17**(5): 3478-3487
- [14] LI X X, KANG Y F, LI F. Forecasting with time series imaging[J]. *Expert Systems with Applications*, 2020, **160**: 113680
- [15] ZHANG Y D, CHEN X. Motif difference field: A simple and effective image representation of time series for classification[OL]. arXiv preprint arXiv: 2001.07582, 2020. DOI: 10.48550/arXiv.2001.07582
- [16] SUN Qingkai, WANG Xiaojun, ZHANG Yizhi, *et al.* Multiple load prediction of integrated energy system based on long short-term memory and multi-task learning[J]. *Automation of Electric Power Systems*, 2021, **45**(5): 63-70 (孙庆凯, 王小君, 张义志, 等. 基于 LSTM 和多任务学习的综合能源系统多元负荷预测 [J]. *电力系统自动化*, 2021, **45**(5): 63-70)
- [17] LIU Ze, ZHANG Chuang, QI Lei *et al.* Prediction of probability density of remaining useful life of lithium ion battery based on CNN-BiLSTM[J]. *Chinese Journal of Power Source*, 2023, **47**(1): 57-61 (刘泽, 张闯, 齐磊, 等. 基于 CNN-BiLSTM 的锂电池剩余使用寿命概率密度预测 [J]. *电源技术*, 2023, **47**(1): 57-61)
- [18] LIU Chunming. Med-Low Latitude Power Grid Geomagnetically Induced Currents and its Assessing Method[D]. Beijing: North China Electric Power University (Beijing), 2009 (刘春明. 中低纬电网地磁感应电流及其评估方法研究 [D]. 北京: 华北电力大学 (北京), 2009)
- [19] LI X M, WANG Y, LIU C M. Short-time Forecasting of GIC in Power Grid Based on ARIMA Model[J]. *Computer & Digital Engineering*, 2012, **40**(9): 3-136 (李小明, 王颖, 刘春明. 基于 ARIMA 的电网地磁感应电流预测研究 [J]. *计算机与数字工程*, 2012, **40**(9): 3-136)

作者简介



蓝东亮 男, 1991 年 8 月生于江西省宜春市, 现为中国大唐集团科学技术研究总院有限公司华东电力试验研究院工程师。主要研究方向为电力系统安全防护、高电压试验技术、绝缘子检测和外绝缘故障辨识等。

E-mail: Dongliang_lan@163.com



吴伟丽 (通信作者) 女, 1978 年 6 月生于新疆乌鲁木齐市, 现为西安科技大学电气工程学院副教授、硕士生导师。主要研究方向为地磁暴灾害对电力系统的影响及其防御、GIC 预测预报等。

E-mail: wwllxm@163.com