

基于 MAGAT 的风电场功率缺失数据填充方法

卢冠华¹, 余涛^{1,2}, 吴毓峰¹, 潘振宁¹, 陈俊斌¹, 邓柏荣¹

(1. 华南理工大学电力学院, 广东省 广州市 510640;
2. 广东省电网智能量测与先进计量企业重点实验室, 广东省 广州市 510640)

MAGAT-based Method for Imputing Power Loss Data in Wind Farms

LU Guanhua¹, YU Tao^{1,2}, WU Yufeng¹, PAN Zhenning¹, CHEN Junbin¹, DENG Bairong¹

(1. School of Electric Power, South China University of Technology, Guangzhou 510640, Guangdong Province, China;

2. Guangdong Provincial Key Laboratory of Intelligent Measurement and Advanced Metering of Power Grid,
Guangzhou 510640, Guangdong Province, China)

ABSTRACT: Wind farms' quality of power data is significant for wind power forecasting. However, due to human error, sensor failures, network issues, or communication congestion, wind farm power data is prone to extensive missing values. Therefore, this article proposes a MAGAT (Multi-Head Attention and Graph Attention Network) model that combines Multi-head Attention (MA) and Graph Attention Network (GAT) to address this issue. Using a heterogeneous graph representation, the GAT layer is used to characterize and extract the associative relationships between known and missing data in the wind farm. On the other hand, the MA layer focuses on mining the mapping relationship between the features of wind farm data and the missing power data, enabling accurate filling of missing power data in the wind farm. The proposed method is compared to other advanced filling algorithms in an empirical analysis using operational monitoring data from a wind farm in Jiangsu, China. The results show that the proposed method outperforms the others in various scenarios, including different types and rates of missing data. This demonstrates the effectiveness and stability of the proposed method for filling in missing data in wind farms.

KEY WORDS: wind farm; data imputation; multi-head attention; graph attention network

摘要: 风电场功率数据质量对风电预测具有重要意义。然而, 由于人为操作、传感器故障、网络故障或通信拥堵等原因, 风电场功率数据容易出现大面积缺失问题。因此, 结合多头注意力机制(multi-head attention, MA)和图注意力网络(graph

attention network, GAT)构建了 MAGAT 模型, 其中 GAT 层以异质图的方式刻画及提取风电场已知数据与缺失数据的关联关系, MA 层挖掘风电场数据特征与缺失功率数据之间的映射关系, 从而实现风电场功率缺失数据的高精度填充。在以我国江苏某风电场运行监测数据为对象的算例分析中, 与其他先进填充算法相比, 所提方法在不同缺失类型、不同缺失率等多个场景下均具有更好表现, 表明所提方法在风电场缺失数据填充任务上的有效性及稳定性。

关键词: 风电场; 数据填充; 多头注意力; 图注意力网络

DOI: 10.13335/j.1000-3673.pst.2023.2017

0 引言

随着风力发电规模不断扩大, 准确的风电预测成为电力系统安稳运行的必要条件^[1]。然而, 目前风电预测的精度受限于两个方面: 1) 风电功率的强波动性和间歇性难以描述^[2]; 2) 风电场功率监测数据的质量难以保证^[3]。前者研究方法的实现同样依赖于高质量的历史数据, 但由于人为操作、网络故障等原因, 风电功率的在线监测数据常出现大面积缺失问题, 风电数据质量问题严峻^[4]。但现阶段少有研究对此展开讨论。因此, 如何实现风电场功率缺失数据的高精度填充是一个具有现实意义与科研价值的课题^[5]。

目前, 风电场功率缺失数据常用填充方法可归纳为 3 类: 插值法、相似法、神经网络法。插值法^[6-7]和相似法^[8]依赖于邻近数据的时序相关性或历史数据的统计特征, 但难以挖掘数据之间复杂关联关系, 且难以适应风电功率波动性强、规律弱的特点。神经网络法在一定程度上解决了上述问题^[9]。实际上, 该方法的研究集中于以下两个方面: 1) 如何刻画已知数据与缺失数据的关联关系; 2) 如何挖掘各已知特征所蕴含的目标缺失数据信息。

基金项目: 国家自然科学基金项目(52207105); 国家自然科学基金委员会-国家电网有限公司智能电网联合基金项目(U2066212); 中国博士后科学基金项目(2022M721184)。

Project Supported by National Natural Science Foundation of China (52207105); Smart Grid Joint Fund of National Natural Science Foundation of China and SGCC (U2066212); China Postdoctoral Science Foundation (2022M721184).

在第一个方面,现有研究应用了不同类型的神经层,但仍无法充分刻画出所有特征数据之间的关联关系。如长短期记忆网络(long short-term memory, LSTM)只能关注到局部数据间的关系^[10-11],卷积神经网络(convolutional neural network, CNN)的应用效果取决于相邻元素的关联关系,且受限于卷积核的设计^[12-13],图卷积神经网络(graph convolutional networks, GCN)所构建异质图连接边的属性需要人为定义^[14-15]。可见,现有方法大多通过预设规则设计数据的表征方式,从而实现数据间关联关系的刻画。

然而,风电功率数据受多个变量影响,变量之间相互交织形成复杂非线性关系,这些关系难以通过人为设定的规则进行准确刻画。在GCN的基础上,图注意力神经网络(graph attention network, GAT)基于自注意力机制实现图连接边的自适应调整,自动学习数据变量间关联关系的强弱,该方法在表征特征间关联关系方面的有效性已在多个领域得到验证^[16-18]。然而,现如今尚无GAT应用于风电场缺失功率数据填充领域的研究,其对于风电场图模型的表征尚没有统一有效的方法。因此,本文考虑设计基于GAT的风电功率数据表征新方法,以多源数据特征为异质节点,并基于不同种类的节点设置对应的连接边及初始连接权重,以刻画已知数据与缺失数据的关系。

第二个问题包含特征自身信息的挖掘与特征之间关联关系的挖掘两个方面。目前单一神经网络的方法对特征信息的挖掘不够全面,如BP(back propagation)神经网络主要关注特征自身信息的挖掘^[19],CNN、GCN、GAT网络集中于提取特征间的关联关系,LSTM主要挖掘特征的时序信息,而忽略了异质特征之间关联关系的提取。因此,GAT网络虽然适用于刻画及提取已知数据与缺失数据的关联关系,但仍缺乏挖掘不同特征对待填充数据贡献的有效手段。

当前这方面的研究通常集中于多头注意力机制的构建。多头注意力机制(multi-head attention, MA)通过学习输入特征与输出结果之间的映射关系,帮助神经网络将重点放在相关输入特征上,提高模型性能。近年来MA被广泛应用于计算机相关领域^[20-22],但处理对象都是序列数据,而GAT的处理对象是不规则的图数据结构,二者并不兼容。因此,本文考虑设计图结构层面的MA机制,创新性地将MA机制和GAT网络结合,以解决目标缺失特征信息挖掘不充分的问题。

因此,本文结合MA机制和GAT网络设计MAGAT网络,从特征间关联关系表征及特征挖掘

两个角度,有望解决现有风电功率数据填充研究中存在的数据表征不准确及特征挖掘不充分等问题,以提高风电场功率缺失数据填充的准确率。本文主要贡献如下:

1) 提出了一种新的风电场缺失功率数据填充学习框架。针对现有风电功率数据填充研究中关于特征关联关系及特征信息挖掘方面的关键短板,设计了由数据特征信息挖掘、数据特征的动态表达、数据特征关联关系学习组成的学习框架,实现缺失数据与已知特征关联关系的动态修正,提高填充模型在训练阶段的学习效率。

2) 提出了一种适用于多源数据表征的异质图表征新方式。以多源数据特征为异质节点,基于Copula函数及时间函数构建异质边(不同特征数据的连接边)及时序边(不同时刻历史功率的连接边),形成了风电场数据异构图表征,完成多维数据特征间关联关系的有效融合。

3) 基于所提应用框架,设计了图结构层面的MA机制,创新性地将MA机制和GAT网络融合应用于风电场缺失功率数据填充问题中,实现数据特征关联关系的动态学习及表征和数据特征挖掘能力的有效加强。

4) 结合我国江苏某风电场真实数据进行算例实验,以验证不同缺失类型、不同缺失率等多场景下,MAGAT对风电场历史数据库中功率缺失数据填充的有效性。

为方便理解文章建模过程,附录A以表格形式展示了文中数学模型所出现的变量符号具体定义。

1 基于 MAGAT 的风电场功率缺失数据填充框架

风电场功率缺失数据填充本质上是已知外源数据到缺失数据的信息挖掘。针对风电场功率缺失数据填充任务,当前学者已提出多种方法,不同方法在不同特点的数据集中表现有所不同。究其原因,各方法信息挖掘方式不同,挖掘的信息类型不同,挖掘程度也不同,因此适用数据类型不一样。但正如引言所提到,现有研究在如何刻画已知数据与缺失数据的关联关系及如何挖掘各已知特征所蕴含的目标缺失数据的信息两个方面仍存在明显缺陷。因此,本文提出了基于MAGAT的风电场功率缺失数据填充框架,如图1所示。

本框架首先从风电场状态监测系统及风电场数据管理系统获取风电场运行数据及气象数据。在构建特征信息图前,依托于MA层挖掘已知数据

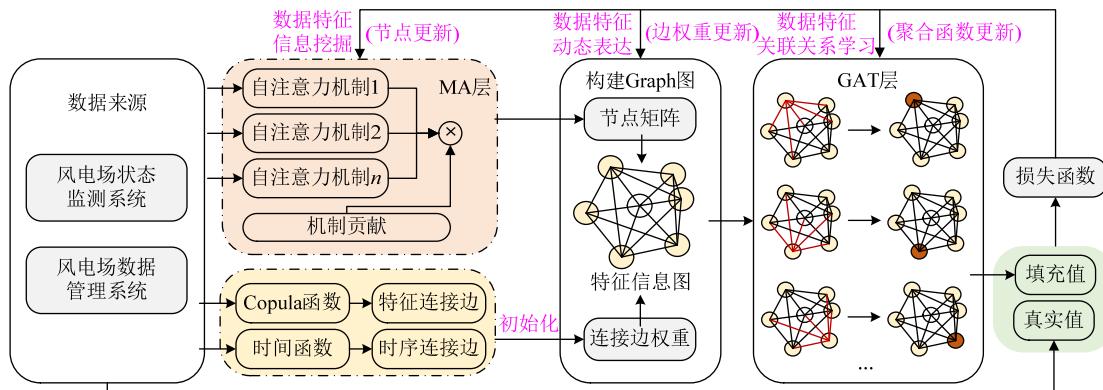


图1 基于 MAGAT 的风电场功率缺失数据填充框架

Fig. 1 Framework of missing power recovery for wind farms based on MAGAT

与缺失数据之间的映射关系,实现图节点信息的更新;异质节点间连接边的权重则根据 Copula 相关性分析及时间函数进行初始化。在构建特征信息图后,依托于 GAT 层聚合图节点信息,实现各已知特征所蕴含目标缺失数据的信息挖掘,完成风电场功率缺失数据的填充。同时损失函数帮助模型在训练过程中完成数据特征信息挖掘(节点更新)、数据特征的动态表达(边权重更新)、数据特征关联关系学习(聚合函数更新)。这种设计旨在利用 Graph 图的结构合理刻画已知数据与缺失数据的关联关系,并利用 MA 层和 GAT 层的注意力机制,充分挖掘节点自身及节点间的关联特征信息,实现外源数据到缺失数据的信息挖掘,从而实现更高精度的风电场功率缺失数据填充。相比于 LSTM、CNN、BP 等特征固定的表征方式,本文所提框架能在特征提取过程中不断更新特征的表征形式,帮助模型充分挖掘特征信息。

2 基于 MAGAT 风电场功率缺失数据填充

2.1 特征信息图构建

在数据集中,除了风电功率外,还包含风速、风向、湿度、温度、气压、气压密度 6 种气象因素。不同模型的填充效果取决于对多源数据的挖掘程度。传统欧式空间下的数据表征无法对风电场数据间的关联关系做出精确的数学描述,因此无法充分挖掘已知外源数据到缺失数据的特征信息。为此,本文提出特征信息图的概念,它本质上是一种图数据。图数据是一种由节点和连接节点的边组成的非欧式空间下的数据类型,其蕴含丰富的结构信息和关联信息。特征信息图重新定义了风电场数据的表达方法,使用节点特征描述风电场多源数据异质特征的同时,通过节点之间边的权重描述特征之间的关联特性,从而全面刻画已知数据与缺失数据的关联关系。特征信息图的构建如图 2 所示。

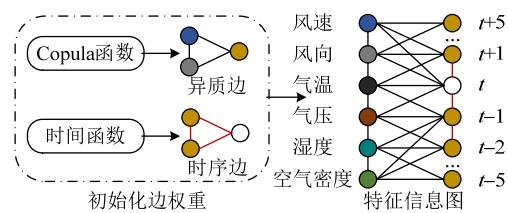


图2 特征信息图架构

Fig. 2 Structure of features information graph

在特征信息图中,为充分挖掘数据中的时序特征及异质特征,同时方便填充模型统一建模,在所有缺失场景中都以单一缺失点为研究对象,并按以下规则选取图节点。假设风电功率数据在 t 时刻发生缺失,即 P_t 缺失,在功率数据方面,选取 $t-5$ 时刻至 $t+5$ 时刻的功率 $[P_{t-5}, P_{t-4}, \dots, P_t, \dots, P_{t+5}]$ 作为输入,并人为设定 P_t 的值为 -1, 其中 -1 为缺失标签;在气象数据方面,选取 t 时刻对应的气象数据(共 6 种)进行输入。若 t 时刻气象数据或 t 时刻邻近功率数据也发生缺失,为最大程度降低缺失数据对填充模型的影响,也人为设定其值为 -1。将选取的功率数据与气象数据融合构成特征矩阵 \mathbf{X} , 则 \mathbf{X} 中共包含 17 个特征数据,以每一个特征数据作为节点构建成无向图 $G(\mathbf{A}, \mathbf{X})$, 其中 \mathbf{A} 为邻接矩阵。在该无向图中,每一个节点代表一个异质特征,为充分挖掘异质节点间的关联关系,设定每个节点都与其他节点相连形成连接边,这意味着 \mathbf{A} 中除对角线元素外的所有元素值都是 1。

在特征信息图中,连接边包含异质边(不同特征数据的连接边)和时序边(不同时刻历史功率的连接边)两种。考虑到不同特征间关联关系不尽相同,需对连接边权重进行初始化。对于异质边,本文引入 Copula 函数进行初始化边权重,Copula 函数是一类用于描述多元随机变量之间依赖关系的函数,多用于多变量随机事件之间的复杂关系。因此本文利用 Copula 函数计算风电场异质特征之间的关联关系,并给出确定的相关系数以初始化连接

边权重; 对于时序边, 考虑到时间间隔越短的节点间相关性越强, 其对应连接边权重应当越大, 因此使用高斯核函数初始化边的权重:

$$C_{i,j}^T = e^{-\frac{\|t_i - t_j\|^2}{2\sigma}} \quad (1)$$

式中: C^T 为时序边权重矩阵; $C_{i,j}^T$ 为节点 i 和 j 之间的连接边权重; t_i 和 t_j 分别为节点 i 和 j 所在的时刻; σ 为比例因子, 决定局部注意力感受范围大小, 取值过大过小都会影响特征提取过程, 在本文中比例因子取值 15(参数确定过程见附录 B)。

2.2 图特征挖掘

通过 2.1 节所述过程, 能够得到风电场功率缺失数据填充过程的特征信息图表示, 解决了如何刻画已知数据与缺失数据的关联关系这个难题。下一步, 设计 MAGAT 网络对特征信息图数据特征进行挖掘与学习, 以形成更加抽象、更深层次的特征表达形式, 从而解决如何挖掘各已知特征所蕴含的目标缺失数据的信息这一问题。

MAGAT 模型主要包含 MA 层和 GAT 层, 分别负责图节点特征的挖掘和图特征的聚合, 其整体框架如图 3 所示。MA 层通过多个自注意力层更新图节点的信息, 从多个维度学习节点特征与缺失数据之间的复杂映射关系; GAT 层结合连接边权重和聚合函数, 使每个更新后的节点聚合相邻节点的特征信息, 形成更加抽象、更深层次的特征表达形式; 最后通过全连接层进行特征变换, 实现高维特征到缺失数据的特征映射。

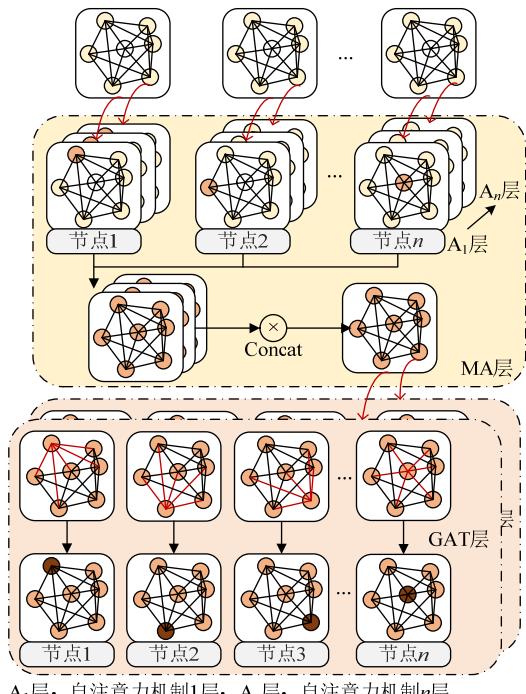


图 3 基于 MAGAT 的图特征挖掘
Fig. 3 Graph feature mining based on MAGAT

2.2.1 MA 层

自注意力机制(self-attention mechanism)是一种针对输入特征的特征处理机制, 通常用于学习输入特征与输出特征之间的映射关系, 使神经网络的重点关注于相关输入特征上, 从而提高模型性能。为了充分利用节点自身的特征信息, MA 层设置了多层自注意力层, 每一层实现了一个维度的特征挖掘。这样, 节点特征便得到了不同维度角度进行挖掘和分配不同重要性的处理。

注意力机制本质是用一个可训练的深度学习网络为每一个特征分配不同权重。针对单层注意力层, 需要学习该维度下节点特征对应的权重, 构建权重矩阵 W^R , 结合特征矩阵 X 得到注意力系数 R :

$$R_i = W_i^R X_i \quad (2)$$

为方便后续网络训练及损失函数的计算, 需要将注意力系数 R 进行归一化操作, 以将 R 中的每个元素转化为 0~1 之间的值, 一般使用 Softmax 函数进行归一化:

$$R'_i = \text{Softmax}(R) = \frac{e^{R_i}}{\sum_{j=1}^n e^{R_j}} \quad (3)$$

MA 层实际上是由 n 层自注意力层堆叠而成, 每一层都可以得到该维度下的注意力系数矩阵 R' , 基于一个可训练的权重矩阵 $W^{R'}$, 为每一个注意力系数矩阵分配不同的权重, 并将他们拼接起来, 得到最终的注意力系数 R'' :

$$R'' = \text{Concat}(R'_1, R'_2, \dots, R'_n) W^{R''} \quad (4)$$

最后, 利用注意力系数 R'' 与特征矩阵 X 进行点乘, 得到更新后的特征矩阵 X' :

$$X'_i = R''_i X_i \quad (5)$$

风电场历史功率缺失数据填充任务的输入数据包括多个不同时间步的风电功率数据及多种不同类型的气象数据, MA 机制的多层注意力层帮助 GAT 网络在不同的表示空间内同时学习不同特征的表征, 从而更好地捕捉序列中的重要信息, 提高了模型的特征挖掘能力; 除此之外, MA 机制帮助 GAT 网络更准确地挖掘不同特征与待填充功率的映射关系, 从而更好地适应不同的场景, 提高了填充模型的鲁棒性。

2.2.2 GAT 层

GAT 利用图数据的结构信息进行特征提取。虽然其工作原理同样依赖于注意力机制, 但与 MA 层不同的是, MA 层实现节点本身特征的挖掘, 而 GAT 层学习节点之间的关联关系, 从而形成更抽象更深层次的特征表达形式。

结合 MA 层更新后的特征矩阵 \mathbf{X}' , 在对节点特征为 X'_i 的节点进行特征聚合时, 需考虑它所有相邻节点的节点特征, 首先基于可训练的聚合函数矩阵 \mathbf{W}^C 及注意力机制, 更新节点 i 与 j 之间的连接边权重信息 C_{ij} :

$$C_{ij} = \frac{\exp(L(\mathbf{A}[\mathbf{W}^C X'_i \| \mathbf{W}^C X'_j]))}{\sum_k \exp(L(\mathbf{A}[\mathbf{W}^C X'_i \| \mathbf{W}^C X'_k]))} \quad (6)$$

式中: $\|$ 表示向量拼接; \mathbf{W}^C 为可训练的聚合函数矩阵, 用于完成每个节点的特征维度变换; \mathbf{A} 为注意力机制中计算节点间相关权重的可训练矩阵; L 表示激活函数 LeakyReLU。

最后, 为学习图中的异质信息和时序信息, 针对节点特征为 X'_i 的节点, 通过加权聚合邻居节点特征得到更新后的节点特征 X''_i :

$$X''_i = \zeta \left(\sum_{j \in N} C_{ij} \mathbf{W}^C X'_j \right) \quad (7)$$

式中 ζ 表示非线性激活函数。

在 GAT 层后, 使用全连接层对图特征进行特征变换, 得到最终的风电场功率填充结果 \mathbf{P}' , 其计算公式为

$$\mathbf{P}' = \mathbf{W}^D \mathbf{X}'' + \mathbf{b}^D \quad (8)$$

式中: \mathbf{W}^D 为全连接层的权重矩阵; \mathbf{b}^D 为全连接层的偏置矩阵。

3 算例分析

3.1 数据与算例说明

3.1.1 数据来源及模型说明

本文研究对象为风电场功率缺失数据, 因此本文算例针对我国江苏某风电场的运行监测数据开展研究, 数据包括: 风电功率、风速、风向、湿度、温度、气压、气压密度共 7 类数据。数据的时间跨度为 2021 年 1 月 1 日—2022 年 4 月 17 日, 数据颗粒度为 15min。

在后续算例分析中, 为了充分验证模型性能, 会将风电场功率数据的缺失数据量比例分别设置为 10%、20%、30% 和 50%。在确定好缺失数据点后, 基于数据缺失位置以图 2 的形式构建特征信息图, 以一个特征信息图作为一个样本。为提高模型泛化能力并保证模型稳定性, 将构建好的所有特征信息图样本打乱, 并随机抽取其中 80% 的数据作为训练集, 供所有填充模型训练使用, 剩余 20% 的数据作为测试集, 以评估对比模型性能。

本文提出的 MAGAT 模型使用 Python 语言进行开发, 基于 Pytorch1.5.0+PyTorch Geometric 图深度学习框架实现, 并在一台配备 GeForce RTX 2080

Ti 的 GPU 服务器上完成算例。

本文所提 MAGAT 模型中每一层的具体参数及输出维度如附录 C 图 C1 所示。

3.1.2 数据预处理

在数据集中, 除了风电功率外, 还包含风速、风向、湿度、温度、气压、气压密度 6 种气象因素。这些气象因素与风电功率之间存在极强的相关性, 将它们与历史功率合并用作输入数据有助于提高风电场功率缺失数据填充的准确性。而为了使模型能够有效收敛, 本文使用 0-1 归一化对所有输入数据进行归一化:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中: x 为原数据特征; x_{\max} 、 x_{\min} 分别为数据序列中的最大、最小值; x' 为归一化后的数据特征。

值得注意的是, 为了更细节地展示填充及预测情况, 后续可视化展示结果图中的数值统一采用归一化后的值(pu)。

3.1.3 模型训练

1) 划分数据集: 将数据集随机打乱后按照 8:2 的比例划分为训练集和测试集。其中训练集用于模型训练, 测试集用于评估模型性能。

2) 学习率: 为防止模型训练陷入局部最优等问题, 使用线性下降的方法动态调整学习率 l_r 。

$$l_r = l_{\max} - \frac{(l_{\max} - l_{\min})N_{\text{epoch}}}{N_{\text{rate}}} \quad (10)$$

式中: N_{epoch} 为当前迭代次数; N_{rate} 为学习率下降速率; l_{\max} 、 l_{\min} 为设置的学习率参数。

3) 损失函数: 本文选用模型训练中较为常见的 MSELoss 函数作为损失函数进行梯度下降。

$$L = \frac{1}{n} \sum_{t=1}^n (P'_t - P_t)^2 \quad (11)$$

式中: n 为测试样本总数; P_t 为时刻 t 风电功率真实值; P'_t 为时刻 t 风电功率填充值。

4) 训练 MAGAT: 搭建好 MAGAT 模型后, 随机初始化模型参数, 结合训练集数据及损失函数通过梯度下降的方式更新模型权重参数, 获得训练完成的 MAGAT 模型。模型训练过程中, 设置相关模型训练参数 N_{epoch} 、 N_{rate} 、 l_{\max} 、 l_{\min} 分别为 200、100、0.005、0.001。

3.1.4 评价指标

使用测试集评估模型填充性能, 为了充分对比模型性能的好坏, 本文使用较为常见的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 这 3 种评价指标对填充结果进行评估。其中: I_{MAE1} 表示平均绝对误差(mean absolute error); I_{MAE2}

表示最大绝对误差(max absolute error); I_{RMSE} 表示均方根误差(root mean square error)。

$$I_{\text{MAE}1} = \frac{\sum_{t=1}^n |P'_t - P_t|}{n} \quad (12)$$

$$I_{\text{MAE}2} = \max(|P'_t - P_t|) \quad (13)$$

$$I_{\text{RMSE}} = \sqrt{\frac{\sum_{t=1}^n (P'_t - P_t)^2}{n}} \quad (14)$$

针对风电功率预测结果, 为防止风电功率真实值很小甚至为 0 时准确率无法准确计算, 无法反映模型预测性能的问题, 本文参考 2021 年国家电网举办的新能源发电预测比赛的准确率计算方法, 规定当风电功率真实值小于 P_b (风电场开机容量的 20%)时, 以 P_b 作为分母计算预测准确率。具体计算方法如下:

$$I_{\text{acc}} = \begin{cases} 1 - \frac{1}{n} \sum_{t=1}^n \frac{|P''_t - P_t|}{P_b} \times 100\%, & P_t < P_b \\ 1 - \frac{1}{n} \sum_{t=1}^n \frac{|P''_t - P_t|}{P_b} \times 100\%, & P_t \geq P_b \end{cases} \quad (15)$$

式中: n 为测试样本总数; P_t 为时刻 t 风电功率真实值; P''_t 为时刻 t 风电功率预测值; P_b 为风电场开机容量的 20%。

3.1.5 模型参数

为了验证 MAGAT 模型的有效性, 出于风电功率缺失填充问题研究现状及填充算法代表性的考虑, 本文使用如三次插值(cubic interpolation)、K 近邻算法(k-nearest neighbor, KNN)、BP 神经网络、MABP、CNN、MACNN 等数据填充方法作为对比。同时为验证多头注意力对 GAT 模型的改进效果, 还使用 GAT 模型作为对比。各模型的输入数据、结构及参数如下。

1) Cubic: 输入数据为风电场历史功率数据。允许最大连续空缺数 100, 插值方向为双向插值。

2) KNN: 输入数据为风电场历史功率数据。设置临近点个数 k 为 3, 聚类方式采用欧氏距离。

3) BP 神经网络: 输入数据为 2.1 节中所提取的 17 个特征数据。模型含三层全连接层, 神经元数量分别为 17: 100(第一层), 100: 50(第二层), 50: 1(第三层), 模型训练迭代次数和学习率与 MAGAT 一致(MABP 为 MA 层嵌入到 BP)。

4) CNN: 为方便构图, 输入数据为 2.1 节中所提取的 17 个特征数据剔除掉 t 时刻功率数据, 共 16 个特征数据, 构建成 4×4 大小数据图像, padding 为 1, padding 后数据图像大小为 6×6 。模

型包括两层卷积层(每层一个卷积核, 卷积核大小为 2×2 , 步长为 1), 两层最大池化层(每层一个池化核, 池化核大小为 2×2)以及一层全连接层(输出神经元数量为 1), 模型训练参数与 MAGAT 一致(MACNN 为 MA 层嵌入到 CNN)。

5) GAT: 与 MAGAT 相比, 除了去除多头注意力机制外, 输入数据、其余结构及参数一致。

6) MAGAT: MAGAT 结构参数展示在图 4。

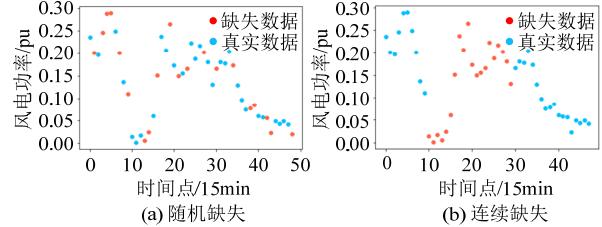


图 4 风电功率缺失类型

Fig. 4 Loss type of wind power

3.1.6 算例设置

风电场功率数据主要存在两种缺失类型, 即随机缺失和连续缺失。在数据采集及传输过程中, 由人为错误或传感器故障导致的数据缺失通常属于随机缺失; 由网络故障或通信拥堵造成的数据缺失往往导致数据出现一段连续时间的数据丢失, 属于连续缺失类型。风电场功率数据的两种缺失类型分别如图 4 所示。

除了风电功率数据纵向的缺失外, 气象数据也可能发生缺失。功率数据及气象数据同时缺失的情况为横向缺失。

为验证本文所提方法有效性, 在 3.2 节对比了不同方法对随机缺失类型风电功率数据的填充效果; 在 3.3 节中对比了不同方法对连续缺失类型风电功率数据的填充效果; 在 3.4 节中对比了不同方法对横向缺失类型风电功率数据的填充效果。

为了更充分验证本文研究内容的必要性, 还需要对比预测模型在风电场填充前后数据集上的预测性能。为了更直观地反映数据填充质量对风电功率预测的影响, 完成了风电场功率数据填充工作后, 在 3.5 节中分别基于填充前、插值法填充、MAGAT 填充的数据集展开研究, 以分析不同填充方法填充的数据集对风电功率预测的影响。

3.2 随机缺失类型数据算例分析

由于人为错误或传感器故障, 风电功率数据可能会出现随机缺失。为了测试所提出的风电场随机缺失数据填充方法的性能, 进行以下算例分析:

设置数据集中风电功率缺失数据比例为 10%, 将所提算法在测试集中反复测试, 展示其各评价

指标如表 1 所示，并以小提琴图的形式在附录 C 图 C2 中展示各算法的绝对误差全概率分布。

表 1 不同算法的误差评价指标
Table 1 Errors of different methods

模型	I_{MAE1}	I_{MAE2}	I_{RMSE}
MAGAT	0.023	0.376	0.040
GAT	0.049	0.417	0.069
Cubic	0.027	0.478	0.049
BP	0.036	0.472	0.060
MABP	0.032	0.448	0.056
KNN	0.160	0.798	0.205
CNN	0.156	0.782	0.200
MACNN	0.097	0.597	0.138

从表 1 和附录 C 图 C1 可以得出以下结论：

1) 虽然 KNN 模型简单易用，但它绝对误差很大；同时 CNN 由于过于依赖相邻元素的关联关系，且受限于卷积核的设计，同样具有很大的绝对误差。具体来说，KNN 和 CNN 的上四分位数大于 0.3，而 MAGAT 的上四分位数小于 0.1。

2) MAGAT 的最大绝对误差、上四分位数和中位数都要低于 GAT 和 BP。具体来说，GAT 的最大绝对误差、上四分位数和中位数分别为 0.41、0.13 和 0.03，BP 的分别为 0.47、0.11 和 0.02，而 MAGAT 的为 0.37、0.07 和 0.01。

3) MAGAT 和 Cubic 具有相似的上四分位数和中位数，但 MAGAT 的最大绝对误差远小于 Cubic。具体来说，Cubic 的最大绝对误差为 0.47，而 MAGAT 的为 0.37。

4) 模型结构方面，MAGAT、MABP、MACNN 在原神经网络基础上增加了多头注意力机制。在误差指标方面，MAGAT、MABP、MACNN 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 远小于 GAT、BP、CNN，说明 MA 机制能帮助填充模型在不同的表示空间内同时学习不同特征的表征，从而更好地捕捉序列中的重要信息，有效提高了神经网络模型的填充准确率。MAGAT 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 远小于 MABP、MACNN，说明 MA 层与 GAT 层的结合能更有效挖掘已知数据的数据特征。

为直观比较各算法的差异，从测试集中随机选两个样本进行可视化展示，如附录 C 图 C3(a)和(b)所示，样本的时间跨度为半天，即 48 个数据点。

从附录 C 图 C3 可以得出以下结论：

1) KNN 和 CNN 的性能显著低于其他算法，因为它们都难以挖掘特征信息之间的相关性。

2) 在图 C3(a)中，风电功率出现连续缺失的情况，且在缺失时间点前后功率出现剧烈波动，BP 和 Cubic 算法分别预测出谷值和峰值，与真实功率

存在很大差异。相对而言，GAT 和 MAGAT 不仅考虑了风电功率整体的波动特性，还考虑了多个气象因素与风电功率之间的相关性，因此填充的功率值与真实值较为接近。同时与 GAT 相比，MAGAT 的 MA 机制帮助填充模型同时学习不同维度的特征表征，从而更好地适应了连续缺失的极端情况，填充趋势也更趋合于真实数据。

3) 在图 C3(b)中，风电功率缺失点出现在功率波动时间序列中，GAT 由于缺少多头注意力机制，当气象特征变化明显时，对风电功率的填充准确率明显变低；而 MAGAT 由于 MA 机制帮助模型准确捕捉功率时序特征、气象特征等高维特征与待填充功率间的映射关系，所以准确率更高。

为了探索缺失数据比例与数据填充准确率之间的关系，将每个样本中随机缺失数据量比例分别设置为 10%、20%、30% 和 50%。对各种算法进行多次测试，其误差分析结果如附录 C 表 C1 所示。

从附录 C 表 C1 可以得出以下结论：

1) 对不同缺失率，MAGAT 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 总小于其他算法，表明 MAGAT 具有更高的填充精度。具体来说，MAGAT 的 I_{MAE1} 总是小于 0.028， I_{MAE2} 总是小于 0.525， I_{RMSE} 总是小于 0.042；

2) 随着缺失率的增加，三次插值 Cubic 和 BP 神经网络的误差尤其是 I_{MAE2} 和 I_{RMSE} 迅速增加，表明它对数据缺失规模非常敏感，只适用于缺失数据量较小的风电场的数据集。相比之下，GAT 和 MAGAT 充分考虑了多个气象因素与风电功率之间的相关性，填充误差随缺失率增加而缓慢增加，表面它们也适用于高缺失率的数据集。

3.3 连续缺失类型数据算例分析

由于网络故障或通信拥堵，风电功率数据可能会出现连续缺失。为测试所提出的风电场连续缺失数据填充方法的性能，将每个样本中连续缺失数据量比例分别设置为 10%、20%、30% 和 50%。对各种算法进行多次测试，其误差分析结果见附录 C 表 C2。

从表附录 C 表 C2 可以得出以下结论：

1) 当缺失率为 10% 时，MAGAT 和 GAT 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 远小于其他算法，说明这两种算法填充风电功率连续缺失的数据效果更好。而 MAGAT 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 都小于 GAT，说明 MA 机制多层注意力的特殊网络结构帮助模型有效学习多维度的特征表征，提高了模型的鲁棒性。

2) KNN 和 CNN 算法的填充效果远差于其他算法。当缺失率增加时，MAGAT、GAT、BP 和 Cubic 的填充误差明显增大，尤其是 Cubic，说明

Cubic 对连续缺失数据的缺失率也非常敏感。当缺失率为 50% 时, Cubic 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 都远高于其他算法, 说明三次插值的方法不适用于填充风电场连续缺失的功率数据。

3) MAGAT 的数据填充误差小于其他算法, 这在高缺失率场景下尤为明显, 这表明它比其他算法更适用于填充风电场连续缺失的功率数据。

为直观比较各算法的差异, 从测试集中随机选取缺失率为 10% 的样本进行可视化展示, 如图 5 所示, 该样本的时间跨度为半天, 即 48 个数据点。

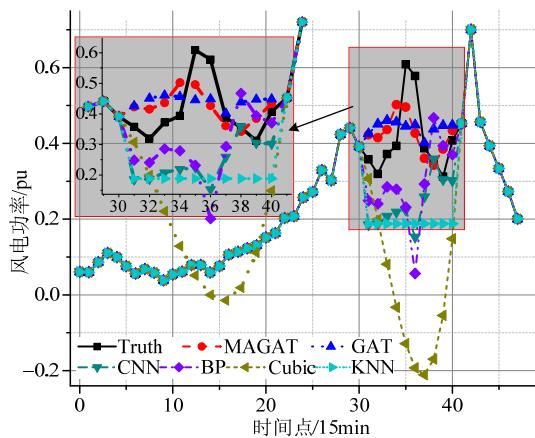


图 5 不同算法的修补情况

Fig. 5 Recovery of different methods

从图 5 可以得出以下结论:

1) 当风电功率发生连续缺失时, KNN 和 Cubic 由于没有挖掘特征信息之间的相关性, 风电场功率填充效果很差; CNN 和 BP 在填充数据缺失中间时间段的数据时, 由于缺乏可以参考的临近时间点的功率, 填充效果较差。

2) GAT 和 MAGAT 由于能充分挖掘特征信息之间的相关性, 能一定程度上拟合出真实功率变化趋势。而对于一些功率峰值和谷值的缺失, MAGAT 的填充效果更好, 说明 MA 机制多层注意力机制的网络结构帮助模型更好地挖掘了不同特征对待填充功率的敏感性, 因而在峰谷值等较为极端的场景填充效果更好。

3.4 横向缺失类型数据算例分析

由于网络故障或通信拥堵, 风电场采集的气象数据也可能出现完全缺失的情况, 此时模型的可用信息将完全来源于历史功率。为了测试 MAGAT 模型在数据发生横向缺失时的填充性能, 将每个样本中横向缺失数据量的比例分别设置为 10%、20%、30% 和 50%。对各种算法进行多次测试, 其误差分析结果如附录 C 表 C3 所示。

从附录 C 表 C3 可以得出以下结论:

1) 与附录 C 表 C2 相比, 除 Cubic 法及 KNN

外, 其余算法的填充误差都有所增大, 尤其是当缺失率较高时, 填充误差大幅度增大, 说明当数据发生极端横向缺失时, 模型仅能挖掘历史功率的特征信息, 可利用的特征信息减少, 导致模型填充误差增大, 而当缺失率增大时, 历史功率可挖掘特征信息也大幅度减少, 导致模型填充误差大幅度增大; 而 Cubic 法及 KNN 仅需要利用历史功率数据, 因此填充误差与附录 C 表 C2 几乎相同。

2) 对于不同的缺失率, 除 Cubic 法外, MAGAT 的 I_{MAE1} 、 I_{MAE2} 、 I_{RMSE} 总是小于其他算法, 这表明 MAGAT 具有更高的填充精度。与 GAT 相比, 在横向缺失的极端条件下, MA 机制最大程度提高了 MAGAT 的鲁棒性, 填充误差远小于 GAT。

3) 与 Cubic 法相比, 当缺失率较低时(10%、20%), MAGAT 的 I_{MAE1} 、 I_{RMSE} 与 Cubic 几乎相同, 但 MAGAT 的 I_{MAE2} 远小于 Cubic, 说明 MAGAT 的填充效果更好; 当缺失率较高时(30%、50%), 除 Cubic 法外, 所有算法的填充误差都相对较大, 已无法准确完成数据填充任务。实际上, 在实际工程中一份完整的数据库数据不大可能出现如此高缺失率的横向缺失。而如果在比较密集的时间段发生了频繁的横向缺失, 可以考虑使用 Cubic 法完成功率数据填充或丢弃该部分数据, 其余数据依然使用 MAGAT 法完成填充。

3.5 数据填充质量对风电功率预测影响算例分析

为了验证数据填充质量对风电功率预测的重要性及本文所提风电场功率缺失数据填充方法的有效性, 本文分别使用填充前、插值法填充、MAGAT 填充的数据集对较为常见的预测算法进行训练, 并对比测试其风电功率预测效果。

本算例为超短期风电功率预测任务, 即预测未来 15min 的风电功率。本算例使用的数据集与 3.2 和 3.3 节中的数据集相同, 数据颗粒度为 15min, 设定风电场功率数据的缺失比例为 10%, 同时结合插值法填充后、MAGAT 填充后的数据集对 LSTM^[23]、随机森林(random forest, RF)^[24]、BP^[25]3 种预测算法进行训练, 使用训练好的模型在测试集中进行多次测试, 其准确率如表 2 所示。其中准确率的计算方法见式(15)。

表 2 不同模型的预测准确率

Table 2 Prediction accuracy of different models

模型	$I_{acc}/\%$		
	数据集 1	数据集 2	数据集 3
LSTM	78.30	79.88	82.33
RF	83.15	84.93	84.97
BP	84.68	85.43	87.91

表2中,数据集1、2、3分别表示缺失比例为10%的数据集、插值法填充后的数据集、MAGAT填充后的数据集。从表2可以得出以下结论:

1) LSTM、RF、BP这3个预测模型在基于插值法和基于MAGAT填充后的数据集上的预测准确率都要高于填充前的数据集。说明风电数据质量对风电功率预测模型的预测准确率存在一定影响,且数据质量越高,预测准确率越高。

2) LSTM、RF、BP这3个预测模型在基于MAGAT填充后的数据集上的预测准确率都要高于在基于插值法填充后的数据集上的预测准确率。充分说明了本文所提风电场功率缺失数据填充方法对于提高风电预测准确率的有效性。

为直观地比较数据质量对各算法的影响,从测试集中随机选取预测算法在填充前数据集及基于MAGAT填充后的数据集上的预测样本展示如图6所示,样本时间跨度为半天,即48个数据点。

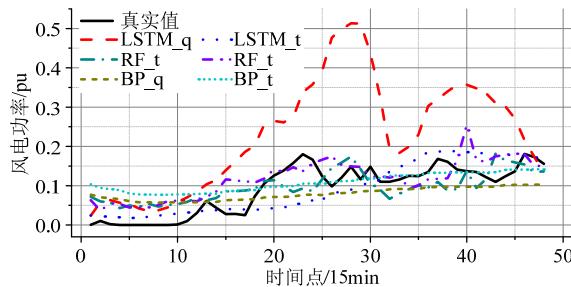


图6 不同算法的预测情况

Fig. 6 Prediction performance of algorithms

图6中:LSTM_q表示LSTM模型在填充前数据集上的预测曲线;LSTM_t表示LSTM模型在基于MAGAT填充后的数据集上的预测曲线;其他曲线以此类推。

从图6可以得出以下结论:3种不同算法在基于MAGAT填充后的数据集上的预测曲线拟合程度都要好于填充前数据集上的预测曲线,且LSTM模型在填充前数据集上的预测出现了明显偏差的情况,这从微观上体现了风电场数据质量对风电预测具有重要意义。

4 结论

风电场数据质量对风电预测具有重要意义。本文为了提高风电场功率缺失数据的填充准确率,提出了基于MAGAT的数据特征表达与挖掘框架,并在真实风电数据集上进行多次测试,从而得出以下结论:

1)与传统的特征表征形式相比,本文所提包含时序功率和外源数据的异质图构建方法,能更有效表征风电场多源数据之间的时序特征和异质特

征,同时更充分刻画了已知数据和缺失数据之间的关联关系,并能在模型训练过程中不断优化更新这种表征形式。同时本文所提的多源特征表征形式还能扩展到其他基于数据驱动的任务。

2)本文所提基于MAGAT的风电场功率缺失数据填充方法,填充效果明显比传统填充方法好,表明了本文所提方法的优异性。同时随着缺失比例的增加,本文所提方法的填充效果具有一定稳定性,表明该方法同样适用于缺失比例较大的数据集。

3)风电场数据质量对风电预测具有重要意义。数据质量越高,风电功率预测模型的预测准确率往往越高。因此,本文所提风电场功率缺失数据填充方法具有重要意义。

MAGAT模型的数据填充不仅限于风电场功率缺失场景,后续会推广到风电场气象缺失数据的填充、电力负荷缺失数据的填充等场景进行研究。

附录见本刊网络版(<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

参考文献

- [1] 周孝信,陈树勇,鲁宗相,等.能源转型中我国新一代电力系统的技术特征[J].中国电机工程学报,2018,38(7): 1893-1904.
ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al. Technology features of the new generation power system in China[J]. Proceedings of the CSEE, 2018, 38(7): 1893-1904(in Chinese).
- [2] 张淑清,杜灵韵,王册浩,等.基于格拉姆角场与改进CNN-ResNet的风电功率预测方法[J].电网技术,2023,47(4): 1540-1547.
ZHANG Shuqing, DU Lingyun, WANG Cehao, et al. Wind power forecasting method based on GAF and improved CNN-ResNet[J]. Power System Technology, 2023, 47(4): 1540-1547(in Chinese).
- [3] 朱倩雯,叶林,赵永宁,等.风电场输出功率异常数据识别与重构方法研究[J].电力系统保护与控制,2015,43(3): 38-45.
ZHU Qianwen, YE Lin, ZHAO Yongning, et al. Methods for elimination and reconstruction of abnormal power data in wind farms [J]. Power System Protection and Control, 2015, 43(3): 38-45(in Chinese).
- [4] 娄建楼,胥佳,陆恒,等.基于功率曲线的风电机组数据清洗算法[J].电力系统自动化,2016,40(10): 116-121.
LOU Jianlou, XU Jia, LU Heng, et al. Wind turbine data-cleaning algorithm based on power curve[J]. Automation of Electric Power Systems, 2016, 40(10): 116-121(in Chinese).
- [5] 陈伟,吴布托,裴喜平.风电机组异常数据预处理的分类多模型算法[J].电力系统及其自动化学报,2018,30(4): 137-143.
CHEN Wei, WU Butuo, PEI Xiping. Classification multi-model algorithm for abnormal data preprocessing in wind turbines[J]. Proceedings of the CSU-EPSA, 2018, 30(4): 137-143(in Chinese).
- [6] HU Yang, QIAO Yilin, LIU Jizhen, et al. Adaptive confidence boundary modeling of wind turbine power curve using SCADA data and its application[J]. IEEE Transactions on Sustainable Energy, 2019, 10(3): 1330-1341.
- [7] 邹同华,高云鹏,伊慧娟,等.基于Thompson tau-四分位和多点插值的风电功率异常数据处理[J].电力系统自动化,2020,44(15): 156-162.
ZOU Tonghua, GAO Yunpeng, YI Huijuan, et al. Processing of wind

- power abnormal data based on Thompson tau-quartile and multi-point interpolation[J]. Automation of Electric Power Systems, 2020, 44(15): 156-162(in Chinese).
- [8] DU Jianghan, HU Minghua, ZHANG Weining. Missing data problem in the monitoring system: a review[J]. IEEE Sensors Journal, 2020, 20(23): 13984-13998.
- [9] LI Tie, TANG Junci, JIANG Feng, et al. Fill missing data for wind farms using long short-term memory based recurrent neural network[C]//Proceedings of 2019 IEEE 3rd International Electrical and Energy Conference. Beijing, China: IEEE, 2019: 705-709.
- [10] 余晓霞, 汤宝平, 王伟影, 等. 复杂工况条件下多头注意力双向长短时记忆网络的风电机组缺失数据修复方法研究[J]. 机械工程学报, 2023, 59(14): 1-9.
- YU Xiaoxia, TANG Baoping, WANG Weiying, et al. Repairing deteriorated data of wind turbines by multi-head attention bi-directional long short time memory networks under complex working conditions[J]. Journal of Mechanical Engineering, 2023, 59(14): 1-9(in Chinese).
- [11] 吴永斌, 张建忠, 袁正飚, 等. 风电场风功率异常数据识别与清洗研究综述[J]. 电网技术, 2023, 47(6): 2367-2379.
- WU Yongbin, ZHANG Jianzhong, YUAN Zhengxi, et al. Review on identification and cleaning of abnormal wind power data for wind farms[J]. Power System Technology, 2023, 47(6): 2367-2379(in Chinese).
- [12] 王守相, 郭陆阳, 赵倩宇, 等. 基于参考序列与全卷积网络的风速数据缺失与异常修复方法[J]. 电力系统自动化, 2023, 47(9): 129-136.
- WANG Shouxiang, GUO Luyang, ZHAO Qianyu, et al. Repair method for missed and abnormal wind speed data based on reference sequence and full convolution network[J]. Automation of Electric Power Systems, 2023, 47(9): 129-136(in Chinese).
- [13] LIAO Wenlong, BAK-JENSEN B, PILLAI J R, et al. Data-driven missing data imputation for wind farms using context encoder[J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(4): 964-976.
- [14] WU Zonghan, PAN Shirui, LONG Guodong, et al. Connecting the dots: multivariate time series forecasting with graph neural networks [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. ACM, 2020: 753-763.
- [15] ZHAO Ling, SONG Yujiao, ZHANG Chao, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [16] DONG Yanni, LIU Quanwei, DU Bo, et al. Weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification[J]. IEEE Transactions on Image Processing, 2022, 31: 1559-1572.
- [17] ISLAM M, IQBAL T. Multi-GAT: a graphical attention-based hierarchical multimodal representation learning approach for human activity recognition[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 1729-1736.
- [18] HUANG Kun, LI Xiaoming, LIU Fangyuan, et al. ML-GAT: a multilevel graph attention model for stock prediction[J]. IEEE Access, 2022, 10: 86408-86422.
- [19] 徐健, 刘长良, 王梓齐, 等. 基于缺失数据填补的风电齿轮箱状态监测研究[J]. 仪器仪表学报, 2022, 43(9): 88-97.
- XU Jian, LIU Changliang, WANG Ziqi, et al. Research on condition monitoring of wind turbine gearbox based on missing data imputation[J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 88-97(in Chinese).
- [20] TIHON S, JAVAID M U, FOURURE D, et al. DAEMA: denoising autoencoder with mask attention[C]//Proceedings of the 30th International Conference on Artificial Neural Networks. Bratislava: Springer, 2021: 229-240.
- [21] 贾旭东, 王莉. 基于多头注意力胶囊网络的文本分类模型[J]. 清华大学学报(自然科学版), 2020, 60(5): 415-421.
- JIA Xudong, WANG Li. Text classification model based on multi-head attention capsule networks[J]. Journal of Tsinghua University (Science & Technology), 2020, 60(5): 415-421(in Chinese).
- [22] 翟一鸣, 王斌君, 周枝凝, 等. 面向文本分类的多头注意力池化 RCNN 模型[J]. 计算机工程与应用, 2021, 57(12): 155-160.
- ZHAI Yiming, WANG Binjun, ZHOU Zhining, et al. Multi-head attention pooling-based RCNN model for text classification[J]. Computer Engineering and Applications, 2021, 57(12): 155-160(in Chinese).
- [23] 何锦华, 刘洋, 朱誉, 等. 融合物理信息的 TPA-LSTM 网络应用于台风条件下海上风电场风速多步预测[J]. 电网技术, 2023, 47(10): 4152-4160.
- HE Jinhua, LIU Yang, ZHU Yu, et al. Physics-informed TPA-LSTM network applied to multi-step wind speed prediction of offshore wind farms under typhoon conditions[J]. Power System Technology, 2023, 47(10): 4152-4160(in Chinese).
- [24] 贡益, 高志球, 韩威. 基于 RF 和 GRU 组合算法的超短期风电功率预测[J]. 中国科技论文, 2020, 15(9): 987-992.
- SHANG Yi, GAO Zhiqiu, HAN Wei. Ultra-short-term wind power forecasting based on RF and GRU network[J]. China Sciencepaper, 2020, 15(9): 987-992(in Chinese).
- [25] 刘芳, 汪震, 刘睿迪, 等. 基于组合损失函数的 BP 神经网络风力发电短期预测方法[J]. 浙江大学学报(工学版), 2021, 55(3): 594-600.
- LIU Fang, WANG Zhen, LIU Ruidi, et al. Short-term forecasting method of wind power generation based on BP neural network with combined loss function[J]. Journal of Zhejiang University (Engineering Science), 2021, 55(3): 594-600(in Chinese).



卢冠华

在线出版日期: 2024-06-28。

收稿日期: 2023-11-10。

作者简介:

卢冠华(1998), 男, 硕士研究生, 主要研究方向为深度学习在源荷多时间尺度预测的机理及应用, E-mail: 493099612@qq.com;

余涛(1974), 男, 工学博士, 教授, 主要从事复杂电力系统的非线性控制理论和仿真方面的研究工作, E-mail: taoyu1@scut.edu.cn;

吴毓峰(1998), 男, 博士研究生, 主要研究方向为人工智能技术在电力系统中的应用、电力系统优化运行与控制, E-mail: wuyuffeng@163.com;

潘振宁(1994), 男, 通信作者, 博士, 博士后, 主要研究方向为人工智能技术在电力系统中的应用、电力系统优化运行与控制, E-mail: panzhenning@scut.edu.cn;

陈俊斌(1992), 男, 博士研究生, 主要研究方向为人工智能在电力系统优化运行中的应用, E-mail: junbin0617@outlook.com;

邓柏荣(1999), 男, 硕士研究生, 主要研究方向为人工智能技术在电力系统中的应用, E-mail: dengbairong0610@foxmail.com。

(责任编辑 王金芝)

附录 A

文中数学模型所出现的变量符号具体定义如表 A1 所示。

表 A1 文章公式符号定义
Table A1 Formula symbol definition of paper

符号	符号定义
$X; X'; X''_x$	初始特征矩阵；MA 层更新后的特征矩阵；GAT 层更新后的特征矩阵；特征矩阵中的元素
$C^T; C$	时序边初始权重矩阵；更新后的连接边权重矩阵
$W^R; W^{R'}; W^C;$ $W^D; b^D; A$	神经网络内部可训练矩阵
$R; R'; R''$	MA 层初始及更新后的注意力系数矩阵
$P; P'; P''; P_b$	风电场功率；模型填充功率；模型预测功率；风电场开机容量的 20%

附录 B

为确定式(1)中比例因子 σ 的大小，采用 $I_{\text{MAE}1}$ 、 $I_{\text{MAE}2}$ 、 I_{RMSE} 这 3 种评价指标分析不同大小比例因子 σ 下的风电功率数据填充效果，评价指标公式见式(12)—(14)。风电功率数据缺失类型设置为随机缺失，缺失比例设置为 10%，根据不同比例因子大小 σ 得到的风电功率填充指标，展示其拟合曲线如图 B1 所示。

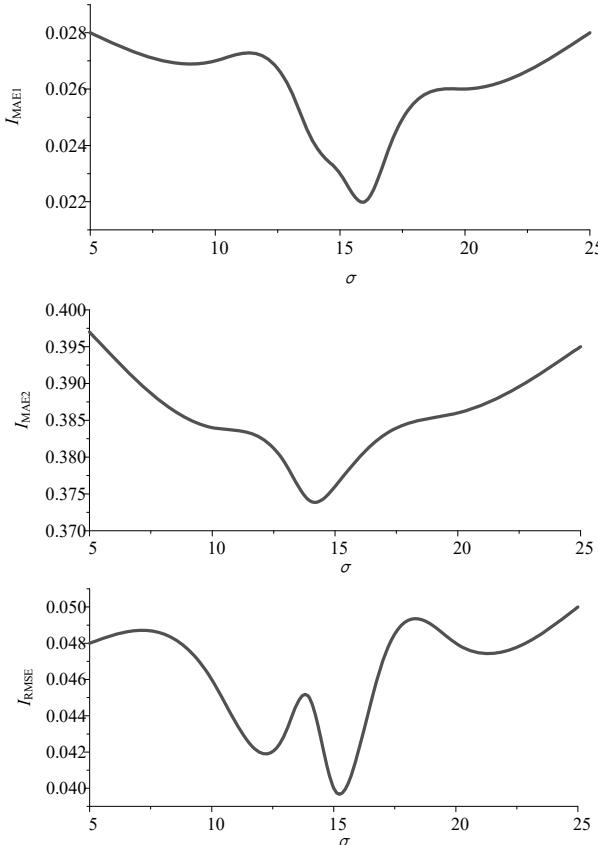


图 B1 不同大小比例因子 σ 下风电功率填充误差

Fig. B1 Different scaling factors σ lower wind power filling error

分析图 B1 算例结果可知，当比例因子 σ 的大小在 13~17 之间时，风电功率填充误差最小；而当比例因子 σ 的大小接近 5 或接近 25 时，填充误差增加。由式(1)可知，当比例因子 σ 的大小太小或太大时，所计算得到的时序边初始权重大小会出现过小或过大的情况，导致时序特征间的权重差距不明显或过于明显，因此填充误差较大。但此算例结果还不能找到使填充模型填充效果最优的比例因子 σ 的大小。

表 B1 不同大小比例因子 σ 下风电功率填充指标
Table B1 Different scaling factors σ lower wind power filling error

σ	$I_{\text{MAE}1}$	$I_{\text{MAE}2}$	I_{RMSE}
13	0.026	0.379	0.043
14	0.024	0.374	0.045
15	0.023	0.376	0.040
16	0.022	0.380	0.042
17	0.024	0.383	0.047
18	0.026	0.379	0.043

为确定最优的比例因子 σ 大小，在同样的缺失情况下，比例因子大小 σ 分别设置为 13、14、15、16、17，不同大小比例因子 σ 下风电功率填充指标见表 B1。

分析表 B1 无法直接选出最优大小的比例因子 σ ，故规定指标在 5 种比例因子 σ 下最优时可得 5 分，最差时可得 1 分。按此规则，比例因子 σ 为 13、14、15、16、17 的得分依次为 7、10、13、11、5，故比例因子 σ 大小为 15 时的填充效果最优。

但超参数的确定并非是文章讨论的重点， $\sigma=15$ 仅是效果较好的选择，而不可确定为 MAGAT 的最优 σ 值。

附录 C

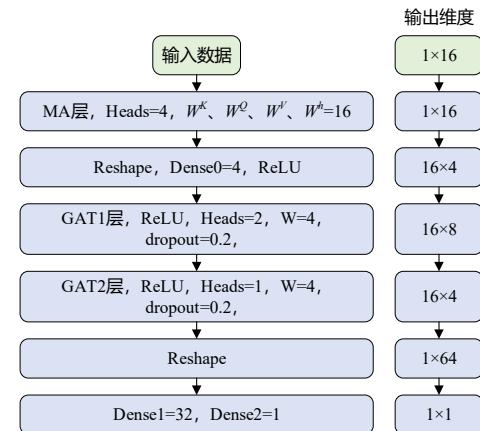


图 C1 MAGAT 的模型参数
Fig. C1 Model parameter of MAGAT

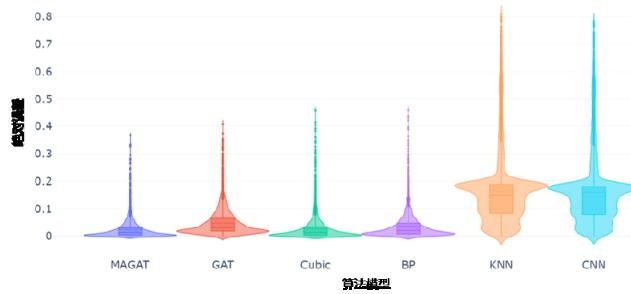


图 C2 不同算法的绝对误差

Fig. C2 Absolute errors of different methods

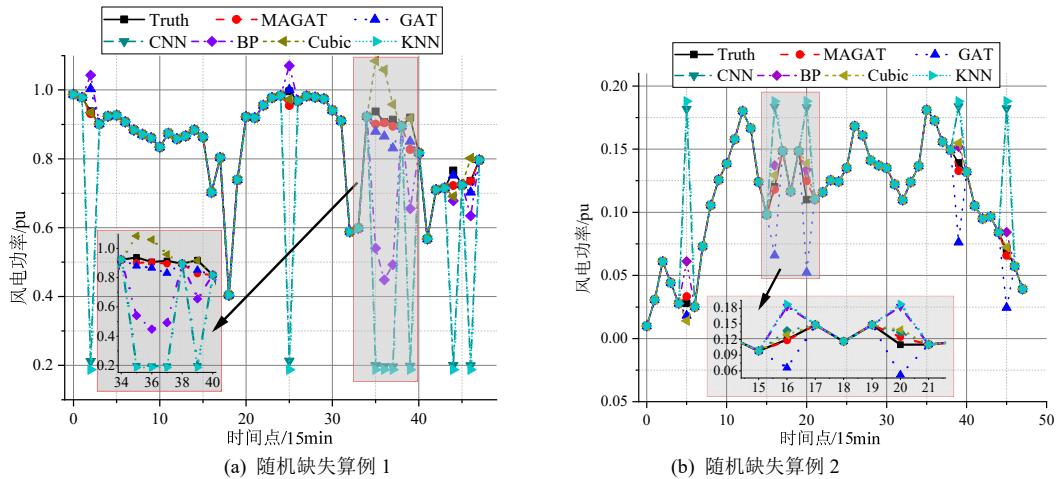


图 C3 不同算法的修补情况

Fig. C3 Recovery of different methods

表 C1 随机缺失不同缺失率下不同算法的误差评价指标

Table C1 Errors of different methods in different loss rate in random loss type

模型/ 误差	缺失率 10%			缺失率 20%			缺失率 30%			缺失率 50%		
	I_{MAE1}	I_{MAE2}	I_{RMSE}									
MAGAT	0.023	0.376	0.040	0.024	0.413	0.041	0.026	0.448	0.042	0.028	0.525	0.042
GAT	0.049	0.417	0.069	0.050	0.434	0.070	0.052	0.489	0.065	0.055	0.562	0.067
Cubic	0.027	0.478	0.049	0.028	0.532	0.053	0.031	0.654	0.058	0.037	0.782	0.066
BP	0.036	0.472	0.060	0.039	0.481	0.066	0.046	0.623	0.070	0.058	0.637	0.083
KNN	0.160	0.798	0.205	0.161	0.808	0.207	0.164	0.811	0.210	0.168	0.820	0.211
CNN	0.156	0.782	0.200	0.157	0.791	0.208	0.160	0.798	0.215	0.162	0.885	0.219

表 C2 连续缺失不同缺失率下不同算法的误差评价指标

Table C2 Errors of different methods in different loss rate in continuous loss type

模型/ 误差	缺失率 10%			缺失率 20%			缺失率 30%			缺失率 50%		
	I_{MAE1}	I_{MAE2}	I_{RMSE}									
MAGAT	0.052	0.603	0.084	0.064	0.644	0.087	0.069	0.685	0.085	0.085	0.772	0.118
GAT	0.058	0.640	0.093	0.080	0.781	0.119	0.093	0.797	0.130	0.109	0.825	0.154
Cubic	0.077	1.199	0.132	0.135	1.829	0.239	0.222	3.031	0.363	0.318	4.919	0.526
BP	0.068	0.741	0.108	0.083	0.829	0.120	0.092	0.897	0.132	0.118	0.951	0.155
KNN	0.164	0.809	0.212	0.166	0.812	0.215	0.170	0.815	0.224	0.174	0.823	0.248
CNN	0.115	0.728	0.146	0.127	0.732	0.157	0.135	0.851	0.170	0.166	0.868	0.188

表 C3 横向缺失不同缺失率下不同算法的误差评价指标

Table C3 Errors of different methods in different loss rate in transverse loss type

模型/ 误差	缺失率 10%			缺失率 20%			缺失率 30%			缺失率 50%		
	I_{MAE1}	I_{MAE2}	I_{RMSE}									
MAGAT	0.026	0.388	0.047	0.029	0.427	0.051	0.043	0.503	0.072	0.058	0.549	0.084
GAT	0.054	0.438	0.073	0.059	0.453	0.078	0.073	0.547	0.086	0.096	0.598	0.102
Cubic	0.028	0.475	0.049	0.029	0.537	0.051	0.031	0.652	0.058	0.039	0.785	0.068
BP	0.046	0.491	0.065	0.054	0.510	0.072	0.071	0.665	0.086	0.098	0.697	0.098
KNN	0.162	0.801	0.207	0.164	0.812	0.209	0.167	0.877	0.213	0.171	0.921	0.215
CNN	0.159	0.788	0.205	0.165	0.800	0.217	0.192	0.853	0.244	0.214	0.908	0.273