

# 基于 SOM 聚类和 ECA 的超短期光伏预测组合模型研究

董金华<sup>1</sup>,徐伊洁<sup>2</sup>,朱一昕<sup>2</sup>,许德智<sup>2</sup>

(1. 国网无锡供电公司,江苏 无锡 214100; 2. 江南大学 物联网工程学院,江苏 无锡 214026)

**摘要:**为提高不同天气类型下光伏输出功率的预测精度,提出了一种基于注意力机制的超短期光伏预测组合模型。首先,通过皮尔逊相关系数分析,选取与光伏发电功率密切相关的关键气象因子,并对其进行逐月标准化,然后加权求和计算得到分类指标天气条件因子(Sky Condition Factor, SCF),以降低输入变量的维度,并消除季节对天气分类的干扰和众多气象因子之间的耦合关系。其次,通过自组织映射神经网络(Self-Organizing Map, SOM)对SCF进行无监督聚类,划分出3种天气类型。然后,在3种天气类型下分别构建卷积神经网络(Convolutional Neural Network, CNN)预测模型,并引入高效通道注意力模块(Efficient Channel Attention, ECA),自适应地为特征信息的多重通道分配相应的权重,使模型集中于重要的特征信息,提高模型的预测精度。采用历史实测数据进行仿真,结果表明:与未引入ECA模块的预测模型相比,所提预测模型在3种天气类型下的预测准确度分别提高了1.006 1%,1.626 1%和1.610 4%,验证了该模型的有效性。

**关键词:**Pearson 相关系数;标准化;SOM 聚类;ECA;CNN

中图分类号:TP183;TM615 文献标识码:A DOI:10.16146/j.cnki.rndlge.2024.03.020

[引用本文格式]董金华,徐伊洁,朱一昕,等.基于 SOM 聚类和 ECA 的超短期光伏预测组合模型研究[J].热能动力工程,2024,39(3):158-165. DONG Jin-hua, XU Yi-jie, ZHU Yi-xin, et al. A combined model for ultra-short-term PV forecasting based on SOM clustering and ECA[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(3):158-165.

## A Combined Model for Ultra-short-term PV Forecasting based on SOM Clustering and ECA

DONG Jin-hua<sup>1</sup>, XU Yi-jie<sup>2</sup>, ZHU Yi-xin<sup>2</sup>, XU De-zhi<sup>2</sup>

(1. State Grid Wuxi Power Supply Company, Wuxi, China, Post Code: 214100;

2. School of Internet of Things Engineering, Jiangnan University, Wuxi, China, Post Code: 214026)

**Abstract:** In order to improve the prediction accuracy of PV output power under different weather types, a combined model of ultra-short-term PV prediction based on attention mechanism was proposed. First, the key meteorological factors closely related to PV power generation were selected by Pearson correlation coefficient analysis and standardized month by month, and then weighted summation was calculated to obtain the classification index sky condition factor (SCF) in order to reduce the dimensionality of input variables and eliminate the interference of season on weather classification and the coupling relationship between numerous meteorological factors. Second, three types of weather types were classified by unsupervised clustering of SCFs through self-organizing map (SOM) neural network. Then, convolutional neural network (CNN) prediction models for each of the three weather types were constructed, and the efficient channel attention (ECA) module was introduced to adaptively assign relevant weights to each of the mul-

iple channels of feature information extracted by the CNN, so that the model focused on important feature information and the prediction accuracy of the model was improved. Finally, simulations were performed using historical measured data. The results show that the prediction accuracies of the proposed prediction model under three different weather types are improved by 1.006 1%, 1.626 1%, 1.610 4%, respectively, compared with the prediction model without the introduction of ECA module, which verifies its effectiveness.

**Key words:** Pearson correlation coefficient, standardization, SOM clustering, efficient channel attention (ECA), convolutional neural network (CNN)

## 引言

由于太阳能具有清洁可持续、分布广泛且发电成本低的特点,太阳能光伏发电技术成为开发可再生能源的重要手段<sup>[1]</sup>。近十多年来,国内外的累计光伏装机容量呈持续快速增长趋势<sup>[2]</sup>,但由于光伏发电的随机波动性和间歇性,其大规模并网使电网的稳定安全运行受到了巨大的挑战<sup>[3-5]</sup>。因此,准确地预测出光伏发电功率具有十分重要的意义。

根据预测模型的不同,可将光伏预测分为统计模型预测、机器学习预测和深度学习预测<sup>[6]</sup>。统计模型预测方法主要包括时间序列分析、回归分析等方法<sup>[7]</sup>,适用于预测周期较短且数据量较小的情况<sup>[8]</sup>。机器学习预测主要采用分类器、回归器、支持向量机和随机森林等算法进行建模和预测,该方法需要较多的数据和特征工程,适用于较长时间的预测<sup>[9]</sup>。深度学习预测使用神经网络对历史数据进行建模和预测,常用的模型包括卷积神经网络和循环神经网络等,该方法能够处理复杂的时空特征<sup>[10]</sup>。

由于注意力机制能衡量输入特征的重要程度,被引入各种神经网络中用来提高模型的泛化能力<sup>[11-12]</sup>。文献[13]通过加权注意力机制在不同时刻选择不同的特征组合作为长短期记忆模型( Long Short-Term Memory, LSTM)的输入进行光伏发电预测。文献[14]通过 CNN 提取光伏序列的空间特征,通过双向门控循环单元( Bidirectional Gate Recurrent Unit, BiGRU) 提取光伏序列的双向时间特征,并在 CNN 和 BiGRU 中引入注意力机制,以放大强相关输入因素的占比,提高模型预测精度。文献[15]在由 LSTM 神经元构建的 Encoder-Decoder 编解码模型中引入注意力机制,建立多步长、多变量的

光伏发电预测模型。上述模型并没有考虑到不同天气类型下光伏发电表现出的不同波动特征。

聚类是一种无监督学习方法,用于将数据集中具有相似特征的样本划分为一个组或者类别,使同一类别的数据表现出高度的相似性,从而提高模型的训练效果。文献[16]提出一种晴朗系数作为天气分类指标,将天气类型划分为晴天和非晴天两种,使用多层次相似匹配方法提取与预测日数据最为相似的历史数据,进而构建自回归移动平均时间序列预测模型( Autoregressive Integrated Moving Average, ARIMA),该方法较传统神经网络方法有效地提高了光伏预测的精度。文献[17]采用地表地外辐照度相关系数、波动系数以及波形熵三维特征,对33种天气类型进行量化来提取特征向量,通过对特征向量进行自适应聚类,将天气划分为4个类型。该方法兼顾了模型的复杂度和泛化能力。文献[18]使用皮尔逊相关系数分析并筛选出关键的影响因子,然后对其进行加权求和获取聚类指标,该方法降低或是消除了各影响因素间存在的耦合关系。文献[19]在文献[18]的基础上,对数据进行逐月标准化,消除了季节因素对模型预测的干扰,使用SOM神经网络将天气分为3种类型,并在每种天气类型下分别构建CNN预测模型。

针对上述问题,本文提出了一种基于通道注意力机制的超短期光伏预测组合模型。首先,对进行数据异常处理、逐月归一化,对历史气象数据与光伏输出功率( Photovoltaic, PV) 数据进行皮尔逊相关系数分析,进而筛选出关键影响因素;其次,对关键因素加权求和得到SCF,将其作为SOM神经网络的输入进行聚类,将天气类型分为3种,并在3种天气类型下分别搭建CNN预测模型,加入通道注意力机制,使模型集中于重要特征,提高模型预测性能;最后,基于某电站的历史实测数据对模型进行训练与

测试,并与未引入通道注意力机制的模型进行对比仿真,结果表明,本文所提模型具有更高的预测精度。

## 1 光伏功率预测模型概述

光伏输出功率预测模型的框架如图 1 所示。

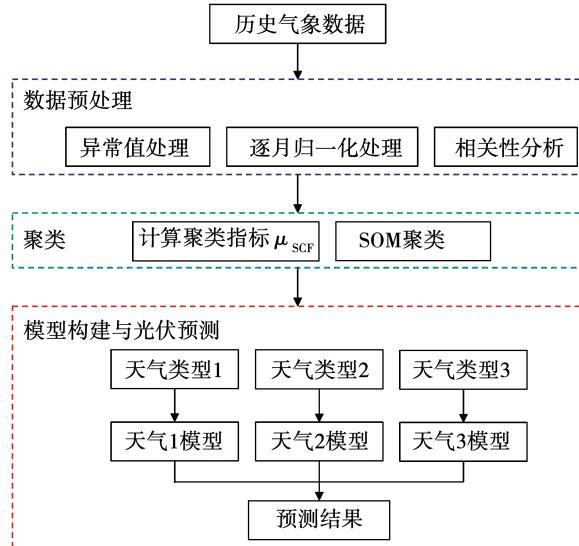


图 1 光伏输出预测模型框架

Fig. 1 Framework for photovoltaic output forecasting model

构建预测模型的主要步骤如下:

### (1) 数据预处理

使用 3-sigma 统计方法识别数据集里的异常数据,并用平均值法修正异常点。以月为单位对数据进行 0~1 标准化,提升模型的收敛速度及预测精度。对光伏出力与各特征变量进行相关性分析,筛选出重要的特征变量,将其作为模型的输入。

### (2) 聚类

将前面选取的特征变量进行加权求和来获取聚类指标  $\mu_{SCF}$ ,将其输入 SOM 神经网络进行天气聚类,得到天气分类结果。

### (3) 构建模型与光伏预测

在 3 种天气类型下分别构建 CNN 预测模型,并引入通道注意力机制,使模型集中于重要特征,进而提高模型预测性能。然后,输入待预测日各时刻的气象数据,最终得到模型的预测输出。

## 2 SOM 聚类

SOM 神经网络可以将相互关系复杂且非线性

的高维数据映射到具有简单几何结构及相互关系的低维空间<sup>[20]</sup>。SOM 为层次性结构,其典型结构是输入层加输出层<sup>[21]</sup>,如图 2 所示。设输入向量为  $X = [x_1, x_2, \dots, x_n]$ ,  $n$  为数据集中所有样本数量,构成输入神经网络的节点数;输出层有  $X \times Y$  个节点,每个节点通过  $n$  条权边与输入节点相连,即输出层的每个节点用 1 个  $n$  维矢量  $W_{ij}$  来表征,权值向量  $W_{ij} = [w_{j0}, w_{j1}, \dots, w_{jn}]$  ( $i = 1, 2, \dots, X; j = 1, 2, \dots, Y$ )。

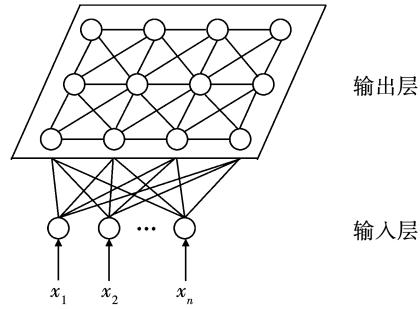


图 2 SOM 神经网络结构

Fig. 2 Structure of SOM neural network

SOM 聚类算法的实现过程归纳为以下 7 个步骤:

### (1) 初始化

对输出层各权值向量赋予较小的随机数,并对其进行归一化处理,得到  $W_{ij}(0)$ ,确定优胜邻域半径  $\delta$ ,初始学习率  $lr_0$  和迭代次数  $\lambda$ 。

### (2) 数据输入

将  $\mu_{SCF}$  输入 SOM 模型。

### (3) 距离计算

计算每个节点与输入节点的距离,找到距离最近的点,称为获胜节点。

本文采用欧氏距离  $d_{ij}$ ,即:

$$d_{ij} = \|X - W_{ij}\| \quad (1)$$

### (4) 权重更新

假设获胜节点为  $(c_x, c_y)$ ,在以该节点为中心、 $\delta$  为半径的优胜邻域内。

节点  $(i, j)$  的权重为:

$$W_{ij} = e^{-\frac{(c_x-i)^2}{2\delta^2}} \cdot e^{-\frac{(c_y-j)^2}{2\delta^2}} \quad (2)$$

### (5) 学习率更新

学习率更新函数为:

$$lr(t) = lr_0 / (1 + \frac{t}{\lambda/2}) \quad (3)$$

其中,  $t$ —当前迭代次数。

### (6) 重复迭代

重复进行步骤(4)~(6),直至迭代次数达到预定值 $\lambda$ 。

### (7) 聚类结果输出

最终输出节点形成了1个低维的网格,每个节点代表1个聚类簇。将数据点映射到相应的节点上,即可得到聚类结果。

## 3 注意力机制

注意力机制(Attention Mechanism)是一种模拟人类注意力行为的计算机模型<sup>[22]</sup>。注意力机制通过对模型不同位置上的信息进行加权,使得模型能够在处理输入序列时有选择地关注相关部分,从而更好地捕捉序列中的关系和重要信息<sup>[23]</sup>。通过引入注意力机制,模型可以自动学习对不同位置的元素进行加权,使得重要的元素获得更高的权重,从而提高模型的性能。

本文采用一种高效通道注意力模块,即ECA模块,该模块结构如图3所示。其中, $W$ , $H$ 和 $C$ 分别是宽度、高度和通道尺寸(即滤波器的数量)。假设该模块的输入 $\chi \in \mathbb{R}^{W \times H \times C}$ 。ECA模块在不降维的情况下使用全局平均池化(Global Average Pooling, GAP)聚合卷积特征,然后自适应地确定核大小 $k$ 并执行一维卷积,然后通过Sigmoid函数来学习通道注意力。

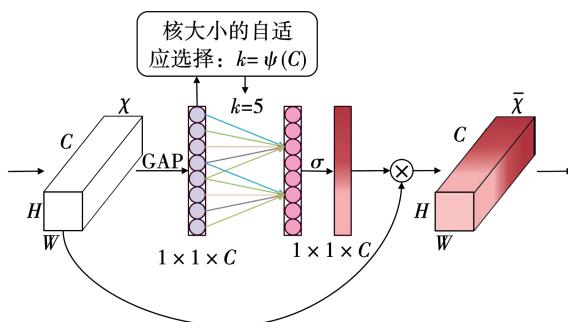


图3 ECA模块示意图

Fig. 3 Schematic diagram of ECA module

ECA模块实现的步骤可归纳为如下5步:

(1) 通过GAP聚合卷积特征,其表达式为:

$$y = \frac{1}{WH} \sum_{i=1, j=1}^{W, H} \chi_{ij} \quad (4)$$

(2) 根据通道维度 $C$ 自适应地确定核大小 $k$ :

$$k = \psi(C) = \left| \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}} \quad (5)$$

式中: $|t|_{\text{odd}}$ —最接近 $t$ 的基数; $\gamma$ 和 $b$ —分别取值2和1。

(3) 对GAP的输出进行核大小为 $k$ 的一维卷积。

(4) 通过Sigmoid函数计算通道的权重:

$$\omega = \sigma(C1D_k(y)) \quad (6)$$

式中: $C1D$ —一维卷积; $\sigma$ —一种Sigmoid函数。

(5) 将输入 $\chi$ 与权重 $\omega$ 按通道相乘,得到最终输出结果。

## 4 基于ECA模块的CNN模型

基于ECA模块的CNN模型结构包括输入模块、ECA-CNN模块以及输出模块,具体结构如图4所示。

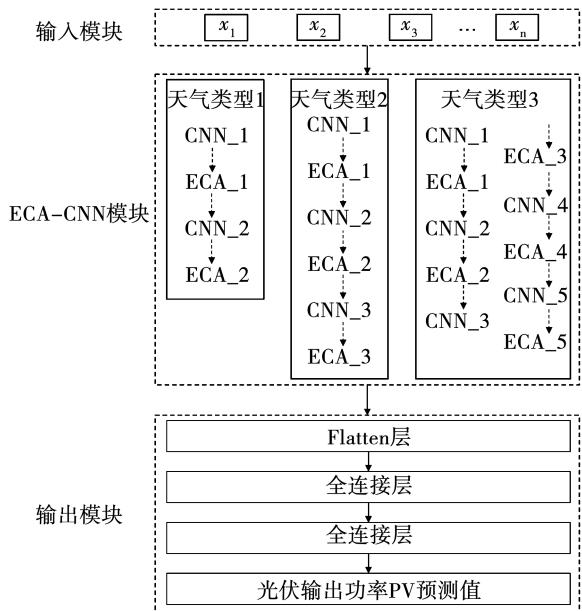


图4 基于ECA模块的CNN模型结构图

Fig. 4 Structure diagram of CNN model  
based on ECA module

输入模块中的 $x_1, x_2, x_3 \dots x_n$ 指输入的气象特征,具体由相关性分析筛选获取。ECA-CNN模块由若干个CNN以及ECA组成,不同天气类型对应的CNN和ECA的数量不同。其中,天气类型1对应的CNN和ECA数量最少,天气类型3最多。原因是:晴天天空条件比较简单,预测难度较低,预测模型相对简单;而阴雨天会出现突变情况,预测难度较大,预测模型相对复杂<sup>[24]</sup>。每个CNN由1个卷积层和

1 个归一化层组成,负责对输入序列进行特征提取及变换;ECA 则将 CNN 处理后的序列通道给与不同的权重,从而使模型集中于重要的特征。

## 5 案例分析

光伏功率数据来源于我国江苏省某装机容量为 35 MW 的光伏电站,气象数据来自于羲和能源大数据平台,数据采样间隔时间为 1 h,包括 2017 年 1 月 1 日至 2019 年 10 月 27 日共 24 703 个数据。将前 80% 的数据作为训练集,后 20% 的数据作为测试集。基于 Pytorch 软件建立超短期光伏发电功率预测模型,并将其与未引入通道注意力机制的预测模型进行预测效果对比。

### 5.1 相关性分析结果

采用皮尔逊相关系数分析来选取关键特征,并将其作为模型的输入。表 1 是使用 2019 年的数据进行相关性分析的结果。

表 1 各气象因素与光伏输出功率的相关系数

Tab. 1 Correlation coefficient of each meteorological factor with PV output power

影响因素	相关系数 R
温度	0.580
湿度	-0.721
气压	-0.012
降水量	-0.096
地面风速	0.214
辐照度	0.965
风向	0.192
直射比	0.801

按照 R 的大小,将相关程度划分为以下几种情况:当  $|R| \geq 0.5$  时,可视为中高度相关;当  $0.2 \leq |R| < 0.5$  时,可视为弱相关;当  $|R| < 0.2$  时,可视为极弱相关或者无关。由表 1 可知,温度、湿度、辐照度、直射比与光伏输出功率呈中高度相关,因此选取这 4 个特征变量作为预测模型的输入<sup>[25]</sup>。

### 5.2 聚类结果

将选取的 4 个特征变量进行加权求和获取聚类指标  $\mu_{\text{SCF}}$ :

$$\mu_{\text{SCF}} = \omega_1 \cdot T + \omega_2 \cdot \text{RH} + \omega_3 \cdot \text{GHI} + \omega_4 \cdot B_d \quad (7)$$

式中:  $T$ —气温;  $\text{RH}$ —湿度;  $\text{GHI}$ —地表水平辐射;  $B_d$ —直射比;  $\omega_1, \omega_2, \omega_3, \omega_4$ —4 个变量的权重系数,这 4 个权重系数之间的比例与相应气象特征和光伏发电功率的相关系数之间的比例相同<sup>[18]</sup>。

将  $\mu_{\text{SCF}}$  输入 SOM 网络,设定聚类数目为 3,每个聚类簇的具体信息如表 2 所示。其中,在对光伏发电功率进行实时预测时,每种天气类型对应的  $\mu_{\text{SCF}}$  不是固定的,可以按照实际数据进行合理修正<sup>[18]</sup>。

表 2 聚类簇信息

Tab. 2 Information of each cluster

天气类型	样本数目	$\mu_{\text{SCF}}$ 取值范围
1	9 643	$\varepsilon_2 < \mu_{\text{SCF}} \leq \varepsilon_1$
2	7 794	$\varepsilon_3 < \mu_{\text{SCF}} \leq \varepsilon_2$
3	7 266	$\varepsilon_4 < \mu_{\text{SCF}} \leq \varepsilon_3$

注:实验数据中,  $\varepsilon_1 = 0.676, \varepsilon_2 = 0.323, \varepsilon_3 = 0.092, \varepsilon_4 = -0.223$ 。

SOM 神经网络输出层神经节点数据分布情况如图 5 所示。

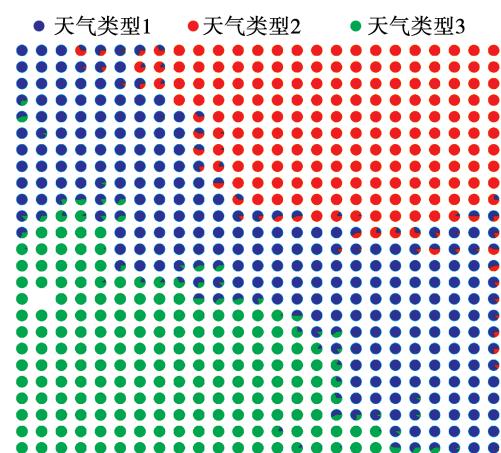


图 5 SOM 神经网络输出层神经节点数据分布

Fig. 5 Data distribution of neural nodes in output layer of SOM neural network

图 6 为 3 种天气类型下各气象要素的分布情况。其中,颜色越浅表示数值越接近 1,颜色越深表示数值越接近 0。为了方便观察,各要素都进行了归一化处理。从图 6 中可以看出,在天气类型 1 中,温度、直射比都比较高,几乎没有降水量,因此天气类型 1 以晴天为主;在天气类型 2 中,温度、直射比都比天气类型 1 低,且有少量的降水,因此天气类型

2以多云、多云转小雨等天气为主;在天气类型3中,温度、直射比明显低于天气类型2,且有大量的降水,因此天气类型3以阴雨天等恶劣天气为主。

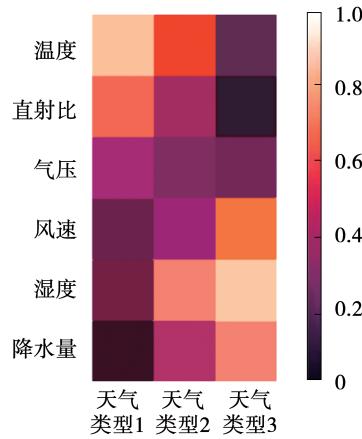


图6 各天气类型下气象要素的分布情况

Fig. 6 Distribution of meteorological elements under each weather type

### 5.3 预测结果分析

选用相对平均绝对误差 nMAE 和相对方差 nRMSE 作为评估模型预测效果的指标。这两种误差指标的具体定义如下:

$$nMAE = \left( \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| / \bar{y} \right) \times 100\% \quad (8)$$

$$nRMSE = \left( \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{y}_i)^2} / \bar{y} \right) \times 100\% \quad (9)$$

式中:N—样本数量; $\hat{y}_i$ —模型预测值; $y_i$ —真实值; $\bar{y}$ —所有真实值的平均值。

为验证所提模型的有效性,将所提模型的预测结果与未引入通道注意力机制(ECA)的模型进行对比。3种天气类型下光伏输出功率预测结果如图7~图9所示。

从图中可以看出,引入 ECA 模块模型的预测结果曲线与实际曲线的拟合度明显高于未引入 ECA 模块的模型。

进一步通过预测误差指标进行对比分析,如表3所示。

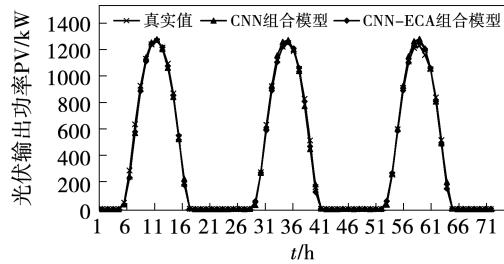


图7 天气类型1光伏功率预测曲线

Fig. 7 PV power prediction curve for weather type 1

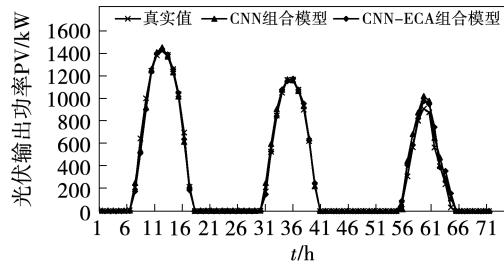


图8 天气类型2光伏功率预测曲线

Fig. 8 PV power prediction curve for weather type 2

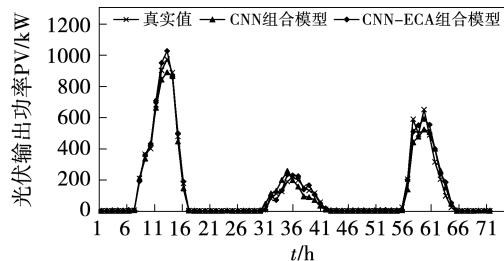


图9 天气类型3光伏功率预测曲线

Fig. 9 PV power prediction curve for weather type 3

表3 模型预测误差指标(%)

Tab. 3 Error indicators for model predictions (%)

指标	CNN-ECA 组合模型				CNN 组合模型			
	类型1	类型2	类型3	平均	类型1	类型2	类型3	平均
nMAE	2.773 8	5.735 6	10.626 9	6.3788	3.420 1	6.927 3	12.398	7.581 8
nRMSE	4.706 6	10.540 2	14.581 4	9.9407	5.712 7	12.166 3	16.191 8	11.356 9

由表3可以看出,在3种天气类型下,引入ECA模块进行优化的预测模型的预测效果均优于未引入

ECA 模块的模型,优化后组合模型预测的平均 nMAE 和 nRMSE 分别为 6.3788% 和 9.9407%,比

未优化模型的平均 nMAE 和 nRMSE 分别低 1.203% 和 1.416 2%。由此验证了本文所提模型的有效性。

## 6 结 论

提出一种基于注意力机制的超短期光伏预测组合模型,通过引入通道注意力机制,加强模型对特征的提取能力,使模型能集中于影响光伏输出功率中更为关键的特征,从而提高模型的预测性能。通过实验验证了所提 CNN-ECA 组合模型的合理性和预测性能上的优势。根据实验结果,得出结论:

(1) 在 3 种天气类型中,天气类型 1 的预测精度最高,天气类型 2 的预测精度次之,天气类型 3 的预测精度最低。

(2) 引入 ECA 模块进行优化的预测模型的预测效果均优于未引入 ECA 模块的模型,优化后组合模型预测的平均 nMAE 和 nRMSE 分别比未优化模型低 1.203% 和 1.416 2%,验证了所提模型的有效性。

## 参 考 文 献:

- [1] 龚莺飞,鲁宗相,乔颖,等.光伏功率预测技术[J].电力系统自动化,2016,40(4):140–151.  
GONG Ying-fei, LU Zong-xiang, QIAO Ying, et al. An overview of photovoltaic energy system output forecasting technology [J]. Automation of Electric Power Systems, 2016, 40(4):140 – 151.
- [2] GUERMOUI M, MELGANI F, GAIRAA K, et al. A comprehensive review of hybrid models for solar radiation forecasting [J]. Journal of Cleaner Production, 2020, 258(5):120357.1 – 120357.30.
- [3] 刘迎澍,王翠敏.光储微电网并网模式协调控制策略[J].电力系统及其自动化学报,2018,30(1):127 – 132.  
LIU Ying-shu, WANG Cui-min. Coordinated control strategy for micro-grid with photovoltaic and energy storage units in grid connected operation [J]. Proceedings of the CSU-EPSA, 2018, 30(1): 127 – 132.
- [4] 左远龙,黄玉水,杨晓辉,等.基于 PFA-MBAS-BP 神经网络模型的光伏发电短期预测[J].电力系统保护与控制,2020,48(15):84 – 91.  
ZUO Yuan-long, HUANG Yu-shui, YANG Xiao-hui, et al. Short-term prediction of photovoltaic power generation based on a PFA-MBAS-BP neural network model [J]. Power System Protection and Control, 2020, 48(15):84 – 91.
- [5] DABRA V, PALIWAL K K, SHARMA P, et al. Optimization of photovoltaic power system: A comparative study [J]. Protection and Control of Modern Power Systems, 2017, 2(1):29 – 39.
- [6] 王晓霞,俞敏,霍泽健,等.基于近邻传播聚类与 LSTNet 的分布式光伏电站群短期功率预测[J].电力系统自动化,2023,47(6):133 – 141.  
WANG Xiao-xia, YU Min, HUO Ze-jian, et al. Short-term power forecasting of distributed photovoltaic station clusters based on affinity propagation clustering and long short-term time-series network [J]. Automation of Electric Power Systems, 2023, 47 (6): 133 – 141.
- [7] 丁明,鲍玉莹,毕锐.应用改进马尔科夫链的光伏出力时间序列模拟[J].电网技术,2016,40(2):459 – 464.  
DING Ming, BAO Yu-ying, BI Rui. Simulation of PV output time series used improved Markov chain [J]. Power System Technology, 2016, 40(2):459 – 464.
- [8] 赖昌伟,黎静华,陈博,等.光伏发电出力预测技术研究综述[J].电工技术学报,2019,34(6):1201 – 1217.  
LAI Chang-wei, LI Jing-hua, CHEN Bo, et al. Review of photovoltaic power output prediction technology [J]. Transactions of China Electrotechnical Society, 2019, 34(6):1201 – 1217.
- [9] BOUZGOU H, GUEYMARD C A. Minimum redundancy - maximum relevance with extreme learning machines for global solar radiation forecasting: Toward an optimized dimensionality reduction for solar time series [J]. Solar Energy, 2017, 158:595 – 609.
- [10] 张雨金,杨凌帆,葛双治,等.基于 Kmeans-SVM 的短期光伏发电功率预测[J].电力系统保护与控制,2018,46 (21): 124 – 130.  
ZHANG Yu-jin, YANG Ling-fan, GE Shuang-ye, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine [J]. Power System Protection and Control, 2018, 46(21):124 – 130.
- [11] 余光正,陆柳,汤波,等.基于云图特征提取的改进混合神经网络超短期光伏功率预测方法[J].中国电机工程学报,2021,41(20):6989 – 7003.  
YU Guang-zheng, LU Liu, TANG Bo, et al. An improved hybrid neural network ultra-short-term photovoltaic power forecasting method based on cloud image feature extraction [J]. Proceedings of the CSEE, 2021, 41(20):6989 – 7003.
- [12] ZHOU H, ZHANG Y, YANG L, et al. Short-term photovoltaic power forecasting based on long short term memory neural network and attention mechanism [J]. IEEE Access, 2019, 99: 78063 – 78074.
- [13] 陈晨,王小杨,梁建盈,等.基于新型注意力机制的 LSTM 光伏发电预测方法[J].现代计算机,2021,27(11):28 – 32,38.  
CHEN Chen, WANG Xiao-yang, LIANG Jian-ying, et al. LSTM photovoltaic power generation forecasting method based on attention mechanism [J]. Modern Computer, 2021, 27 (11): 28 – 32,38.

- [14] 梁宏涛,王莹,刘红菊,等. 基于注意力机制的 CNN-BiGRU 短期光伏发电功率预测 [J]. 计算机测量与控制, 2022, 30(6):259–265.  
LIANG Hong-tao, WANG Ying, LIU Hong-ju, et al. Short-term PV output forecast of BiGRU based on the attention mechanism [J]. Computer Measurement & Control, 2022, 30(6):259–265.
- [15] 宋良才,索贵龙,胡军涛,等. 基于注意力机制的 Encoder-Decoder 光伏发电预测模型 [J]. 计算机与现代化, 2020(9): 112–117.  
SONG Liang-cai, SUO Gui-long, HU Jun-tao, et al. Encoder-decoder photovoltaic power generation prediction model based on attention mechanism [J]. Computer and Modernization, 2020(9): 112–117.
- [16] 王志忠,韩茂林,胡海,等. 基于晴朗系数和多层次匹配的光伏功率预测的方法研究 [J]. 电测与仪表, 2019, 56(8): 45–50.  
WANG Zhi-zhong, HAN Mao-lin, HU Hai, et al. Research on photovoltaic power prediction method based on sunny coefficient and multi-similarity matching [J]. Electrical Measurement & Instrumentation, 2019, 56(8):45–50.
- [17] 蒋小波,徐小艳,刘乐平,等. 天气分类和 BP 神经网络的光伏短期出力预测 [J]. 电源技术, 2020, 44(12):1809–1813.  
JIANG Xiao-bo, XU Xiao-yan, LIU Le-ping, et al. Short-term photovoltaic power output prediction method based on fuzzy weather classification and improved BP network [J]. Chinese Journal of Power Sources, 2020, 44(12):1809–1813.
- [18] 李芬,周尔畅,孙改平,等. 一种新型天气分型方法及其在光伏功率预测中的应用 [J]. 上海交通大学学报, 2021, 55(12):1510–1519.  
LI Fen, ZHOU Er-chang, SUN Gai-ping, et al. A novel weather classification method and its application in photovoltaic power prediction [J]. Journal of Shanghai Jiao Tong University, 2021, 55(12):1510–1519.
- [19] XU Y, DONG J, ZHU Y, et al. A combined model for ultra-short-term PV forecasting based on SOM clustering [C]//2023 IEEE 14th International Symposium on Power Electronics for Distributed Generation Systems (PEDG), Shanghai, China, 2023.
- [20] 宋莉娜,冯旭鹏,刘利军,等. 基于 SOM 聚类的微博话题发现 [J]. 计算机应用研究, 2018, 35(3):671–674, 679.  
SONG Li-na, FENG Xu-peng, LIU Li-jun, et al. Microblog topics detection based on SOM clustering [J]. Application Research of Computers, 2018, 35(3):671–674, 679.
- [21] 蒋海峰,万畅,林树胜. 基于 SOM 神经网络的蓄电池 SOH 快速检测研究 [J]. 工业控制计算机, 2023, 36(3):132–134.  
JIANG Hai-feng, WAN Chang, LIN Shu-sheng. Research on rapid detection of battery health based on SOM neural network [J]. Industrial Control Computer, 2023, 36(3):132–134.
- [22] 马磊,黄伟,李克成,等. 基于 Attention-LSTM 的光伏超短期功率预测模型 [J]. 电测与仪表, 2021, 58(2):146–152.  
MA Lei, HUANG WEI, LI Ke-cheng, et al. Photovoltaic ultra-short-term power prediction model based on Attention-LSTM [J]. Electrical Measurement & Instrumentation, 2021, 58(2): 146–152.
- [23] 杨晶显,张帅,刘继春,等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测 [J]. 电力系统自动化, 2021, 45(3): 174–182.  
YANG Jing-xian, ZHANG Shuai, LIU Ji-chun, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long short-term memory with dual-stage attention mechanism [J]. Automation of Electric Power Systems, 2021, 45(3): 174–182.
- [24] NIE Y, SUN Y, CHEN Y, et al. PV power output prediction from sky images using convolutional neural network: The comparison of sky-condition-specific sub-models and an end-to-end model [J]. Journal of Renewable and Sustainable Energy, 2020, 12(4): 046101.1–046101.19.
- [25] COSCIA M. Pearson correlations on complex networks [J]. Journal of Complex Networks, 2021, 9(6):1–14.

(丛敏编辑)