

DOI: 10.19783/j.cnki.pspc.220116

基于 SEELM 多专家模型的分布式光伏系统负荷预测方法

张翰霆¹, 陈俊¹, 陈根永²

(1. 湖北工业大学电气与电子工程学院, 湖北 武汉 430068; 2. 郑州大学电气工程学院, 河南 郑州 450001)

摘要: 针对分布式光伏系统负荷所具有的非线性和非平稳等数据分布特性, 基于神经网络与挂起规则, 提出一种基于多模型集成式极限学习机的分布式光伏负荷预测方法。首先, 设计多个神经网络作为子专家模型, 并随机选取每一个网络的初始输入权值。构建挂起规则, 依据数值波动范围在相应时间节点划分各神经网络的类别。针对其中数值波动较大的大误差网络, 基于对应数值概率分布实施在线动态更新, 以实现训练误差、输入权值的双维度同步优化。最后, 将各个子专家模型的优化结果进行整合, 并汇总输出, 从而降低初始权值选取步骤中潜在误差波动的不利影响。基于某地区实际分布式光伏系统实施实证仿真, 结果表明: 在光伏负荷高波动这一特殊数据环境下, 所提出预测模型在预测精度以及输出稳定性两方面均能够保持一定优势, 可进一步推动并改善光伏接入背景下系统负荷预测的性能与效果。

关键词: 光伏系统; 负荷预测; 多专家模型; SEELM

An SEELM-based ensemble method for load forecasting in a distributed photovoltaic systems

ZHANG Hanting¹, CHEN Jun¹, CHEN Genyong²

(1. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China;

2. School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: Given the nonlinear and non-stationary data distribution characteristics of distributed photovoltaic system load, this paper proposes a suspended ensemble extreme learning machine (SEELM) method based on neural networks and a hanging criterion to implement power load prediction in distributed photovoltaic systems. First, multiple neural network models are built, and the initial input weights of each model are randomly assigned. Then the hanging criteria are designed to divide the models into two parts according to the numerical fluctuation ranges at different time spots. For large error models with larger fluctuation ranges, the online updates will be carried out in a probabilistic way to optimize the training error and input weights simultaneously. Finally, the outputs of all submodels are taken for the final output, which can reduce the error fluctuation impacts in the initial weight selection step. Based on an empirical simulation of the actual distributed photovoltaic system in a region, the advantages of the proposed method in terms of prediction accuracy and output stability under the scenarios of large fluctuation in photovoltaic load can be verified, and better capability and performance of load forecasting in the high-proportion photovoltaic systems can thus be achieved.

This work is supported by the National Natural Science Foundation of China (No. 61803343).

Key words: photovoltaic systems; load forecast; ensemble systems; SEELM

0 引言

近年来, 我国能源短缺、环境污染问题日益突出。得益于光伏发电在经济性与环保性两方面的优势, 使得分布式光伏电源接入电网成为当前研究热点^[1-2]。但有别于传统发电方式, 光伏出力具有较强

的随机性与波动性, 这使得电网在调峰、调频以及系统调度和运行等环节面临严峻考验^[3-4]。因此, 实现高效准确的分布式光伏系统负荷预测, 能够助推电网安全运行和系统持续优化。

光伏电源出力同时受到较多因素共同作用, 但具有一定时空分布规律。从空间分布上看, 光伏电源的出力大小受所在位置气候、所处时段日照与云量等诸多因素影响^[5-6]。因此, 众多学者在这一背景

基金项目: 国家自然科学基金项目资助(61803343)

下进行深入研究^[7-11]。

现行光伏负荷预测方法可依据对应实现机理,划分为数学统计和人工智能方法。文献[12]针对光伏接入环境下热电源系统的无功控制过程,构建了一种多时间尺度下的无功优化策略;文献[13]设计了一种改进的有限集模型预测控制(FCS-MPC)策略;文献[14]构建了基于多元自适应回归样条(MARS)的光伏系统输出功率预测方法。此类方法都以时间、气温等因素为自变量,建立光伏负荷数学统计模型,揭示光伏发电变化规律。此外,文献[15]建立了基于LSTM神经网络和综合天气预报的短期光伏功率预测;文献[16]提出了依据二次自适应支持向量机的光伏输出功率预测;文献[17]搭建了一种基于SAPSO-BP和分位数回归的光伏功率区间预测方法。此类方法利用机器学习手段,建立各特征因素与光伏出力间的映射关系实施光伏预测模型^[18-19]。但上述两类方法大多面向确定性预测,即每一时刻对应一个确定值。当面对突发状况(如极端天气)时,确定性预测难以保持精度,也难以满足系统稳定性要求。

为此,另一类光伏负荷预测方法主要基于概率预测,即可预测下一时刻光伏出力状况的对应概率^[20-22]。文献[23]提出了一种基于高斯混合模型的光伏发电功率概率区间预测方法,实施光伏出力大小概率数值区间的预测;文献[24]针对光伏出力爬坡现象预测过程中潜在的误报和漏报,基于模糊概率设计了一种预测方法;文献[25]利用贝叶斯概率原理采用预测偏移率(POR)、预测调整率(PAR)以及预测误差的伪方差(PVPE)三个指标对DFM模型实施了修正,进而利用PSO优化算法加权寻优得到最终的光伏出力组合预测模型;文献[26]构建了一种基于双输入规则模组的深度模糊分析方法,能够提升短期光伏预测性能;文献[27]针对光伏出力的日负荷预测,设计了一种基于CNN-LSTM神经网络的预测方法,可在优化过程中计及多相关变量。此类方法在维持预测结果精度的同时,提高了应对突发状况的适应性能。但在光伏数据具备强随机性这一背景下,这类概率型方法在输出稳定性上仍有进一步提升的空间。

为此,本文通过整合多个神经网络模型,构建了挂起多模型集成极限学习机算法(Suspend Ensemble Extreme Learning Machine, SEELM),针对分布式光伏接入系统的负荷实施预测。首先,随机生成各神经网络的初始权重;然后,设计并行架构下的挂起规则,实施动态优化;在优化过程中区分小误差以及大误差网络,采用不同途径实施子专家

模型权重的动态调整;最终,依据各子专家模型的输出结果,综合修正预测输出,能够抑制初始权重随机选择这一步骤中产生的额外不确定度,降低汇总结果的误差波动。基于某区域光伏接入系统实际运行数据进行实例仿真分析,结果表明:所提出SEELM模型在光伏系统具备更强负荷波动这一背景下,仍保持较好的预测精度及输出稳定性能。

1 SEELM 模型

1.1 极限学习机模型

在第*i*个时间节点上,设 $\mathbf{x}^{(i)} \in R^n$ 、 $\mathbf{y}^{(i)} \in R^m$ 分别为 n_1 维输入向量、 n_2 维输出向量。在总计 N 个时刻的研究周期中,带有输入输出数据样本的训练数据集可写为 (x^i, y^i) , $i=1, L, N$ 。基于这些数据样本,构建合计 M 个单隐层的前馈神经网络模型,可写为sIFNN_{*j*}, $j=1, L, M$ 。设每一个神经网络在隐含层均具有 n_0 ($n_0 = n_1$)个节点,其结构如图1所示。

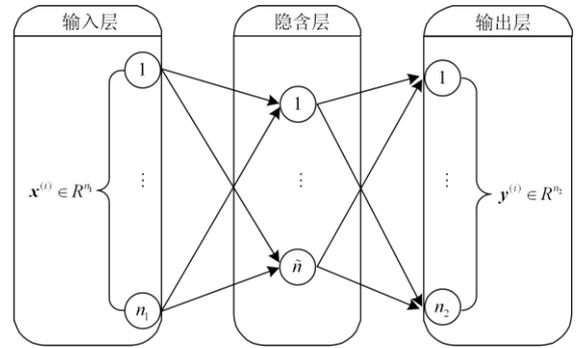


图1 单隐层前馈神经网络结构示意图

Fig. 1 Illustration of single-layer FNN structure

在*i*时刻的第*j*个神经网络sIFNN_{*j*}的输出可写为

$$\sum_{k=1}^{n_0} \beta_{kj} \cdot g(a_{kj} \mathbf{x}^{(i)} + b_{kj}) = \mathbf{y}_j^{(i)} \quad (1)$$

$$\mathbf{a}_{kj} \cdot \mathbf{x}^{(i)} @ [\mathbf{a}_{kj}]^T \cdot \mathbf{x}^{(i)} \quad (2)$$

式中: $\mathbf{a}_{kj} = [a_{1j}, a_{2j}, L, a_{n_0j}]^T$ 为介于第*k*个隐藏与输入神经元的权重向量; $\beta_{kj} = [\beta_{1j}, \beta_{2j}, L, \beta_{n_0j}]^T$ 为介于第*k*个隐藏和输出神经元的权重向量; b_{kj} 是第*k*个隐含层神经元的偏置量; $g(\cdot)$ 为激励函数; $\mathbf{y}_j^{(i)}$ 为网络的输出向量。

通过整合带有数据样本的训练数据集,式(1)可改写为矩阵形式。

$$\mathbf{H}_j^{(N)} \boldsymbol{\beta}_j^{(N)} = \mathbf{Y}_j^{(N)} \quad (3)$$

式中:

$$\mathbf{H}_j^{(N)} = \begin{bmatrix} g(a_{1j}x^{(1)} + b_{1j}) & \mathbf{L} & g(a_{n_j}x^{(1)} + b_{n_j}) \\ & \mathbf{M} & \\ g(a_{1j}x^{(N)} + b_{1j}) & \mathbf{L} & g(a_{n_j}x^{(N)} + b_{n_j}) \end{bmatrix}_{n_j \times n_2}$$

为隐含层输出矩阵, 其中第 k 列元素为第 k 个隐含层神经元的输出向量; $\boldsymbol{\beta}_j^{(N)} = [\beta_{1j}, \mathbf{L}, \beta_{n_j}]_{n_j \times n_2}^T$ 为 $\boldsymbol{\beta}_j^{(N)}$ 所构成的输出权值矩阵; $\mathbf{Y}_j^{(N)} = [y_j^{(1)}, \mathbf{L}, y_j^{(N)}]^T$ 为期望的输出矩阵。

设 \mathbf{a}_{kj} 的初值为 $[-1, 1]$ 间随机选取的 n 维向量, 则可根据此求解第 j 个神经网络的输出权值, 其数学表达式如式(4)所示。

$$(\boldsymbol{\beta}_j)^{(N)} = [\mathbf{H}_j^{(N)}]^+ \mathbf{Y}_j^{(N)} = \left[[\mathbf{H}_j^{(N)}]^T \mathbf{H}_j^{(N)} \right]^{-1} [\mathbf{H}_j^{(N)}]^T \mathbf{Y}_j^{(N)} \quad (4)$$

式中, $[\mathbf{H}_j^{(N)}]^+$ 为矩阵 $\mathbf{H}_j^{(N)}$ 的广义逆矩阵。

由此可得第 j 个神经网络 sIFNN _{j} 的数学表达式。重复以上步骤, 可汇总求解全部总计 M 个初始输入神经网络 sIFNN _{j} ($j=1, \mathbf{L}, M$)。

1.2 挂起规则

针对第 N 时刻的数据样本对 $\{(x^{(N)}, y^{(N)})\}$, 挂起规则实施方式如式(5)所示。

$$\begin{cases} \|y_j^{(N)}\| \leq G, \text{模型挂起} \\ \|y_j^{(N)}\| > G, \text{模型更新} \end{cases} \quad (5)$$

式中: G 为设定的输出阈值, 以判别每个子神经网络的输出对应挂起或更新。若子网络的输出满足 $\|y_j^{(N)}\| \leq G$, 则为挂起模型, 将保留该网络结构, 并在原有基础上进行迭代计算; 若满足 $\|y_j^{(N)}\| > G$, 则为更新模型, 将更新网络结构, 并重新随机选取权值矩阵初值, 再实施迭代。

1.3 挂起模型

基于上述挂起规则判别结果, 对于神经网络 SLFNN _{j} ($j=1, \mathbf{L}, Z$), 当输入一组新数据样本 $(x^{(N+1)}, y^{(N+1)})$ 时, 可在原有网络结构的基础上进行迭代计算。由此, 可将式(3)拓展为

$$\begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{N+1} \end{bmatrix} \boldsymbol{\beta}_j^{(N+1)} = \begin{bmatrix} \mathbf{Y}_j^{(N)} \\ \mathbf{y}_j^{N+1} \end{bmatrix} \quad (6)$$

式中: $\mathbf{h}_j^{N+1} = [g(a_{1j}x^{N+1} + b_{1j}), \mathbf{L}, g(a_{n_j}x^{N+1} + b_{n_j})]_{1 \times n_2}$

为新输入数据样本 $(x^{(N+1)}, y^{(N+1)})$ 对应的隐含层输出矩阵; $\mathbf{y}_j^{(N)}$ 为 $(x^{(N+1)}, y^{(N+1)})$ 对应的输出。

$\boldsymbol{\beta}_j^{(N+1)}$ 可写为

$$\boldsymbol{\beta}_j^{(N+1)} = \begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{(N+1)} \end{bmatrix}^+ \begin{bmatrix} \mathbf{Y}_j^{(N)} \\ \mathbf{y}_j^{(N+1)} \end{bmatrix} = \left[\mathbf{L}_j^{(N+1)} \right]^{-1} \begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{(N+1)} \end{bmatrix}^T \begin{bmatrix} \mathbf{Y}_j^{(N)} \\ \mathbf{y}_j^{(N+1)} \end{bmatrix} \quad (7)$$

为降低运算复杂度, 改善运行效率, 针对 $\boldsymbol{\beta}_j^{(N+1)}$ 的递推构建在线训练方法, 具体步骤如下所述。

首先, 由 $\mathbf{L}_j^{(N)} = (\mathbf{H}_j^{(N)})^T \mathbf{H}_j^{(N)}$ 可解得

$$\begin{aligned} \mathbf{L}_j^{(N+1)} &= \begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{(N+1)} \end{bmatrix}^T \begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{(N+1)} \end{bmatrix} = \\ &= \left[(\mathbf{H}_j^{(N)})^T (\mathbf{h}_j^{(N+1)})^T \right] \begin{bmatrix} \mathbf{H}_j^{(N)} \\ \mathbf{h}_j^{(N+1)} \end{bmatrix} + \\ &= (\mathbf{L}_j)^{(N)} + \left[\mathbf{h}_j^{(N+1)} \right]^T \mathbf{h}_j^{(N+1)} \end{aligned} \quad (8)$$

其次, 结合式(7)可得

$$\begin{aligned} \boldsymbol{\beta}_j^{(N+1)} &= \boldsymbol{\beta}_j^{(N)} + \left[\mathbf{L}_j^{(N+1)} \right]^{-1} \left[\mathbf{h}_j^{(N+1)} \right]^T \cdot \\ &= \left[\mathbf{y}_j^{(N+1)} - \mathbf{h}_j^{(N+1)} \boldsymbol{\beta}_j^{(N)} \right] \end{aligned} \quad (9)$$

然后, 结合 Woodbury 定理, 可求得

$$\begin{aligned} \left[\mathbf{L}_j^{(N+1)} \right]^{-1} &= \left[\mathbf{L}_j^{(N)} + (\mathbf{h}_j^{(N+1)})^T \mathbf{h}_j^{(N+1)} \right]^{-1} = \\ &= \left[\mathbf{L}_j^{(N+1)} \right]^{-1} - \left[\mathbf{L}_j^{(N+1)} \right]^{-1} \left[\mathbf{h}_j^{(N+1)} \right]^T \cdot \\ &= \left[\mathbf{I} + \mathbf{h}_j^{(N+1)} \boldsymbol{\beta}_j^{(N)} \left[\mathbf{L}_j^{(N)} \right]^{-1} \left[\mathbf{h}_j^{(N+1)} \right]^T \right]^{-1} \cdot \\ &= \mathbf{h}_j^{(N+1)} \left[\mathbf{L}_j^{(N)} \right]^{-1} \end{aligned} \quad (10)$$

进而设 $\mathbf{F}_j^{(N+1)} = \left[\mathbf{L}_j^{(N+1)} \right]^{-1}$, 则 $\boldsymbol{\beta}_j^{(N+1)}$ 的递推公式可写为

$$\begin{aligned} \boldsymbol{\beta}_j^{(N+1)} &= \boldsymbol{\beta}_j^{(N)} + \mathbf{F}_j^{(N+1)} (\mathbf{H}_j^{(N+1)})^T \cdot \\ &= \left[\mathbf{y}_j^{(N+1)} - \mathbf{h}_j^{(N+1)} \boldsymbol{\beta}_j^{(N)} \right] \end{aligned} \quad (11)$$

$$\mathbf{F}_j^{(N+1)} = \mathbf{F}_j^{(N)} - \mathbf{F}_j^{(N)} \left[\mathbf{h}_j^{(N+1)} \right]^T \cdot$$

$$\left[\mathbf{I} + \mathbf{h}_j^{(N+1)} \mathbf{F}_j^{(N)} \left[\mathbf{h}_j^{(N+1)} \right]^T \right]^{-1} \cdot \mathbf{h}_j^{(N+1)} \mathbf{F}_j^{(N)} \quad (12)$$

因此, 利用式(11)一式(12)可实现神经网络 SLFNN _{j} 的在线训练。

根据式(11), 可求解挂起模型的输出, 其数学表达式为

$$y_j^{(N+1)} = h_j^{(N+1)} \beta_j^{(N+1)} \quad (13)$$

由式(13)可得总计 Z 个挂起模型的输出。

1.4 更新模型

将更新模型记为: $SLFNN_j(j=Z+1, L, M)$ 。

当输入一组新数据样本 $(x^{(N+1)}, y^{(N+1)})$ 时, 需重新构造神经网络结构。

通过初始步骤中随机选取的向量 a_{kj} , 结合式(4), 可求取 β_j^N 。则更新模型的输出如式(14)所示。

$$y_j^{(N+1)} = h_j^{(N+1)} \beta_j^{(N)} \quad (14)$$

由此可得 $M-Z$ 个更新模型的输出为

$$h_j^{(N+1)} = \left[g(a_{1j} \cdot x^{(N+1)} + b_{1j}), L, g(a_{mj} \cdot x^{(N+1)} + b_{mj}) \right]_{1 \times n_h} \quad (15)$$

1.5 多模型集成

结合上述结果, 整合全部 Z 个挂起模型和 $M-Z$ 个更新模型, 采用算术平均方法求解 M 个神经网络 $SLFNN_j(j=1, L, M)$ 的汇总输出 $y_{out}^{(N+1)}$, 其数学表达式如式(16)所示。

$$y_{out}^{(N+1)} = \frac{1}{M} \left(\sum_{j=1}^M y_j^{(N+1)} \right) \quad (16)$$

综上所述, 当输入数据更新时, 每个子模型都会通过挂起规则进行判断, 并通过模型挂起或更新分别进行优化, 最后得出总的平均值。在确保整个网络输出结果准确性的前提下, 可进一步提升方法的运算效率。

1.6 光伏负荷预测整体框架

本文设计 SEELM 模型实施分布式光伏接入系统负荷预测。其中的主要步骤如下:

1) 实施历史数据预处理。主要包括对电力负荷和影响因素(气象因素、时间因素)的归一化处理, 得到训练模型样本数据。

2) 确定 SEELM 多专家模型的拓扑结构, 并对参数进行初始化。

3) 根据第 i 个时刻的输入输出数据 $\{(x^i, y^i)\}$, $i=1, L, N$ 训练各神经网络。

4) 针对一组新的输入、输出数据样本 $\{x^{(N+1)}, y^{(N+1)}\}$, 利用挂起规则判别模型类别。

5) 分别运行挂起模型或更新模型。

6) 由式(16)计算下一时刻输出 $y_{out}^{(N+2)}$ 。

7) 返回步骤 4), 并重复上述过程, 直至预测结束。

2 算例分析

本文基于东北某地区分布式光伏接入网络实施

算例仿真。其中, 每组样本数据由当天需求负荷值、昨日需求负荷值、日期以及气象特征(日平均温度、相对湿度、日降水量、风向、平均风速、天气类型、云量等)组成。在去除异常数据和缺失数据后, 共计 2 906 组数据。算例数据具有较为显著的波动性, 经统计可得, 样本数据中“当天需求负荷值”、“昨日需求负荷值”两组特征数据的变异系数分别为 69.35% 与 58.83%。因此, 本文采用交叉验证, 以所包含的 2 034 组(70%)作为训练集, 436 组(15%)作为验证集, 436 组(15%)作为测试集。

首先, 选择 SEELM 模型训练函数。为分析在不同训练函数下 SEELM 模型的预测性能优劣, 依据训练步长对以下常用训练函数实施验证对比: Trainrp 弹性法、Traingdx 自适应学习速率法、Traincgf 共扼梯度法、Trainbfg 拟牛顿法、Trainlm Levenberg-Marquardt 法。上述训练函数的最优训练步长对比如图 2 所示。

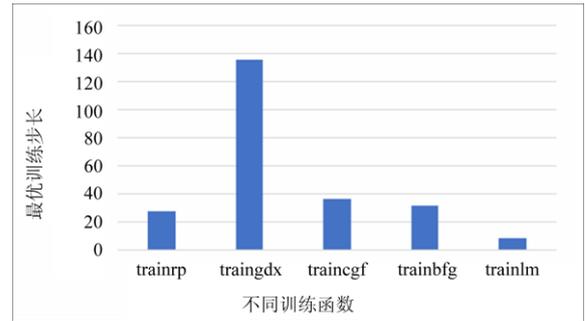


图 2 不同训练函数的模型最优训练步长对比

Fig. 2 Training steps comparison of different training functions

由图 2 可得, 采用 traingdx 的 SEELM 模型训练步长最大, 为 136; 采用 trainlm 的训练步长最小, 步长仅为 8; 而其他三种 BP 神经网络训练步长差异不大, 最优训练步长均在 30 左右。由此, 采用 Levenberg-Marquardt 训练函数的 SEELM 模型预测性能更强, 其训练步长曲线如图 3 所示。

由图 3 可知, Levenberg-Marquardt 训练函数的步长训练由 0 向 1 增大时, 均方误差迅速下降, 其后下降速度放缓, 训练步长到达 8 步时的均方误差为 0.028 539。

高比例光伏系统负荷具有“非平稳”特征, 采用不同的方法会对非平稳时间序列预测结果产生影响^[28], 为验证 SEELM 模型的预测性能, 以 PSO、BPNN、LSTM 模型的预测结果进行对比^[29-30]。基于部分测试数据, 本文所提 SEELM 预测模型的预测示例如图 4 所示, 其中负荷曲线下散点为相应时间点的误差值。

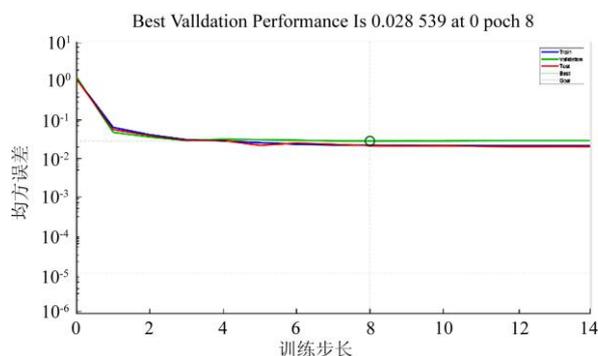


图3 Levenberg-Marquardt 法训练步长曲线

Fig. 3 Training curve by the Levenberg-Marquardt training functions

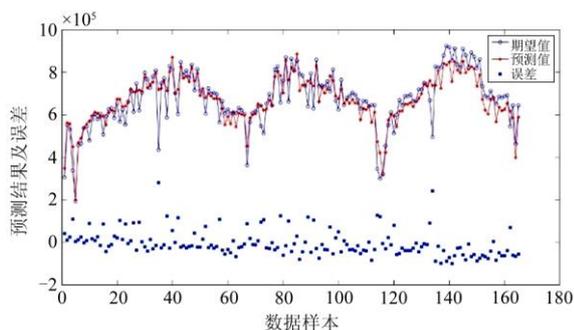


图4 SEELM 模型预测误差

Fig. 4 Prediction performance of the SEELM model

为整体分析各预测模型性能, 分别对比了各模型负荷预测的准确度及运算效率。一方面, 预测准确度基于平均绝对百分比误差(MAPE)及均方根误差(RMSE)实施评估, 结果如表 1 所示。

表 1 预测模型准确性对比

Table 1 Precision comparison of different forecast models

预测模型	MAPE/%	RMSE/kW
SEELM	6.971 0	5.543 1
LSTM	7.676 9	6.469 3
BPNN	8.649 7	6.659 5
PSO	9.649 1	7.058 8

从表 1 中整体误差对比可得, SEELM 预测模型的平均绝对误差最小, 低于 0.07, 其单位均方根误差也相对最低, 表明其具有更优秀的预测性能。相较之下, PSO 模型由于在结果反馈性能上存在限制, 从而导致预测效果稍差。此外, 同样基于神经网络原理的 LSTM 及 BPNN 的预测误差仍相对较高。对比结果充分体现了 SEELM 模型针对神经网络模型的改进作用。所提出模型在神经网络的基础上, 通过挂起规则将多个神经网络的结果进行合理

整合, 能够显著降低随机选取这一步骤造成的误差。

另一方面, 基于同一主机实施相同预测, 对比各模型的运算效率, 结果如表 2 所示。

表 2 预测模型运算效率对比

Table 2 Computation efficiency of different forecast models

预测模型	迭代次数	运行时间/s
SEELM	43	6.3
LSTM	123	10.5
BPNN	212	17.7
PSO	298	24.8

由表 2 可得, SEELM 模型在预测效率上同样具有一定优势。结合准确性对比结果, SEELM 模型在应对波动性较大的数据环境下, 能够保持较强的综合预测性能。因此, 该模型可适用于分布式光伏系统的负荷预测场景。

3 结论

针对高比例光伏系统负荷所具有的非线性、非平稳、异方差数据特性, 本文提出一种基于多模型集成极限学习模型的负荷预测方法, 能够有效改善预测结果的稳定度, 从而助力系统安全可靠运行。本文主要工作归纳如下:

1) 设计输出权重连接优化模型, 针对不同时间序列下的多个神经网络模型构建并行运算架构, 综合各神经网络的预测输出结果, 以减小单个网络潜在输出不确定度。

2) 建立挂起规则模型, 在所有神经网络初始权重实行随机设置这一前提下, 依据各子模型在任意时刻下的输出误差, 分类型实施针对权重自适应调整, 降低存在较大误差的子模型权重, 从而降低整体输出结果的误差波动。

参考文献

- [1] 潘晴宇. 考虑分布式电源接入的变电站规划关键技术研究[J]. 电力系统保护与控制, 2021, 49(6): 98-104.
PAN Qingyu. Research on key technologies of substation planning considering distributed power access[J]. Power System Protection and Control, 2021, 49(6): 98-104.
- [2] 肖异瑶, 熊宁, 周晨曦, 等. 计及分布式电源的乡村地区变电站动态升压规划[J]. 电力系统保护与控制, 2021, 49(7): 86-93.
XIAO Yiyao, XIONG Ning, ZHOU Chenxi, et al. Booster planning considering dynamic development of load and distributed generator for substations in low-load density areas[J]. Power System Protection and Control, 2021, 49(7): 86-93.

- [3] 黎嘉明, 艾小猛, 文劲宇, 等. 光伏发电功率持续时间特性的概率分布定量分析[J]. 电力系统自动化, 2017, 41(6): 30-36.
LI Jiaming, AI Xiaomeng, WEN Jinyu, et al. Quantitative analysis of probability distribution for duration time characteristic of photovoltaic Power[J]. Automation of Electric Power Systems, 2017, 41(6): 30-36.
- [4] FARIAS-BASULTO G, REYES-FIGUEROA P, ULBRICH C, et al. Validation of a multiple linear regression model for CIGSSE photovoltaic module performance and PMPP prediction[J]. Solar Energy, 2020, 208(1): 859-865.
- [5] 方保民, 李红志, 孔祥鹏, 等. 含高比例光伏出力的长期分布式储能配置研究[J]. 电力系统保护与控制, 2021, 49(2): 121-129.
FANG Baomin, LI Hongzhi, KONG Xiangpeng, et al. Research on long-term distributed energy storage configuration with a high proportion of photovoltaic output[J]. Power System Protection and Control, 2021, 49(2): 121-129.
- [6] ZHU H, SHI Y, WANG H, et al. New feature extraction method for photovoltaic array output time series and its application in fault diagnosis[J]. IEEE Journal of Photovoltaics, 2020, 10(4): 1133-1141.
- [7] 王连民, 李玮, 张克甲, 等. 分布式光伏电源并网可靠性研究[J]. 制造业自动化, 2021, 43(3): 156-159.
WANG Lianmin, LI Wei, ZHANG Kejia, et al. Research on grid connected reliability of distributed photovoltaic power generation[J]. Manufacturing Automation, 2021, 43(3): 156-159.
- [8] 徐可寒, 张哲, 刘慧媛, 等. 光伏电源故障特性研究及影响因素分析[J]. 电工技术学报, 2020, 35(2): 359-371.
XU Kehan, ZHANG Zhe, LIU Huiyuan, et al. Study on fault characteristics and its related impact factors of photovoltaic generator[J]. Transactions of China Electrotechnical Society, 2020, 35(2): 359-371.
- [9] 郭杉, 张源渊, 贾俊青, 等. 基于蒙特卡洛的配电网光伏消纳能力评估[J]. 浙江电力, 2021, 40(6): 8-14.
GUO Shan, ZHANG Yuanyuan, JIA Junqing, et al. Evaluation of photovoltaic consumption capacity of distribution network based on Monte Carlo method[J]. Zhejiang Electric Power, 2021, 40(6): 8-14.
- [10] CHEN W, DUAN Y, GUO L, et al. Modeling and prediction of radiated emission from solar cellina photovoltaic generation system[J]. IEEE Journal of Photovoltaics, 2016, 6(2): 540-545.
- [11] HASHEMI B, TAHERI S, CRETU A M, et al. Systematic photovoltaic system power losses calculation and modeling using computational intelligence techniques[J]. Applied Energy, 2021(1): 284-297.
- [12] 张宏, 董海鹰, 陈钊, 等. 基于模型预测控制的光热-光伏系统多时间尺度无功优化控制策略研究[J]. 电力系统保护与控制, 2020, 48(9): 135-142.
ZHANG Hong, DONG Haiying, CHEN Zhao, et al. Multi-time scale reactive power optimal control strategy of a CSP-PV system based on model predictive control[J]. Power System Protection and Control, 2020, 48(9): 135-142.
- [13] 李立雄, 阳同光, 袁越阳, 等. 基于改进有限集模型预测控制策略的光伏发电系统最大功率点追踪算法[J]. 电力系统保护与控制, 2021, 49(17): 28-37.
LI Lixiong, YANG Tongguang, YUAN Yueyang, et al. Maximum power point tracking algorithm of a photovoltaic power generation system based on an improved finite set model predictive control strategy[J]. Power System Protection and Control, 2021, 49(17): 28-37.
- [14] 鲍长庚, 闫贻鹏, 黄一楠, 等. 基于多元自适应回归样条的光伏并网系统日输出功率预测[J]. 电力系统保护与控制, 2021, 49(5): 124-131.
BAO Changgeng, YAN Yipeng, HUANG Yinan, et al. Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines[J]. Power System Protection and Control, 2021, 49(5): 124-131.
- [15] 殷豪, 陈云龙, 孟安波, 等. 基于二次自适应支持向量的光伏输出功率预测[J]. 太阳能学报, 2019, 48(7): 1866-1873.
YIN Hao, CHEN Yunlong, MENG Anbo, et al. Forecasting photovoltaic power based on quadric self-adaptive SVM model[J]. Acta Energiæ Solaris Sinica, 2019, 48(7): 1866-1873.
- [16] HOSSAIN M, MAHMOOD H. Short term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast[J]. IEEE Access, 2020, 8(1): 172524-172533.
- [17] 贾德香, 吕干云, 林芬, 等. 基于 SAPSO-BP 和分位数回归的光伏功率区间预测[J]. 电力系统保护与控制, 2021, 49(10): 20-26.
JIA Dexiang, LÜ Ganyun, LIN Fen, et al. Photovoltaic power interval prediction based on SAPSO-BP and quantile regression[J]. Power System Protection and Control,

- 2021, 49(10): 20-26.
- [18] 安鹏跃, 孙堃. 基于相似日和回声状态网络的光伏发电功率预测[J]. 智慧电力, 2020, 48(8): 38-43.
AN Pengyue, SUN Kun. Photovoltaic power prediction based on similar day and echo state networks[J]. Smart Power, 2020, 48(8): 38-43.
- [19] 陆爽, 徐伟明, 刘维亮, 等. 基于聚类再回归方法的光伏发电量短期预测[J]. 浙江电力, 2020, 39(7): 48-54.
LU Shuang, XU Weiming, LIU Weiliang, et al. Short-term forecasting of PV power generation based on clustering and later regression[J]. Zhejiang Electric Power, 2020, 39(7): 48-54.
- [20] 田浩含, 撤奥洋, 于立涛, 等. 基于 GRA-LSTM 神经网络的区域综合能源系统多元负荷短期预测模型[J]. 广东电力, 2020, 33(5): 44-51.
TIAN Haohan, HAN Aoyang, YU Litao, et al. Research on multi-load short-term forecasting model of regional integrated energy system based on GRA-LSTM neural network[J]. Guangdong Electric Power, 2020, 33(5): 44-51.
- [21] GU B, SHEN H, LEI X, et al. Forecasting and uncertainty analysis of day-ahead photovoltaic power using a novel forecasting method[J]. Applied Energy, 2021, 299(1): 117-129.
- [22] PEYGHAMI S, WANG Z, BLAABJERG F. A guideline for reliability prediction in power electronic converters[J]. IEEE Transactions on Power Electronics, 2020, 35(10): 10958-10968.
- [23] 周帆, 郑常宝, 胡存刚, 等. 基于高斯混合模型的光伏发电功率概率区间预测[J]. 科学技术与工程, 2021, 21(24): 10284-10290.
ZHOU Fan, ZHENG Changbao, HU Cungang, et al. Prediction of photovoltaic power generation probability interval based on gaussian mixture model[J]. Science Technology and Engineering, 2021, 21(24): 10284-10290.
- [24] 朱文立, 张利, 杨明, 等. 考虑日周期性影响的光伏功率爬坡事件非精确概率预测[J]. 电力系统自动化, 2019, 43(20): 31-38.
ZHU Wenli, ZHANG Li, YANG Ming, et al. Imprecise probabilistic prediction of photovoltaic power ramp event considering daily periodic effect[J]. Automation of Electric Power Systems, 2019, 43(20): 31-38.
- [25] 张雪松, 李鹏, 周亦尧, 等. 基于贝叶斯概率的光伏出力组合预测方法[J]. 太阳能学报, 2021, 42(10): 80-86.
ZHANG Xuesong, LI Peng, ZHOU Yiyao, et al. Photovoltaic output combination forecasting method based on Bayesian probability[J]. Acta Energetica Solaris Sinica, 2021, 42(10): 80-86.
- [26] CL A, CZ A, WEI P, et al. Accurate prediction of short-term photovoltaic power generation via a novel double-input-rule-modules stacked deep fuzzy method[J]. Energy, 2020, 212(1): 192-201.
- [27] QU J, QIAN Z, PEI Y. Day-ahead hourly photovoltaic power forecasting using attention-based CNN-LSTM neural network embedded with multiple relevant and target variables prediction pattern[J]. Energy, 2021, 232(1): 131-142.
- [28] NOGUERA A, CASTELLANOS L, SILVA L, et al. Optimum design of a hybrid diesel-ORC/photovoltaic system using PSO: case study for the city of Cujubim, Brazil[J]. Energy, 2017, 142(1): 33-45.
- [29] 贾嵘, 李云桥, 张惠智, 等. 基于改进 BP 神经网络的光伏阵列多传感器故障检测定位方法[J]. 太阳能学报, 2018, 39(1): 110-116.
JIA Rong, LI Yunqiao, ZHANG Huizhi, et al. Multi-sensor fault detection and positioning method of photovoltaic array based on improved BP neural network[J]. Acta Energetica Solaris Sinica, 2018, 39(1): 110-116.
- [30] HAO Z, DNA B, KWA B, et al. Photovoltaic power forecasting based on GA improved Bi-LSTM in microgrid without meteorological information[J]. Energy, 2021, 231(1): 120-130.
-
- 收稿日期: 2022-01-25; 修回日期: 2022-02-28
- 作者简介:
- 张翰霆(2001—), 男, 本科, 研究方向为电力系统自动化; E-mail: 1910201408@hbut.edu.cn
- 陈俊(1976—), 男, 博士, 副教授, 研究方向为分布式发电系统; E-mail: chenjun@hbut.edu.cn
- 陈根永(1964—), 男, 博士, 教授, 研究方向为电力系统规划与运行。
- (编辑 张爱琴)