

面向光伏用户电压质量指标的注意力机制双流 LSTM-CNN 预测方法

贺星¹, 王智¹, 刘谋海¹, 刘浩², 黄瑞¹, 颜宏文², 颜勤³, 马瑞³

(1. 国网湖南供电服务中心(计量中心), 长沙 410007; 2. 长沙理工大学 计算机与通信学院, 长沙 410015; 3. 长沙理工大学 电气与信息工程学院, 长沙 410114)

摘要: 随着国家双碳战略目标的提出, 分布式光伏迎来新的发展机遇, 对光伏电站的电压质量管理成为关键挑战。文中基于双流 LSTM-CNN(long short-term memory-convolutional neural network)模型, 建立交互层和多特征融合预测模块来实现对光伏用户电压质量指标的预测, 监控各设备在不同时段、相同间隔的运行状态反馈数据, 对数据进行指数移动平均滤波处理来减少噪声的影响, 构建双流 LSTM-CNN 模型进行序列建模, 并引入注意力机制增强对关键特征的关注程度, 最后提出了多特征融合模块, 充分利用来自不同层次的数字信息来丰富结果预测的特征表示, 分别得到 6 个预测头来实现对未来电压闪变、电压波动、电压偏差(电压质量指标)的预测。实验使用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)对模型性能进行评估, 其中电压偏差 MAE 的仿真结果为 0.029 0, 表现出较小的预测误差。实验结果表明, 该方法能够有效地预测低压分布式光伏电压质量的情况, 为低压分布式光伏台区的稳定运行提供重要支持和参考。

关键词: 低压分布式发电; 光伏电站; 电压质量预测; 神经网络; 注意力机制; 特征融合

DOI: 10.19753/j.issn1001-1390.2026.03.013

中图分类号: TM769

文献标识码: A

文章编号: 1001-1390(2026)03-0126-11

Attention mechanism dual-stream LSTM-CNN prediction model for photovoltaic user voltage quality index

HE Xing¹, WANG Zhi¹, LIU Mouhai¹, LIU Jie², HUANG Rui¹, YAN Hongwen², YAN Qin³, MA Rui³

(1. State Grid Hunan Power Supply Service Center (Metering Center), Changsha 410007, China.

2. School of Computer and Communication Engineering, Changsha University of Science and Technology,

Changsha 410015, China. 3. School of Electrical and Information Engineering, Changsha

University of Science and Technology, Changsha 410114, China)

Abstract: With the proposal of the national dual-carbon strategic goal, distributed photovoltaic (PV) ushers in new development opportunities, and the management of voltage quality for photovoltaic power stations becomes a key challenge. Based on the dual flow long short-term memory-convolutional neural network (LSTM-CNN) model, this paper proposes an interaction layer and a multi-feature fusion prediction module to achieve the prediction of photovoltaic user voltage quality indicators. The operating status feedback data of different periods and the same interval is monitored, and the data is filtered by exponential moving average to reduce the influence of noise. The dual-stream LSTM-CNN model for sequence modeling is constructed, with the introduction of attention mechanism aimed at enhancing attention to key features. We propose a multi-feature fusion module, which fully leverages digital information from different levels to enrich the feature representation for prediction. This module consists of six prediction heads, allowing us to predict future voltage fluctuations, voltage variations, and voltage deviations (voltage quality indices). Model performance is evaluated using the mean absolute error (MAE) and the root mean square error (RMSE), where the simulation of voltage deviation MAE is 0.029 0, showing a small prediction er-

基金项目: 国网湖南省电力有限公司科技项目(5216AG220007)

ror. The experimental results demonstrate that the proposed method can effectively predict the voltage quality of low voltage distributed PV, and provide important support and reference for the stable operation of low voltage distributed PV platform area.

Keywords: low-voltage distributed generation, photovoltaic power station, voltage quality prediction, neural network, attention mechanism, feature fusion

0 引言

低压分布式光伏电站在实现清洁能源转型中具有重要的地位和作用,分布式光伏领域也正迎来新的发展与挑战^[1-2]。然而,随着光伏发电量在电力系统中的比例不断增加,光伏电站接入电网后可能引发电压质量问题,这些问题包括电压闪变、电压波动和电压偏差,其中电压闪变是指电压在短时间内快速波动的现象,通常由突然的负载变化引起;电压波动是电压在一段时间内的连续波动,通常由光伏电站或其他因素引起;电压偏差是指电压与标准电压之间的差异,可能导致设备故障或电能质量问题。再超出国家相关标准后引发电压质量问题,那可能导致设备性能下降或电力质量下降^[3],电力设备和系统产生不利影响,因此快速、准确的监测预测光伏电站接入电网后的电压质量指标情况变得尤为重要。

电压质量指标(电压闪变、电压波动、电压偏差)的预测方法可以分成统计方法、时间序列分析和深度学习方法^[4-5]。统计方法是使用历史数据的统计均值、方差、标准差来进行预测,但不适用于电压闪变中捕捉短期和复杂的波动,对突变信息的处理较差。时间序列分析使用时间序列模型如 ARIMA 自回归移动平均模型,以历史数据中的时间信息来预测未来的电压质量指标,适用于考虑时间相关性的预测,可以捕捉季节性和趋势^[6]。深度学习方法使用深度学习模型如循环神经网络或卷积神经网络,可以自动捕捉时间序列数据中的复杂模式和关联性^[7],可以挖掘数据的深层特征,在电压质量指标预测中得到广泛应用。传统的预测方法如统计模型^[8]和随机森林^[9],在处理动态数据和实时性方面存在局限性。它们往往无法适应数据流的变化和实时预测的要求。文献[10]利用自适应经验小波分解算法解决外部影响因素对电力系统负荷数据的非平稳性,并采用卷积神经网络、双向长短期记忆(convolutional neural network bidirectional long short-term memory, CNNBiLSTM)网络模型训练进行负荷预测。文献[11]利用熵权灰色关联分析法筛选出影响光伏发电功率的主要因素,采用改进

后的黏菌算法对模型的参数进行优化,并建立了光伏发电功率预测模型。文献[12]在传统的 LSTM(long short-term memory-convolutional)网络的中引入注意力层,构造不同工况下的 LSTM 子模型,并将 CNN(convolutional neural network)输出的软分类标签作为初始权值,使用遗传算法对权值偏置进行搜索寻优,相较于单一模型,组合模型具有更小的误差。

为了充分利用数据信息,提高光伏电压质量指标的预测精度,文章特别关注了光伏电流和功率对电压质量的潜在影响,先对低压光伏电站历史发电功率进行指数移动平均滤波预处理,并提出构建不同于单网络模型的双流分支网络 LSTM-CNN-ATT(long short-term memory-convolutional neural network-attention mechanism)进行序列建模,引入注意力机制^[13]增强对关键特征的关注程度,提出了多特征融合模块丰富结果预测的特征表示,实现对未来电压质量指标情况的预测。以更全面地理解光伏电站接入电网后电压质量的特征和趋势。

1 基于 LSTM-CNN 的预测模型

1.1 CNN 网络

CNN 模型^[11]拥有对局部特征的有效提取和对平移不变性的建模能力,由卷积层、池化层和全连接层构成,可以自动学习数据中的特征并建立对应的特征量。在卷积层中,CNN 模型使用滤波器(也称为卷积核)来对输入数据进行局部感知,并提取出其中的局部特征。滤波器通过与输入数据进行卷积操作,计算得到新的特征映射。通过多个滤波器的组合,CNN 模型能够同时提取出多个不同的局部特征,并对其进行学习和展示。

1.2 LSTM 网络

LSTM^[10]是一种常用于处理序列数据的循环神经网络结构,相比于传统 RNN(recurrent neural network)结构,能够更好地处理长期依赖关系,从而在处理序列数据时具有更好的性能和表现。

在每个时间步,LSTM 接收输入序列,并利用当前输入和前一时刻的隐藏状态来计算各个门控单元的输出和细胞状态的更新。遗忘门 f_t 控制单元

状态的遗忘程度,决定上一时刻中哪些信息需要被遗忘。输入门 i_t 用于控制新输入对单元时间状态的更新程度。输出门 O_t 决定了单元时间状态如何影响当前时刻的隐藏状态和输出结果。细胞状态 C_t 通过遗忘门和输入门来决定何时遗忘过去的信息并更新信息。隐藏状态 h_t 用于存储和传递模型对输入序列的信息。其中计算如式(1)~式(6)所示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

$$C_{-t} = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C_{-t} \quad (5)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (6)$$

式中: W_f 是输入值 X_t 与遗忘门的权重矩阵; b_f 是遗忘门的偏置向量; σ 表示 sigmoid 激活函数; \tanh 为双曲正切激活函数; C_t 为 t 时刻候选单元状态。将输入的加权和映射到 $0 \sim 1$ 之间的概率值。激活值越接近 0 ,表示对应位置上的信息更容易被遗忘或对数据更新没有贡献;激活值越接近 1 ,表示对应位置上的信息更容易保留。

1.3 注意力机制

注意力机制^[14]可以捕捉到数据时更加关注重要的信息,通过计算注意力权重来选择性地强调关键部分,提高模型的感知能力。其次,注意力机制能够捕捉输入序列中不同层次之间的关系、建模不同时间步或特征通道之间的相关性,从而更好地理解序列数据的复杂关联。此外,还能够提升模型的性能,减少无关信息的干扰,从而更准确地预测目标变量,通过分析注意力权重来理解模型对不同部分的关注程度,为模型的决策提供解释并增强可解释性。综上所述,注意力机制在处理序列数据和进行任务预测时具有重要的优势和应用价值。

2 基于注意力机制和 LSTM-CNN 的低压光伏电压质量指标预测模型设计

在本章节中,考虑到模型的泛化能力、过拟合和整体训练效率问题,提出了基于注意力机制和 LSTM-CNN 的低压光伏电压质量指标预测模型设计。接下来将详细介绍基于 LSTM-CNN 网络来特征提取,再引入交互层增强对关键特征的关注程度,最后设计多特征融合预测模块的设计原理。旨在构建一个全面而高效的预测模型,综合考虑了数

据的空间和时间特征,并通过注意力机制和多特征融合实现了更准确的电压质量指标的预测。

2.1 模型分支 1:CNN

将分布式光伏接入功率和电流作为网络的输入数据,主干模型由双流网络组成(见图 1)。为了将这些多维度的数据输入到模型中,首先需要和数据进行预处理和转换,在一个训练批次中,将输入数据记为 $I \in \mathbb{R}^{B \times S \times D}$,其中 B 表示批次大小, S 表示数据序列的长度, D 表示数据的维度,在实验中, $B = 32, S = 32, D = 5$ 。

针对图 1 分支 1 的 CNN 网络,将输入数据 I 重组以后得到 $B \times 1 \times L$ 维度的新数据(其中 $L = SD$, SD 表示将原始输入数据的每个样本重组成为一个新的向量)。然后经过由 4 个卷积层和 2 个池化层组成的 CNN 模。如表 1 所示。输入数据经过一维批量归一化层(BN)进行标准化,以提高训练的稳定性和收敛速度。通过不同的一维卷积层(Conv1d)进行特征提取。每个卷积层具有不同数量的卷积核,卷积核的大小(K)、填充(P)和通道数(C)也不同。这些卷积核在输入数据上滑动,从中提取出不同特征。同时,每个卷积层后跟一个 LeakyReLU 激活函数,引入非线性有助于模型学习复杂的模式和特征。通过一维最大池化 MaxPool,特征图的尺寸被减小,同时保留了最重要的特征,有助于降低计算复杂度。最终我们能得到输出维度为 $B \times C \times N$ 的向量,其中 $C = 32, N = 10$ 。经过重组操作后最终能得到 CNN 分支的特征输出 $X^l \in \mathbb{R}^{B \times N \times C}$ 。

表 1 CNN 分支每层具体操作

Tab. 1 CNN branch each layer specific operations

层数	组成	K, P, C	输出
1	BN + Cov1D + LeakyReLU	11, 5, 32	$B \times 32 \times L$
2	BN + Cov1D + LeakyReLU	11, 5, 64	$B \times 64 \times L$
3	BN + MaxPool	—	$B \times 64 \times L/4$
4	Cov1D + LeakyReLU	3, 1, 128	$B \times 128 \times L/4$
5	BN + Cov1D + LeakyReLU	3, 1, 32	$B \times 32 \times L/4$
6	MaxPool + Dropout	—	$B \times 32 \times L/16$

2.2 模型分支 2:LSTM

如图 1 分支 2 所示,LSTM 网络内部包含 2 个 LSTM 单元,每个 LSTM 单元都具有内部状态,如隐藏状态和细胞状态。首先,对于输入数据 $I \in \mathbb{R}^{B \times S \times D}$,应用线性变换,将每个时间步的 D 维特征映射到一个更高维度的空间,产生 $B \times S \times H$ 。

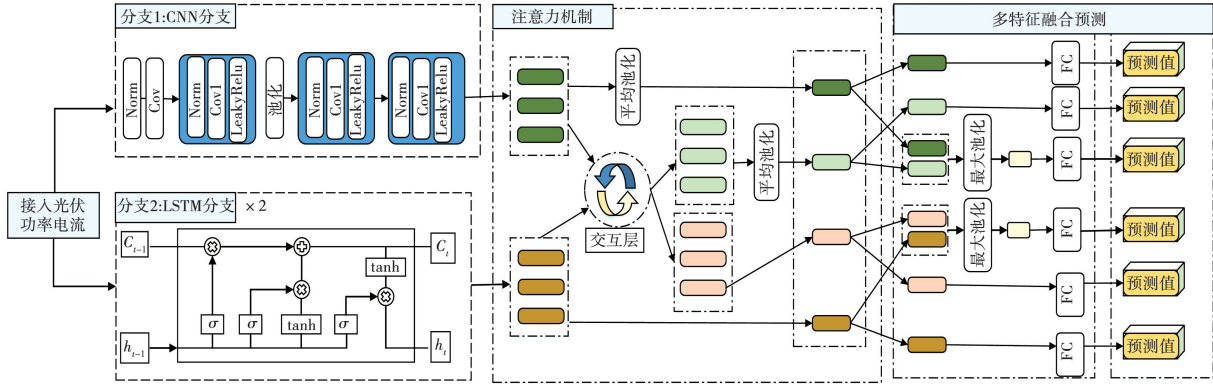


图 1 基于注意力机制的 LSTM-CNN 模型结构图

Fig. 1 Structure diagram of LSTM-CNN model combined with attention mechanism

H 表示隐藏状态的维度, $H = 32$) 的输出。在每个时间步, LSTM 单元将前一时间步的隐藏状态和细胞状态作为输入, 并结合当前时间步的输入数据进行计算。这个操作会在每个 LSTM 单元内部执行, 但是在整个序列中会重复多次。每个时间步 LSTM 单元将生成一个新的隐藏状态, 具有相同的维度, 即 $B \times S \times H$ 。这个隐藏状态包含了对过去信息的编码以及对当前输入的处理结果; 还将生成一个细胞状态, 与隐藏状态维度相同, 即 $B \times S \times H$ 。可以使用 LSTM 的隐藏状态作为网络的最终输出是 $X^l \in \mathbb{R}^{B \times S \times C}$, C 表示最终的输出特征维度。

2.3 交互层: 融合注意力机制

双流分支后的两个没有经过全连接处理的输出结果, 经过 LSTM 流后得到的特征向量为 $X^l \in \mathbb{R}^{B \times N \times C}$, 经过 CNN 流后经过得到的特征向量为 $X^c \in \mathbb{R}^{B \times S \times C}$ 。在之后, 这两个向量会通过交互层进行交叉注意力处理, 将不同的特征分别看作查询(Q)、键(K)和值(V)。如图 2 左所示, 将 X^{cmm} 经过 Norm 处理得到 Q_c , X^l 经过 Norm 处理分别得到 K_l 和 V_l 。接下来我们将这三个向量经过交叉注意力计算。

首先需要计算查询和键之间的相似度, 通过点积注意力相似度方法来实现, 如式(7)所示:

$$A = \text{Attention}(Q_c, K_l) = \text{softmax}(Q_c K_l^T / \sqrt{d}) \quad (7)$$

式中: Q_c 表示查询矩阵; K_l 表示键矩阵; d 表示特征向量的维度。通过将查询和键进行点积操作, 并除以特征维度的平方根, 可以得到归一化的相似度矩阵 A 。接下来, 将计算得到的相似度矩阵 A 与值 V_l 进行处理, 如式(2)所示, 得到的注意力加权的值矩阵。

$$\bar{X}^c = AV_l \quad (8)$$

将注意力加权的值传入前馈网络 (multi-layer perceptron, MLP)。在前馈网络中, 如式(9)所示, 进一步进行一系列线性组合和非线性变换。

$$\tilde{X}^c = \text{MLP}(\bar{X}^c) \quad (9)$$

相似地, 可以得到在交互层进行相同处理的特征向量 \tilde{X}^l 。通过交互层处理与双流分支特征处理最终可以得到来自不同深度与不同分支的特征信息。

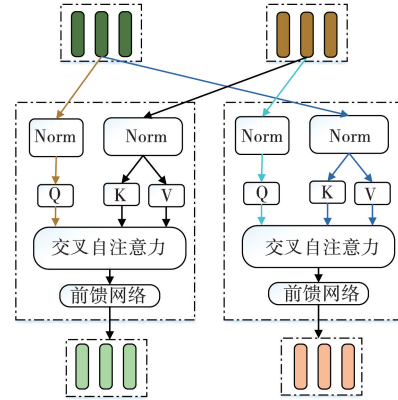


图 2 注意力机制的结构图

Fig. 2 Structural diagram of the attention mechanism

2.4 多特征融合预测

提出了多特征融合模块, 充分地利用来自不同层次和来源的数字信息, 以丰富结果预测的特征表示。该模块将各种特征整合为一个综合的特征集, 如图 1 多头预测模块所示, 包括经过不同处理方法获得的 6 个关键特征。具体为经过分支 1 的特征 X^l 、经过分支 2 的特征 X^c 、在交互层进行交叉注意力机制得到的特征 \tilde{X}^c 、 \tilde{X}^l , 以及处理不同的输入特征, 如式(10)和式(11)所示, 提取最大值特征。

$$\hat{X}^c = \max(\tilde{X}^c, \bar{X}^c) \quad (10)$$

$$\hat{X}^l = \max(\tilde{X}^l, \bar{X}^l) \quad (11)$$

这样便得到了进行结果预测的 6 个特征信息,

分别是 $X^c, \tilde{X}^c, \hat{X}^c, X^l, \tilde{X}^l$ 和 \hat{X}^l 。在训练阶段,我们假设特征向量 $V^c \in \{X^c, \tilde{X}^c, \hat{X}^c\}, V^l \in \{X^l, \tilde{X}^l, \hat{X}^l\}$,分别对此向量进行不同的处理。对于 V^c ,经过最大池化层和分类器后,如式(12)所示,最后能得到 $p^c \in \mathbb{R}^{B \times 1}$ 用于预测最终值。

$$p^c = \text{FC}(\text{maxpool}(V^c)) \quad (12)$$

对于 V^l ,则获取第一个下标的向量,经过线性层后,如式(13)所示,最后能得到 $p^l \in \mathbb{R}^{B \times 1}$ 用于预测最终值。

$$p^l = \text{FC}(V_1^l) \quad (13)$$

通过以上两个公式,最终能得到 6 个预测结果 $\{p^c, \tilde{p}^c, \hat{p}^c, p^l, \tilde{p}^l, \hat{p}^l\}$ 。多特征融合模块将 LSTM、CNN、交叉注意力多种方法结合在一起,融合了不同特征的信息,丰富了结果预测的特征表示。这个模块产生了 6 个关键特征,每一个都代表了不同层次和来源的数据信息,在本研究中发挥了关键作用,为结果预测任务带来了更多的信息和性能提升。

3 实验流程与数据预处理

3.1 实验流程

实验流程主要步骤(见图 3)。

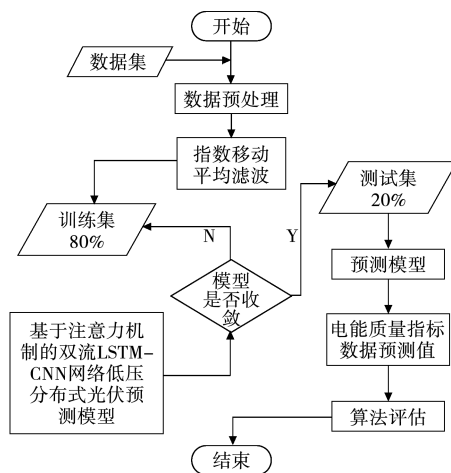


图 3 实验流程

Fig. 3 Experimental process

针对在数据预处理阶段,使用均值插值处理可能存在的缺失值和异常值,采取指数移动平均滤波的方法,对低压光伏电站的所有数据进行平滑处

理,以减少噪音和突变的影响。然后使用训练集对构建的基于注意力机制的 LSTM-CNN 双流网络模型进行训练,通过迭代优化参数,判断损失函数是否收敛,如果收敛效果达不到要求,就修改调整模型的参数进行再次训练直到损失函数收敛。在模型训练完成后,使用测试集对最终训练好的模型进行评估。

3.2 特征选择与数据预处理

3.2.1 特征选择

分布式光伏电站的功率和电流表现出多种复杂特性,受天气、光照条件、季节变化以及日内变化的影响。这些特性包括不稳定性、季节性变化、日内变化和随机性。白天光照较强,夜晚发电量接近零,同时还受到随机因素的干扰,例如云层的遮挡、阴天或雨天等。电压闪变通常表现为电压的瞬时变化,它可以由光伏电站功率快速变化引起。例如,在一个晴天,当云层突然遮挡太阳光时,光伏电站的输出功率可能会急剧下降,这会导致电压迅速下降,然后又迅速回升。这种电压闪变对光伏电力系统的稳定性产生负面影响,因为它可能导致设备的故障或其他问题。电压波动表现为电压在短时间内的连续振荡,通常是由于电力系统中的负载变化引起的。当光伏电站的输出功率突然增加时,电压可能会上升,然后在功率变化减小后再次下降。这种电压波动可能会引发电力系统中的共振现象^[15],从而影响电力设备的正常运行。电压偏差通常表示电压的长期偏离标准值,光伏电站的季节性发电量变化可能导致电压长期偏高或偏低,尤其是在高负荷时期对电网的稳定性产生重大影响。

在光伏电站运行中,电压闪变、电压波动和电压偏差往往不是孤立存在的,它们之间可能存在复杂的因果关系。其中电压波动和电压偏差可能存在正相关性。例如,光伏电站的发电功率随着太阳辐射的变化而波动,这可能引起电压的瞬时波动;其中电压波动可能与电压闪变呈负相关性。例如,系统中的电压波动可能受到电网的变化或负载扰动的影响,而电压闪变可能受到逆变器响应速度等因素的制约。在这种情况下,电压波动增加时,电压闪变可能减小,反之亦然。量化三者之间的线性关系来了解之间的相互依赖程度,更好地理解电压质量问题,从而采取适当措施,确保电力系统正常运行。

文章专注研究光伏电流和功率对电压质量指标的潜在影响。研究数据来自某光伏用户在 2022 年的历史分布式光伏接入功率、电流、电压闪变、电压波动和电压偏差五个方面的数据。每 15 分钟记录一次数据,总计形成了一个包含 $96 \times 180 \times 5$ 的数据量的特征集,涵盖了 5 个维度的信息。通过采用建模的方法,分析功率和电流与电压之间的关系,以推断电压的行为,并继而评估电压质量的各项指标,建立 LSTM-CNN-ATT 模型旨在预测电压的闪变、波动和偏差情况。

3.2.2 缺失异常值处理

对于整合好的数据集,存在缺失值和异常值,缺失的观测值或属性值可能影响数据分析和建模结果,并且模型对异常值敏感,可能导致模型训练不稳定或产生误导性结果。应用均值插值代替异常值和缺失值,对于每个属性列,计算非缺失值的平均值,得到一个平均值向量。找出数据集中所有的缺失值和异常值所在的位置,使用相应属性列的平均值来替代。

3.2.3 特征归一化

文章采用最小-最大归一化方法将数据按照原始值与最小值、最大值之间的比例进行线性缩放:

$$x_{\text{normalized}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (14)$$

式中: x 是原始数据; x_{min} 是数据集中的最小值; x_{max} 是数据集中的最大值。这种归一化方法保留

了数据的原始分布形态,适用于数据没有明显边界的情况。它可以使不同特征之间具有相同的尺度,避免某些特征对模型训练的影响过大。

3.2.4 数据集划分

为了能够对模型进行充分的训练、选择最佳的参数,并在验证集上进行模型的调优和选择,文章按照 80%、20% 的比例进行数据划分。首先随机打乱原始数据集的顺序,确保样本的顺序不会对划分结果产生偏差,然后根据划分比例,将打乱后的前 80% 数据集作为训练集,剩下的为测试集。

3.3 指数移动平均滤波

低压分布式光伏发电的数据在时域范围呈现不稳定性和波动性,外界的干扰极易造成输出功率的突变。因此,在数据集划分之前,对预处理完毕的数据要进行指数移动平均滤波处理^[16]。以某光伏用户 12 月部分分布式光伏接入功率曲线如图 4 所示。发电站的输出功率具有间歇性、周期性,结合实际电站的地理位置设置观测的时间为 15 分钟一次,一天 96 次监测输出功率数据,数据的取值范围从 $-1.47 \sim 0.46$,在该时间间隔内,光伏系统的功率变化较大,功率的变化并不是平滑稳定的,信号存在噪声干扰,不利于预测模型对于输出功率曲线的拟合^[17]。为了消除数据中的噪声和干扰成分,本文采用指数移动平均滤波处理历史输出功率和电流数据。

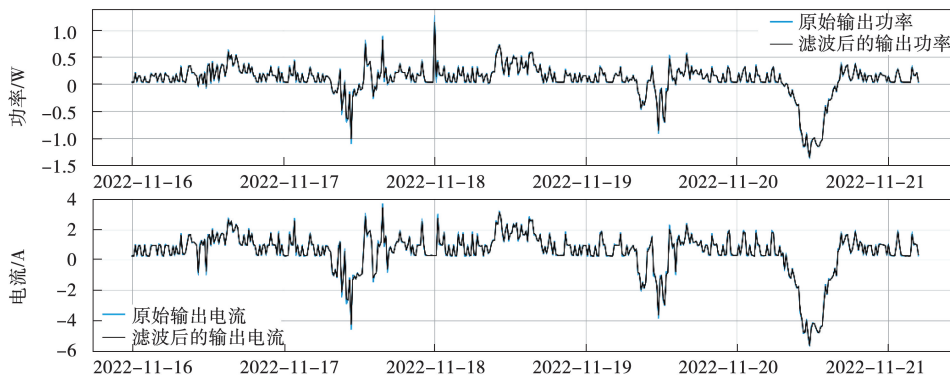


图 4 与滤波后的输出功率与电流曲线对比

Fig. 4 Comparison with the filtered output power and current curves

指数移动平均滤波通过平滑数据曲线,减少噪声和瞬时波动,以获得一个更平滑的输出功率序列^[18-20]。首先选择适当的平滑因子 α ,它能决定新数据点的权重;初始化第一个指数移动平均值,选择历史输出功率的第一个数据点作为初始的指数

移动平均值。对于每个时间步,如式(15)所示,根据指数移动平均滤波的公式计算新的指数移动平均值。

$$\text{EMA}(t) = \alpha * X(t) + (1 - \alpha) * \text{EMA}(t - 1) \quad (15)$$

式中:EMA(t)是在时间 t 的指数移动平均值; $X(t)$ 是在时间 t 的输入数据点;EMA($t-1$)是在时间 $t-1$ 的上一个指数移动平均值。

重复上述公式计算,直到处理完所有的历史输出功率和电流数据。在使用时间窗口移动进行滤波处理时,着重于选择合适的窗口大小和处理方式,以确保电压闪变等关键信息不被滤除。选择将平滑因子 α 设置为 0.9,这对于迅速变化的信号有较好的追踪效果,同时对噪声进行一定的平滑,提高信号的稳定性。如图 4 所示为滤波后的输出功率和电流曲线对比,减少了噪声的影响,曲线变得更加平滑。

4 实验验证与算例分析

4.1 实验损失函数与评价指标

在基于注意力机制的 LSTM-CNN 双流网络模型中,我们能得到 6 个预测值。如式(16)所示,计算预测结果与真实标签之间的差异。

$$L = \text{MSE}(p, y) = \|p - y\|^2 \quad (16)$$

式中: $p \in \{p^c, \tilde{p}^c, \hat{p}^c, p^l, \tilde{p}^l, \hat{p}^l\}$, y 为真实值。计算最终能得到不同的损失值,再经过多特征融合模块后最终损失函数如式(17)所示:

$$L = \{L^c, \tilde{L}^c, \hat{L}^c, L^l, \tilde{L}^l, \hat{L}^l\} \quad (17)$$

每个损失函数都对应着不同的模型分支或流程,通过多特征融合预测模块确保能够充分利用 CNN、LSTM 和交互层的优势。

低压分布式光伏电压质量指标预测中,使用平均绝对误差 MAE 和均方根误差 RMSE 作为评判模型光伏电压质量指标预测精度的标准。

$$\text{MAE} = 1/N \sum_{i=1}^n |y_{\text{real}} - y_{\text{pre}}| \quad (18)$$

$$\text{RMSE} = \sqrt{1/N \sum_{i=1}^n (y_{\text{real}} - y_{\text{pre}})^2} \quad (19)$$

式中: N 为样本数量; y_{real} 为电压电压质量指标的真实值; y_{pre} 为电压闪变的预测值。越小的 MAE 和 RMSE 值表示模型能够更精准地预测光伏电压电压质量指标的变化趋势和幅度。

4.2 模型训练

本次实验均在英特尔 Xeon 4110 处理器、NV-DIA RTX3060 24 G 显卡、128 G 内存的 Linux 服务器上进行。如表 2 为部分实验参数设置数据。

文章将指数移动平均滤波权重系数设置为

0.9;学习率设置为 0.005;迭代次数设定为 2 000,批次大小为 64,采用 ADAM 优化器来提高训练效率;序列长度设置为 32,隐藏层大小为 32,多头注意力机制的头数为 8。

表 2 实验参数设置

Tab. 2 Experimental parameter settings

参数名称	参数值
LR	0.005
Epoch Number	2 000
Batch size (B)	64
Optimizer	ADAM
sequence_length	32
hidden_size	32

4.3 不同的算法对比

为更好突出所提模型的可行性,对湖南某光伏电站用户的 2022 年的数据进行训练和预测,各方法的预测结果如表 3 和表 4 所示。从不同数据预测结果可以看出,所提算法 LSTM-CNN-ATT 在 RMSE 和 MAE 上均优于其他算法。

在对电压闪变的预测中,所提模型的 RMSE 相较于随机森林、CNN、LSTM、LSTM-CNN 其他算法分别减少了 1.743、0.721、0.321 和 0.501 9,所提模型具有更小的误差。所提模型的 MAE 相较于其他算法分别减少了 1.641 1、0.172 1、0.121 9 和 0.528 7。可以发现,随机森林模型的预测结果与实际数据存在较大的偏差,LSTM 模型在 MAE 和 RMSE 方面表现出显著的改善,且在电压闪变特定任务中,将 CNN 与 LSTM 结合并不一定能够显著改善预测性能。LSTM-CNN 模型基于 LSTM 和 CNN 的特点,具有同时捕捉时间序列数据的长期依赖关系和局部特征的能力。然而,猜测可能是 CNN 部分提取的特征无法准确捕捉到与电压闪变相关的重要模式和特征,那么 LSTM 部分的输入就会受到影响,从而影响了整个模型的性能。而基于注意力机制的 LSTM-CNN 模型中,LSTM-CNN 模型双分支后,引入交互层,弥补 CNN 和 LSTM 没有提取的部分特征,关注局部与局部的数字相关联特征,更好地捕捉与电压闪变相关的信息。从图 5(a)可以看出,相较其他算法模型,所提 LSTM-CNN-ATT 模型的电压闪变的变化趋势与实际曲线之间的最为接近。

表 3 不同预测模型电压质量指标值的预测误差

Tab. 3 Prediction errors of voltage quality indices in different prediction models

模型	训练时长/min	参数量/M	电压闪变		电压波动		电压偏差	
			MAE	RMSE	MAE	RMSE	MAE	RMSE
随机森林	45	0.089 8	1.687	1.854	1.254 3	1.354 6	1.124 8	1.024 8
决策树	40	0.079 6	1.235	1.752	1.652 6	1.224 9	1.296 5	1.002 5
CNN	61	0.116 3	0.218	0.832	0.217	0.799	0.247 5	0.298 2
RNN	62	0.103 2	0.321	0.798 2	0.398 5	0.813 1	0.194 2	0.311 5
LSTM	65	0.118 1	0.167 8	0.432	0.114 2	0.220 9	0.125 8	0.135 8
LSTM-CNN	70	0.190 9	0.574 6	0.612 9	0.082 9	0.193 5	0.085 9	0.096 5
LSTM-CNN-ATT	100	0.487 4	0.045 9	0.111 0	0.077 7	0.185 2	0.029 0	0.043 6

表 4 不同分支与模块的效果

Tab. 4 Effect of different branches and modules

组别	CNN	LSTM	交互层	多特征预测模块	MAE			RMSE		
					电压闪变	电压波动	电压偏差	电压闪变	电压波动	电压偏差
1	✓				0.218	0.217	0.247 5	0.832	0.799	0.298 2
2	✓	✓			0.574 6	0.082 9	0.085 9	0.612 9	0.193 5	0.096 5
3	✓	✓	✓		0.253 9	0.081 2	0.052 7	0.423 3	0.187 6	0.086 5
4	✓	✓	✓	✓	0.045 9	0.077 7	0.029 0	0.111 0	0.185 2	0.043 6




图 5 模型电压质量指标预测值与真实值对比

Fig. 5 Comparison between the predicted values and actual values of the model voltage quality indices

在对电压波动的预测中,所提模型的 *RMSE* 相较于其他算法分别减少了 1.169 4、0.613 8、0.035 7 和 0.008 3,所提模型具有更小的误差。所提模型的 *MAE* 相较于其他算法分别减少了 1.176 6、0.139 3、0.036 5 和 0.005 2。相对于传统的机器学习模型随机森林和单一的深度学习模型 CNN 和 LSTM,文中模型基于 LSTM 和 CNN 的特点,具有同时捕捉时间序列数据的长期依赖关系和局部特征的能力,从图 5(b)可以看出,LSTM-CNN-ATT 算法电压波动预测结果与实际间具有更好的拟合度,能够更准确地预测未来的电压波动情况,维护电网的稳定性和优化能源分配。

从电压偏差的预测结果的平均值来看,所提出基于注意力机制的 LSTM_CNN 模型的 *RMSE* 相较于随机森林、CNN、LSTM、LSTM-CNN 其他算法分别减少了 0.981 2、0.254 6、0.092 2 和 0.052 9,并且所提算法的 *MAE* 相较于其他算法分别减少了 1.095 8、0.218 5、0.096 8 和 0.056 9,所提模型具有更小的误差。从以上仿真结果可知,LSTM-CNN-ATT 预测模型相较于其他算法模型具有更小的误差和更高的精度,结合了深度学习和序列建模的优势,发现特征之间存在相关性,具备较强的泛化能

力,且该模型能够适应不同任务和不同数据集下的电压质量指标预测,这对于实际应用中面对不同电压相关问题的情况非常重要,对于低压分布式光伏系统的监控与管理可靠性具有重要意义。

从不同算法的参数数量和计算速度进行比较,随机森林中的每棵决策树是通过对训练集的随机采样和对特征的随机选择而得到的。决策树作为基本的分类和回归模型,其参数量主要取决于树的深度和每个节点的分裂条件。两者都是基于树结构的模型,树结构相对简单,计算复杂度较低。随机森林包含多棵决策树,因此在一些情况下可能比单一决策树稍慢。相对于深度学习算法,这两者的参数量通常较小,分别为 0.089 8 M 和 0.079 6 M,计算速度相对较快。对于轻量级的 CNN、RNN 和 LSTM 这些算法具有参数共享的性质,参数是可学习的权重和偏差,分别为 0.116 3 M、0.103 2 M、0.118 1 M,计算速度也相近。LSTM-CNN、LSTM-CNN-ATT 算法结合了多个深度学习组件,但与简单的决策树或浅层神经网络相比,参数量相对较大。为了平衡模型性能和计算速度,本文进行了超参数调整,将 LSTM 层数调整为 2、CNN 的滤波器数量按照表 1 进行设置。同时,在多模块融合预测进行了并行处理,同时在测试阶段,考虑到可能存在极端的预测结果,提出了对异常值进行排除的方法,将所有预测值的均值作为最终预测值,以提高整体计算效率。LSTM-CNN-ATT 算法由于在交互层使用注意力机制中,对输入序列中不同部分的加权关注涉及到对整个序列的计算和加权操作,并引入多特征预测模块来处理 6 个输入特征,增加了额外的计算量,因此计算速度最长,但相较于其他算法模型具有更小的误差和更高的精度。

4.4 实验结果

如表 4 所示,组别 1-4 为不同网络分支以及模块在光伏用户数据集上预测电压质量指标的性能,其中组别 1 只进行 CNN 单分支处理,性能效果差,无法充分捕捉复杂的任务特性;组别 2 进行 LSTM-CNN 双分支处理后,性能有了显著的提升,其中电压闪变 MAE 和 RMSE 分别降至 0.574 6 和 0.612 9,表明 LSTM 分支对于任务的时间序列特性有帮助,提高了模型的性能,能够有效捕捉数据中的趋势、周期性和长期依赖关系。在组别 3 中引入交互层,对双分支 LSTM_CNN 后的特征进行交叉注意力机制处理,理解不同特征之间的相关性和相互作用,

进一步加强了模型对不同层次和来源数字信息的利用,在特定任务中对特征进行加权,强调与电压闪变、电压波动和电压偏差相关的特征,从而提高了特征的表示和任务的性能。其中电压闪变 MAE 和 RMSE 分别降至 0.253 9 和 0.423 3,电压波动 MAE 和 RMSE 分别降至 0.081 2 和 0.187 6;在组别 4 进一步引入多特征预测模块,其中多特征融合的 6 个特征分别是经过 CNN 层的特征 X^l 、经过 LSTM 的特征 X^c 、在交互层中, X^l 和 X^c 进行交叉注意力机制得到的特征 \tilde{X}^c, \tilde{X}^l ,以及经过如式(10)和式(11)最大化处理后的特征 \hat{X}^c, \hat{X}^l 。这样多次融合 CNN、LSTM、交互层的信息,捕获数据的多样性和复杂性,最终获得 6 个预测头结果,并在测试阶段考虑到会极端的预测结果存在,提出了对异常值进行排除,将所有值的均值作为最终预测值。这种多特征融合的关键在于整合不同来源的信息,使得模型能够更全面地理解输入数据的特征,提高对电压质量各方面指标的准确预测能力。最终电压闪变 MAE 和 RMSE 显著减小至 0.045 9 和 0.111 0,电压偏差 MAE 和 RMSE 显著减小至 0.029 0 和 0.043 6,对于闪变、波动、偏差的预测效果均有提升,表明该策略对结果的提升起到了关键作用。这一系列结果明显提升了预测模型的性能,成功实现了分布式光伏电站电压质量指标的准确预测。这一成果对于低压分布式光伏系统的监控与管理具有实际应用价值。

5 结 论

针对低压分布式用户光伏电压质量的监控和准确预测问题,提出了一种基于注意力机制的双流 LSTM-CNN 网络低压分布式光伏电压质量指标预测模型。在测试阶段,我们的预测模型在所有三个指标(电压闪变、电压波动和电压偏差)上均取得了最佳的性能,双分支 LSTM-CNN 网络能够更好地捕捉数据的动态特性,引入交叉注意力机制,提高特征之间的关联性,自动学习数据中的关键信息,最后在多特征融合模块显著提高了所有任务的性能,表明多特征的整合对于电压闪变、电压波动和电压偏差的预测具有重要意义。

未来的工作可以进一步优化模型的结构和参数,探索更加有效的特征提取和表示方法。同时,可以考虑引入更多的外部因素和影响因素,如天气数据、负荷变化等,以提高预测模型的综合性能。同时,在异常情况的判断方面,可以进一步根据判

定条件来根据预测值来判断异常情况,从而能提前采取必要的监测和管理措施。此外,还可以进一步研究电压质量问题的原因和机制,深入挖掘电压偏差、电压波动和电压闪变之间的内在联系,提出相应的解决方案,以促进低压分布式光伏电站的可持续发展和光伏监测系统的稳定运行。

参 考 文 献

- [1] 王诗雯, 刘飞, 庄一展, 等. 基于有功指令共享的两级式光伏并网系统低电压穿越控制策略[J]. 电力自动化设备, 2023, 43(4): 99-105.
WANG Shiwen, LIU Fei, ZHUANG Yizhan, et al. Low-voltage ride-through control strategy for two-stage photovoltaic grid-connected systems based on active power command sharing[J]. Electric Power Automation Equipment, 2023, 43(4): 99-105.
- [2] 谢敏, 高浩睿, 胡海峰. 分布式光伏+储能在民用建筑应用研究与探讨[J]. 建筑电气, 2022, 41(12): 62-66.
XIE Min, GAO Haorui, HU Haifeng. Research and discussion on distributed photovoltaic + energy storage in civil buildings[J]. Building Electricity, 2022, 41(12): 62-66.
- [3] 陈钱军, 陶梅玉, 孙智一, 等. 光伏电站接入电网对电力系统电压闪变的影响[J]. 低压电器, 2011(22): 19-22.
CHEN Qianjun, TAO Meiyu, SUN Zhiyi, et al. The influence of the photovoltaic power station connected to the power grid on the voltage flicker of the power system[J]. Low-voltage electrical appliance, 2011(22): 19-22.
- [4] 魏杏, 阮绍炯, 曾小兰, 等. 分布式光伏接入对配电网电压质量的影响分析[J]. 电气开关, 2023, 61(3): 94-97, 102.
WEI Xing, RUAN Shaojiong, ZENG Xiaolan, et al. Analysis of the influence of distributed PV access on the voltage quality of the distribution network[J]. Electrical Switch, 2023, 61(3): 94-97, 102.
- [5] 孟安波, 许炫淙, 陈嘉铭, 等. 基于强化学习和组合式深度学习模型的超短期光伏功率预测[J]. 电网技术, 2021, 45(12): 4721-4728.
MENG Anbo, XU Xuancong, CHEN Jiaming, et al. Ultra-short-term photovoltaic power forecasting based on reinforcement learning and combined deep learning models[J]. Power System Technology, 2021, 45(12): 4721-4728.
- [6] 毕贵红, 鲍童语, 陈臣鹏, 等. 基于混合分解多尺度时频图和 Res-GRU-AT 的电能质量复合扰动识别[J]. 电力系统保护与控制, 2024, 52(4): 12-25.
BI Guihong, BAO Tongyu, CHEN Chenpeng, et al. Composite PQDs identification based on a hybrid decomposition multi-scale time - frequency map and Res-GRU-AT[J]. Power System Protection and Control, 2024, 52(4): 12-25.
- [7] WANG Z C, PENG Y F, LIU Y F, et al. Photovoltaic power quality analysis based on the modulation broadband mode decomposition algorithm[J]. Energies, 2021, 14(23): 7948-7948.
- [8] 赵泽妮, 云斯宁, 贾凌云, 等. 基于统计模型的短期风能预测方法研究进展[J]. 太阳能学报, 2022, 43(11): 224-234.
ZHAO Zeni, YUN Sining, JIA Lingyun, et al. Research progress of short-term wind energy prediction method based on statistical model[J]. Acta Energetica Solaris Sinica, 2022, 43(11): 224-234.
- [9] 陈天立. 基于孤立森林算法的 10 kV 配电网故障自动定位方法[J]. 自动化应用, 2023, 64(11): 196-198.
CHEN Tianli. An automatic fault location method for 10 kv distribution networks based on isolation forest algorithm[J]. Automation Application, 2023, 64(11): 196-198.
- [10] 陈露东, 卢嗣斌, 徐常. 基于传统 CNN-LSTM 模型和 PGAN 模型的用电量预测对比研究[J]. 电测与仪表, 2023, 60(10): 98-103.
CHEN Ludong, LU Sibin, XU Chang. Based on traditional CNN-LSTM model and PGAN model comparative study on power consumption prediction[J]. Electrical Measurement & Instrumentation, 2023, 60(10): 98-103.
- [11] 万俊杰, 方严, 司文旭, 等. 基于熵权-灰色关联法与 ISMA-HKELM 的光伏发电功率预测[J]. 电气应用, 2023, 42(3): 16-26.
WAN Junjie, FANG Yan, SI Wenxu, et al. Photovoltaic power prediction based on entropy right-grey correlation method and ISMA-HKELM[J]. Electrical Applications, 2023, 42(3): 16-26.
- [12] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023, 44(4): 19-27.
WEI Wei, LV You, QI Xinyu, et al. Power station fan state prediction method based on CNN-LSTM-AM dynamic integration model[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [13] 杨超, 冉启武, 罗德虎, 等. 基于注意力机制的 CNN-BIGRU 短期电价预测[J/OL]. 电力系统及其自动化学报: 1-10[2023-06-25] DOI:10.19635/j.cnki.csu-epsa.001257.
YANG Chao, RAN Qiwu, LUO Dehu, et al. Short-term electricity price forecast of CNN-BIGRU based on attention mechanism[J/OL]. Journal of Electric Power System and Its Automation; 1-10[2023-06-25] DOI:10.19635/j.cnki.csu-epsa.001257.
- [14] CHEN J, ZHANG X, ZHOU X, et al. An approach based

- on cross-attention mechanism and label-enhancement algorithm for legal judgment prediction[J]. Mathematics, 2023, 11(9): 9-14.
- [15] 罗刚, 钱钢, 范强, 等. 改进型光伏并网系统谐波电流检测和补偿算法[J]. 广东电力, 2021, 34(5): 28-37.
LUO Gang, QIAN Gang, FAN Qiang, et al. The harmonic current detection and compensation algorithm for the modified photovoltaic grid-connected system[J]. Guangdong Electric Power, 2021, 34(5): 28-37.
- [16] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023, 44(4): 19-27.
WEI Wei, LU You, QI Xinyu, et al. Power station fan state prediction method based on CNN-LSTM-AM dynamic integration model[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [17] 杨京渝, 罗隆福, 阳同光, 等. 基于气象特征挖掘和改进深度学习模型的风电功率短期预测[J]. 电力自动化设备, 2023, 43(3): 110-116.
YANG Jingyu, LUO Longfu, YANG Tongguang, et al. Short-term wind power forecasting based on meteorological feature mining and improved deep learning model[J]. Electric Power Automation Equipment, 2023, 43(3): 110-116.
- [18] 胡斌, 叶斌, 任曦骏, 等. 基于改进 TOPSIS 的台区低电压治理措施优选评价研究[J]. 电测与仪表, 2018, 55(7): 16-22.
HU Bin, YE Bin, REN Xijun, et al. Study on optimal evaluation of low voltage control measures in platform area based on improved TOPSIS[J]. Electrical Measurement & Instrumentation, 2018, 55(7): 16-22.
- [19] ZHAO X Z, YA Q Z, AO L, et al. Wild terrestrial animal re-identification based on an improved locally aware transformer with a cross-attention mechanism[J]. Animals, 2022, 12(24): 3503.
- [20] CAO L C, LI J C, ZHANG L B, et al. Cross-attention-based multi-sensing signals fusion for penetration state monitoring during laser welding of aluminum alloy[J]. Knowledge-Based Systems, 2023, 26(1): 10-18.
- 收稿日期: 2023-11-01; 修回日期: 2024-05-16
- 作者简介:
- 贺星(1982—),女,通信作者,高级工程师,研究方向为营销设备质量管控、新技术推广应用工作,设备检测、现场故障诊断技术。E-mail:71591160@qq.com
- 王智(1984—)女,硕士,高级工程师,研究方向为电力仪器仪表智能检测以及电力计量新技术。
- 刘谋海(1990—)男,高级工程师,研究方向为从事智能电气量测与应用技术。
- 刘洁(2000—),女,硕士研究生,研究方向为智能电网、电力系统大数据方向。
- 黄瑞(1989—),男,硕士,高级工程师,研究方向为智能电气量测与应用技术。
- 颜宏文(1968—),女,博士,教授,研究方向为智能电网中的数据挖掘。
- 颜勤(1988—),女,博士,副教授,研究方向为电动汽车及新能源接入电力系统运行优化。
- 马瑞(1971—),男,博士,教授,研究方向为电力系统分析与控制、能源互联网和电力系统大数据。
- (编辑 杜景飞)