

# 计及分布式能源时序不确定性的短期负荷预测技术

杨小龙<sup>1</sup>, 姚陶<sup>1</sup>, 孙辰军<sup>1</sup>, 魏新杰<sup>2</sup>, 张华铭<sup>3</sup>, 孙毅<sup>4</sup>

(1.国网河北省电力有限公司信息通信分公司, 河北 石家庄 050000; 2.国网河北省电力有限公司, 河北 石家庄 050021; 3.北京清软创新科技股份有限公司, 北京 100080; 4.华北电力大学 电气与电子工程学院, 北京 102206)

**摘要:** 随着城镇分布式光伏规模快速增长,其出力的随机波动特性对城镇负荷的影响也不断加剧。传统方法难以准确预测上述场景下的负荷变化规律,不利于电网的安全稳定运行。面对大规模分布式光伏接入的负荷预测场景,文章提出一种考虑分布式光伏影响下的短期负荷预测方法。光伏接入下的电网侧负荷为实际用电负荷与光伏出力之间的差值,因此,文章在构造输入数据之前,首先采用大数据挖掘技术,分析光伏出力和用户侧负荷特性以及二者与各自影响因素之间的相关性,通过特征构造选出相关性较大的影响因素作为负荷预测模型的输入特征集;然后构建融合自注意力机制的LSTM神经网络预测模型,深度挖掘负荷序列特征。采用灰狼算法对预测模型进行优化,确定预测效果最佳的模型。算例分析结果表明,文章所提方法能够有效提高含分布式光伏的净负荷预测精度。

**关键词:** 分布式光伏; 相关性分析; 自注意力机制; LSTM; 灰狼优化算法; 负荷预测

**中图分类号:** TK51; TM7 **文献标志码:** A **文章编号:** 1671-5292(2024)01-0096-08

## 0 引言

目前,全球能源面临着较为严峻的形式,我国正处于能源绿色低碳转型的关键时期<sup>[1]</sup>,我国“十四五”规划明确指出,要力争在2025年实现“碳达峰”,因此加快构建以新能源为主体的新型电力系统对“双碳”目标的实现有着极其重要的作用<sup>[2]</sup>。风电、光伏等新能源的大规模开发及高比例并网能够大幅度降低碳排放量<sup>[3,4]</sup>,其中分布式光伏电源作为一种重要的新能源发电形式,对优化能源结构,推动节能减排,实现经济可持续发展具有重要意义。在新型电力系统下,配电网也将迎来全面的升级改造,全面、准确地掌握负荷的变化规律将会为配电网的规划建设以及电网运营者的经营决策提供可靠的信息和依据。但是,分布式光伏电源不同于传统能源发电,它具有随机性、波动性以及间歇性等特性,这给负荷预测带来一定的困难,因此在新型电力系统建设过程中,要充分考虑分布式能源接入对新型电力系统的影响<sup>[5]</sup>。

短期负荷预测的方法有很多,主要方法有时间序列法<sup>[6]</sup>、回归分析法<sup>[7]</sup>、XGBoost<sup>[8]</sup>、模糊预测

法<sup>[9]</sup>、深度神经网络法等。其中,文献[10]提出了一种数据挖掘预处理的支持向量机预测系统,通过数据挖掘技术,找出与预测日具有相同天气条件的历史短期负荷组成数据序列,作为支持向量机的训练数据,从而提高预测精度。文献[11]提出了一种基于深度神经网络混合模型的短期负荷预测方法,先采用卷积神经网络提取特征向量,再采用长短期记忆神经网络提取负荷时序特征,该方法在预测精度上有所提升。文献[12]对传统极限学习机(ELM)算法进行了改进,采用全局寻优法对ELM算法进行优化,该方法只是对ELM算法的参数进行了寻优,但是对负荷序列内部特征的学习还存在一定的局限性。文献[13]提出了一种改进的集成经验模态分解和深度信念网络相结合的用户侧净负荷预测方法,该方法首先通过改进的经验模态分解算法将原始净负荷分解为若干个本征模态函数(IMF),再使用深度信念网络对每个IMF分量进行特征提取和预测,最后将多个目标预测结果累加得到最终用户侧净负荷预测结果,该方法能够解决分布式电源与负荷耦合下的负荷预测问题,但是未考虑外部环境因素对净负荷的影响。

收稿日期: 2023-07-07。

基金项目: 国家电网有限公司科技项目(5204XA22000D)。

作者简介: 杨小龙(1989-),男,硕士,工程师,研究方向为电气工程、智慧能源系统、虚拟电厂。E-mail: 277135930@qq.com

综上所述,目前大多数预测算法在负荷预测领域有着出色的表现,随着分布式电源的大规模接入,用户侧负荷预测难度将大大增加,因此对电网调度工作者来说,研究新的预测方法和技术变得极其重要<sup>[14]</sup>。

本文基于分布式光伏接入对电网负荷的影响,提出了一种分布式光伏接入场景下的短期负荷预测方法。由于分布式电源主要部署在用户侧,因此对不同的用户产生的影响不同。为了提高电网负荷短期预测的精度,文章首先基于大数据分析技术探索用户负荷特性、分布式光伏出力特性以及外部因素对二者变化趋势的影响。在上述分析基础上,提出了融合自注意力的长短期记忆神经网络短期净负荷预测模型,充分提取时间序列之间的依赖关系,并采用灰狼优化算法对上述预测模型的参数进行优化,训练出预测能力最优的模型。最后通过算例分析,验证了本文所提方法的合理性和有效性。

### 1 考虑分布式光伏接入的配电网

光伏发电是一种将太阳能转换为电能的新型发电技术,具有清洁、可再生的特点,具有广阔的发展前景。目前分布式光伏主要有屋顶光伏、产业园区光伏以及农业养殖光伏等。如图1所示,分布式光伏发电系统通过一系列变换输出交流电供给用户自身负载,多余发电量可以存储起来或者上送电网。这种发电方式具有输出功率小,发电用电共存,清洁高效,可灵活调节等特点,在一定程度上可以缓解局部地区的用电压力。

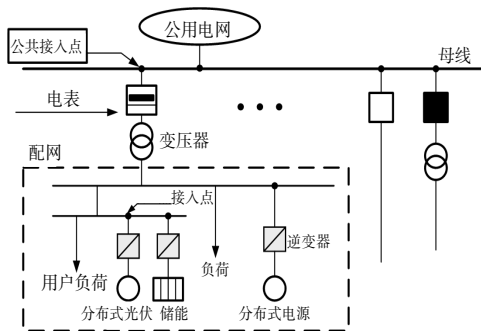


图1 用户侧接入分布式光伏接线图

Fig.1 Distributed photovoltaic wiring diagram for user access

分布式光伏一般安装在电表之后,因此装置采集到的数据为光伏出力和配电网用户负荷的耦合结果,即配电网净负荷<sup>[15]</sup>。如式(1)所示,净负荷指用户实际负荷与分布式光伏出力的差值。

$$P_n = P_{\text{actual}} - P_{\text{pv}} \quad (1)$$

式中: $P_n$ 为净负荷; $P_{\text{actual}}$ 为用户实际负荷; $P_{\text{pv}}$ 为光伏出力。

图2为光伏出力特性以及含分布式光伏的负荷曲线,选取连续3d的历史数据,采样频率为15min,共288个负荷点。从图2中可以看出,间歇性分布式光伏接入配电网改变了原有的负荷特性,白天时段分布式光伏开始发电,净负荷出现低估且伴有强的波动性和间歇性,夜晚光伏不出力,净负荷保持原有特性。




图2 含分布式光伏的负荷特性曲线

Fig.2 Load characteristic curve with distributed PV

### 2 负荷特性及相关性分析

#### 2.1 Pearson 相关系数

Pearson 相关系数通常可以用来定量分析变量之间的线性相关性,通过式(2)可以计算两个变量之间的相关程度。

$$\rho_{X,Y} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2 \sum (Y - \bar{Y})^2}} \quad (2)$$

式中: $\rho_{X,Y}$ 为相关系数; $X$ 为自变量; $Y$ 为因变量。

$\rho_{X,Y}$  的取值为[0, 1],相关系数越接近0,变量之间的相关性越弱;相关系数的绝对值取值越靠近1时,两个变量之间的相关性越强。通常情况下通过划分 Pearson 系数的取值范围来判断变量的相关性强度,当  $0.6 < |\rho_{X,Y}| \leq 1$ ,表示强相关;当  $0.4 < |\rho_{X,Y}| \leq 0.6$ ,表示中等程度相关;当  $0 < |\rho_{X,Y}| \leq 0.4$ ,表示弱相关或无关。假设自变量是  $X$ ,因变量是  $Y$ ,若  $\rho_{X,Y}$  越大,则  $X$  与  $Y$  之间的相关性越强,从而可以判别  $X$  变化对  $Y$  的影响。

#### 2.2 用户侧负荷特性及其影响因素

按用电性质可将负荷大致分为工业负荷、商业负荷以及居民负荷<sup>[16]</sup>。不同类型的用户负荷特性差异较大,工业用户的用电量较大,负荷较为稳

定。商业负荷主要指大型商场、写字楼等商业场所的照明、空调、动力等用电负荷,覆盖面积较大,且用电增长平稳,具有典型的季节性波动特性。居民负荷特性与人们的日常生活方式以及工作规律有着较为紧密的联系,主要用电负荷是城镇居民的家用电器,同样有着明显的季节性波动特点。图3为三大类型用户负荷的日特性曲线。




图3 三大类型用户日用电负荷特性曲线  
Fig.3 Daily power load characteristic curves of three types of users

为了探索外部环境因素对用户侧负荷的影响,文章通过计算 Pearson 相关系数定量分析变量间的相关性。表1给出了天气因素与某商业用户负荷之间的相关性系数,可以看出温度对用户负荷变化规律的影响较为显著。因为当外界环境温度过高时,大量制冷设备被投入使用,负荷也相应增加;温度过低,用户须要投入大量制热设备来提高室内温度,导致用电负荷也随之增加。

表1 某商业用户负荷与天气因素之间的相关系数  
Table 1 Correlation coefficient between a commercial user's load and weather factors

影响因素	温度	湿度	风速	风向	气压
Pearson 相关系数	0.837	-0.520	-0.295	0.096	0.368

### 2.3 光伏出力特性及其影响因素分析

图4给出了4种不同天气条件下光伏出力




图4 不同类型天气下光伏日出力特性  
Fig.4 Photovoltaic sunrise force characteristics under different types of weather

曲线。不同天气类型下,光伏出力会出现较大的差异。晴天光伏出力较好,光伏出力呈现一个山峰型;多云天,光伏出力受云的影响,出现较大的波动性;当出现阴转晴的情况时,分布式光伏出力将随着阴转晴的过程逐渐增强;在阴雨天,光伏出力较差。因此,不同类型的天气造成了光伏出力的随机性和不确定性。

为了定量分析气象因素对光伏出力的影响,表2给出了光伏出力与各影响因素之间的 Pearson 相关系数。由表2可以看出,温度、湿度以及直接辐射度与光伏出力之间存在着较强的相关性,而风速、气压与光伏出力之间的相关性较弱。因此,温度、湿度、直接辐射度对光伏出力有着较大的影响。

表2 光伏出力与各影响因素之间的相关系数  
Table 2 Correlation coefficients between photovoltaic output and various influencing factors

影响因素	温度	湿度	直接辐射度	风速	气压
Pearson 相关系数	0.547	0.681	0.963	0.288	0.025

通过对光伏出力特性以及影响因素分析,可以得出在天气晴朗条件下,光伏出力受光照强度和环境温度的制约,表现出明显的规律性和周期性;在天气条件不好的情况下,其出力会出现不确定性和随机性。

### 3 相关算法及预测模型

#### 3.1 自注意力机制

在进行时间序列建模时,不同时刻点之间存在着一定的相互依赖关系,自注意力机制<sup>[7]</sup>(Self Attention Mechanism)可以最大程度上挖掘任意两个点之间的关系,在进行时序预测时抽取强相关特征点的关键信息,使得预测更加准确。

首先,对样本的  $m$  个序列  $[x_1, x_2, \dots, x_m]$  进行自适应线性映射,样本被转换成 3 个长度为  $d$  的向量  $q, k, v$ , 再将 3 个向量并联组合成矩阵  $Q, K, V$ , 根据式(3)计算矩阵  $S$ ,  $S$  为  $m$  个序列间的权值集合;再经过式(4)标准化后变成  $S_n[S_{n1}, S_{n2}, \dots, S_{nm}]^T$ 。

$$S = QK^T \quad (3)$$

$$S_n = \frac{S}{\sqrt{d}} \quad (4)$$

根据式(5),使用 Soft max 函数将权值转换成概率形式  $P=[P_1, P_2, \dots, P_m]$ 。

$$P_i = \text{Soft max}(S_n) = \frac{e^{s_{ni}}}{\sum_{i=1}^m e^{s_{ni}}} \quad (5)$$

最后,根据式(6)获取加权矩阵  $\mathbf{Z}$ :

$$\mathbf{Z} = \mathbf{V} \cdot \mathbf{P} \quad (6)$$

因此,自注意力过程如下:

$$SA(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Soft max} \frac{\mathbf{Q} \cdot \mathbf{K}^T}{\sqrt{d}} \mathbf{V} \quad (7)$$

### 3.2 长短期记忆神经网络

时间序列具有较强的历史依赖性,相邻时间点的关联性较大。为了更好地学习这种时序特征,本文采用长短期记忆神经网络(Long Short Term Memory, LSTM)<sup>[18,19]</sup>,LSTM 延续了 RNN 主体结构,区别在于 LSTM 在隐藏层中增加了门控结构,分别是遗忘门、输入门、输出门,同时新增了一个记忆单元,通过记忆单元  $c_t$  来保持长期记忆,具体更新流程如下:

$$c_t = f_t \times c_{t-1} + i_t \times a_t \quad (8)$$

$$f_t = \sigma(w_f \times h_{t-1} + v_f \times x_t) \quad (9)$$

$$i_t = \sigma(w_i \times h_{t-1} + v_i \times x_t) \quad (10)$$

$$o_t = \tanh(w_o \times h_{t-1} + v_o \times x_t) \quad (11)$$

$$a_t = \sigma(w_a \times h_{t-1} + v_a \times x_t) \quad (12)$$

式中:  $x_t$  表示  $t$  时刻的输入;  $h_{t-1}$  表示  $t-1$  时刻的隐藏层状态值;  $f_t, i_t, o_t$  分别表示  $t$  时刻遗忘门、输入门、输出门的值;  $w_f, w_i, w_o$  分别表示遗忘门、输入门、输出门在特征提取过程中  $h_{t-1}$  的权重系数;  $v_f, v_i, v_o$  分别表示遗忘门、输入门、输出门在特征提取过程中  $x_t$  的权重系数;  $a_t$  表示  $t$  时刻对  $h_{t-1}$  和  $x_t$  的初步特征提取;  $\tanh$  表示正切双曲线函数;  $\sigma$  表示激活函数 Sigmoid。

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (13)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

### 3.3 灰狼优化算法

灰狼优化算法(Grey Wolf Optimizer, GWO)是一种智能优化算法<sup>[20]</sup>,具有收敛性能好、参数少、易实现等优点。GWO 优化大致包含灰狼的社会等级分层、跟踪、包围和攻击猎物等捕猎过程<sup>[21]</sup>,其优化过程如下。

#### ① 社会等级分层

GWO 优化须建立灰狼社会等级层次模型,主

要有 4 层社会等级。通过计算种群个体适应度,将狼群中适应度最好的 3 匹灰狼依次标记为  $\alpha, \beta, \delta$ ,剩下的灰狼标记为  $\omega$ 。

#### ② 包围猎物

灰狼在狩猎过程中的围猎行为可表示为

$$\mathbf{D} = \mathbf{C} \times \mathbf{X}_p(t) - \mathbf{X}(t) \quad (15)$$

$$\mathbf{X}(t+1) = \mathbf{X}_p(t) - \mathbf{A} \times \mathbf{D} \quad (16)$$

式中:  $t$  为当前迭代次数;  $\mathbf{X}_p(t), \mathbf{X}(t)$  分别表示当前猎物和灰狼的位置向量;  $\mathbf{D}$  表示个体与猎物之间的距离;  $\mathbf{A}, \mathbf{C}$  为系数向量。

由式(17),(18)计算可得:

$$\mathbf{A} = 2 \times \mathbf{A} \times \mathbf{r}_1 - \mathbf{a}(t) \quad (17)$$

$$\mathbf{C} = 2\mathbf{r}_2 \quad (18)$$

式中:  $\mathbf{a}$  为收敛因子,随迭代次数增加线性递减;  $\mathbf{r}_1, \mathbf{r}_2$  是  $[0, 1]$  中的随机向量。

#### ③ 狩猎

灰狼能够识别猎物的位置并包围它们。当灰狼识别出猎物的位置后,在  $\alpha, \beta, \delta$  的带领下指导狼群包围猎物。灰狼个体跟踪猎物位置的数学模型如下:

$$\begin{cases} D_\alpha = \mathbf{C}_1 \times \mathbf{X}_\alpha - \mathbf{X} \\ D_\beta = \mathbf{C}_2 \times \mathbf{X}_\beta - \mathbf{X} \\ D_\delta = \mathbf{C}_3 \times \mathbf{X}_\delta - \mathbf{X} \end{cases} \quad (19)$$

$$\begin{cases} \mathbf{X}_1 = \mathbf{X}_\alpha - \mathbf{A} \times D_\alpha \\ \mathbf{X}_2 = \mathbf{X}_\beta - \mathbf{A} \times D_\beta \\ \mathbf{X}_3 = \mathbf{X}_\delta - \mathbf{A} \times D_\delta \end{cases} \quad (20)$$

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (21)$$

式中:  $\mathbf{X}_\alpha, \mathbf{X}_\beta, \mathbf{X}_\delta$  分别表示当前狼群中  $\alpha, \beta, \delta$  的位置向量;  $D_\alpha, D_\beta, D_\delta$  分别表示当前候选灰狼与最优灰狼  $\alpha, \beta, \delta$  之间的距离;当  $|\mathbf{A}| \geq 1$  时,灰狼之间尽量分散在各区域并搜寻猎物,当  $|\mathbf{A}| < 1$  时,灰狼将集中搜寻特定区域的猎物。

#### ④ 攻击猎物

当猎物停止移动时,灰狼通过攻击来完成狩猎过程。

### 3.4 考虑分布式光伏接入的负荷预测模型

#### ① 模型输入输出

通过负荷特性及相关性分析,选择光照辐射度、环境温度、相对湿度以及历史净负荷数据构造净负荷预测的输入特征集,预测输出为下一个时刻的净负荷。

②融合自注意力机制的 LSTM 神经网络预测模型

由于分布式光伏的接入,使得原有负荷预测变为净负荷预测,图 5 是融合自注意力机制的 LSTM 神经网络预测模型。在进行净负荷预测之前,须要构造用于模型训练的输入输出数据,基于相关性分析,在影响光伏出力和负荷变化规律的关键因素中筛选出最优的特征集作为输入输出数据。输入数据经过输入层传递到 LSTM 神经网络层,经过 3 层 LSTM,可以充分学习特征序列的长期依赖性,形成持久的信息记忆,时序的变化规律特性也能够得到更好的学习。在 Self Attention 层,对序列中强相关特征赋予更高的权重,使得预测更加准确。最后,通过全连接层将其堆叠起来,直接生成净负荷预测值。




图 5 融合自注意力机制的 LSTM 神经网络模型  
Fig.5 LSTM neural network model integrated with self-attention mechanism

③GWO 优化 Self Attention-LSTM 神经网络预测模型的步骤

图 6 为 GWO 优化 Self Attention-LSTM 预测模型

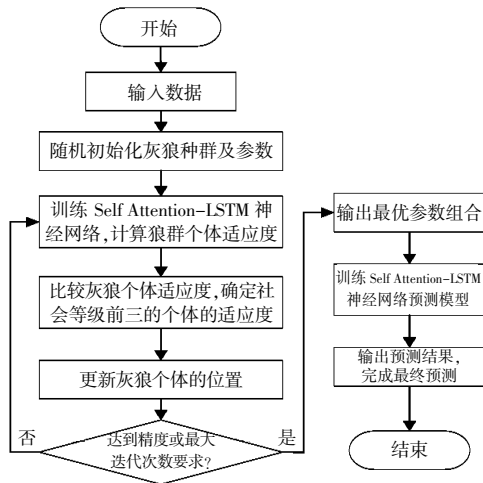


图 6 GWO 优化的 Self Attention-LSTM 预测模型流程  
Fig.6 Flow chart of GWO optimized Self Attention-LSTM prediction model

模型流程图。通过构建 Self Attention-LSTM 神经网络模型来实现对考虑分布式光伏接入场景的净负荷预测,基于输入数据仅仅是对预测模型进行初步的训练,要想使模型具有更出色的性能和预测效果,还须对其进行优化,寻找最优的参数组合。因此,本文采用 GWO 算法对 Self Attention-LSTM 预测模型进行寻优,使得模型在最优状态下,输出误差较小的净负荷预测结果。

4 算例分析

本文算例使用在中国北方某城市含分布式光伏的用户侧采集的数据,数据集包括该地区 2020 年 6-8 月份的用户侧负荷数据、分布式光伏的出力数据以及相应的气象数据。首先对采集的样本数据进行预处理,然后通过相关性分析来构建模型输入特征集。70%的样本数据作为训练集,30%的样本数据作为测试集。

4.1 数据预处理

本文通过最大-最小数据归一化方法,将模型输入数据转换为[0, 1]的数据,消除量纲之间的影响,其转换关系如式(22)所示。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (22)$$

式中: $x^*$  为数据归一化后的值; $x$  为原样本数据; $x_{\max}$  为原样本数据中的最大值; $x_{\min}$  为原样本数据中的最小值。

4.2 数据预处理

为了检验本文所提方法对考虑分布式光伏接入场景的负荷预测效果,采用均方根误差(Root Mean Squared Error, RMSE) 和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)两种评价方法,具体见式(23), (24)。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (23)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (24)$$

式中: $n$  为样本容量; $\hat{y}_i$  为预测值; $y_i$  为实际值。

4.3 模型超参数设置

本文在搭建深度神经网络预测模型过程中,会产生训练迭代次数、数据批量处理大小、网络层数、每层神经元的数目等一系列超参数,而且 GWO 算法在优化预测模型过程中,也须要设置迭

代次数、种群大小以及调控参数等。本文所提预测模型的具体参数设置如表 3 所示,表 3 给出了模型在训练及寻优过程中产生的超参数以及最优数值。在寻优过程中,选择预测模型训练迭代次数、批量处理大小、LSTM 层数、每层 LSTM 神经元数目以及全连接层神经元数目作为 GWO 的寻参变量,因此 GWO 优化的变量维度为 5。

表 3 预测模型及优化算法参数设置  
Table 3 Parameter Settings of prediction model and optimization algorithm

算法类型	超参数	数值大小
Self Attention-LSTM 神经网络 预测算法	预测模型训练迭代次数	100
	批量处理大小	32
	LSTM 层数	3
	每层 LSTM 神经元数目	64, 128, 64
	全连接层神经元数目	50
GWO 优化算法	神经网络模型优化算法	Adam 算法
	激活函数	Relu 函数
	最大迭代次数	150
	种群数目	30
	变量维度	5
	收敛因子 $\alpha$	2

#### 4.4 预测结果及分析

图 7 为采用 GWO 优化的 Self Attention-LSTM 神经网络预测模型的净负荷预测效果图。从图 7 中可以看出,本文所提方法有着出色的净负荷预测效果,且净负荷预测值更接近于实际净负荷值。

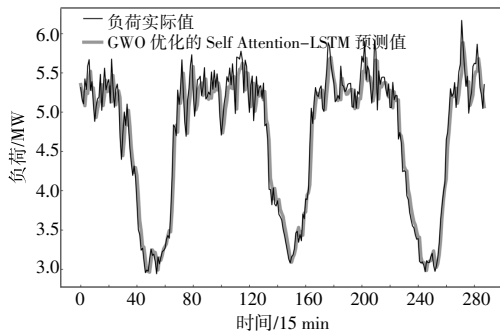


图 7 GWO 优化的 Self Attention-LSTM 神经网络预测模型的净负荷预测效果

Fig.7 Net load prediction effect diagram of GWO optimized Self Attention-LSTM neural network prediction model

为了验证本文提出的净负荷预测方法的有效性和优越性,分别采用长短期记忆神经网络(LSTM),XGBoost 以及 BP 神经网络 3 种预测模型与 GWO 优化的 Self Attention-LSTM 神经网络预测模型进行对比分析。表 4 给出了 4 种模型的

测试结果,分别从 RMSE 和 MAPE 两个方面进行评价。其中,本文所提考虑分布式光伏的净负荷预测模型的 RMSE 和 MAPE 低于其他 3 种预测方法。

表 4 4 种方法净负荷预测精度对比  
Table 4 Net power prediction accuracy comparison of the four models

模型	RMSE/MW	MAPE/%
GWO-Self Attention-LSTM	0.432	2.204
LSTM	0.618	2.663
XGBoost	0.625	2.565
BP	0.712	3.130

#### 5 结束语

考虑分布式光伏接入对用户侧负荷的影响,本文提出了一种基于灰狼算法优化的自注意力 LSTM 神经网络模型,实现对含分布式光伏的负荷预测。首先,对用户侧负荷、分布式光伏出力特性及其影响因素进行分析,采用 Pearson 相关系数定量分析天气因素对负荷及光伏出力的影响,筛选出了影响较强的因素作为输入特征集。其次,将自注意力机制和 LSTM 神经网络融合到一起,给予输入特征不同的关注度,使得 LSTM 神经网络具有更好的学习能力。最后,采用灰狼算法对 Self Attention-LSTM 神经网络预测模型进行参数寻优,得到预测效果更佳的模型。通过算例分析验证了本文所提预测方法的有效性和可行性,并与其他预测模型进行对比,本文所提方法具有较高的预测精度。

#### 参考文献:

- [1] 王国法,刘合,王丹丹,等.新形势下我国能源高质量发展与能源安全 [J]. 中国科学院院刊,2023,38(1): 23-37.
- [2] 徐楠,赵子豪,张丹阳,等.双碳目标下考虑风光不确定性的综合能源系统规划研究 [J]. 可再生能源, 2023,41(2):236-242.
- [3] 车彬,刘艳章,于若英,等.计及分布式光伏出力随机性的配网风险评估方法 [J]. 可再生能源,2019,37(11):1685-1690.
- [4] Shi J, Ma L, Li C, et al. A comprehensive review of standards for distributed energy resource grid-integration and microgrid [J].Renewable and Sustainable Energy Reviews, 2022,170:112957.
- [5] 何德卫.浅析分布式光伏对配电网的影响[J].农村电气化,2021,413(10):73-74.
- [6] 雷绍兰,孙才新,周隼,等.电力短期负荷的多变量时

- 间序列线性回归预测方法研究 [J]. 中国电机工程学报, 2006, 26(2): 25-29.
- [7] 姜玉山, 刘嘉婧, 卢毅. 基于回归分析的频域分解短期负荷预测方法[J]. 电力需求侧管理, 2011, 13(5): 12-16.
- [8] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测 [J]. 电网技术, 2020, 44(2): 614-620.
- [9] 马文晓, 白晓民, 沐连顺. 基于人工神经网络和模糊推理的短期负荷预测方法 [J]. 电网技术, 2003, 27(5): 29-32.
- [10] 牛东晓, 谷志红, 邢棉, 等. 基于数据挖掘的 SVM 短期负荷预测方法研究[J]. 中国电机工程学报, 2006(18): 6-12.
- [11] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法 [J]. 电力系统自动化, 2019, 43(8): 131-137.
- [12] 洪宇, 高骞, 杨俊义, 等. 基于 DE-ELM 算法的配电网电力系统负荷预测研究[J]. 吉林大学学报(信息科学版), 2022, 40(6): 918-923.
- [13] 刘友波, 吴浩, 刘挺坚, 等. 集成经验模态分解与深度学习的用户侧净负荷预测算法[J]. 电力系统自动化, 2021, 45(24): 57-64.
- [14] Shi J, Liu N, Huang Y, et al. An edge computing-oriented net power forecasting for PV-assisted charging station: Model complexity and forecasting accuracy trade-off[J]. Applied Energy, 2022, 310: 118456.
- [15] 廖启术, 胡维昊, 曹迪, 等. 新能源电力系统中的分布式光伏净负荷预测 [J]. 上海交通大学学报, 2021, 55(12): 1520-1531.
- [16] 任洪波, 陈杰, 李琦芬, 等. 面向园区能源互联网的多元负荷特性及其调控潜力研究现状与展望[J]. 可再生能源, 2021, 39(2): 245-251.
- [17] 朱张莉, 饶元, 吴渊, 等. 注意力机制在深度学习中的研究进展[J]. 中文信息学报, 2019, 33(6): 1-11.
- [18] Yu Y, Si X, Hu C, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31(7): 1235-1270.
- [19] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术, 2018, 47(1): 39-41.
- [20] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [21] 刘雨薇, 刘辉, 陈馨凝, 等. 基于 DE-GWO-LSSVM 模型的用电负荷预测 [J]. 湖北工业大学学报, 2019, 34(4): 30-34.

## Short-term load forecasting technology with distributed energy timing uncertainty

Yang Xiaolong<sup>1</sup>, Yao Tao<sup>1</sup>, Sun Chenjun<sup>1</sup>, Wei Xinjie<sup>2</sup>, Zhang Huaming<sup>3</sup>, Sun Yi<sup>4</sup>

(1.Information Communication Branch of State Grid Hebei Electric Power Co.,LTD., Shijiazhuang 050000, China; 2.State Grid Hebei Electric Power Co.,LTD., Shijiazhuang 050021, China; 3.Beijing Qingsoft Innovation Technology Co.,LTD., Beijing 100080, China; 4.College of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

**Abstract:** In recent years, with the rapid growth of the scale of distributed photovoltaic deployment in cities and towns, the impact of random fluctuation characteristics of its output on urban load is also increasing. The traditional method is difficult to accurately predict the complex load fluctuation after large-scale deployment of distributed photovoltaic system, which is not conducive to the safe and stable operation of power grid. To solve these problems, this paper proposes a short-term load forecasting method considering distributed PV. Since the net load including distributed PV is the difference between the actual consumption load of the user side and the PV output, this paper first adopts the big data mining technology to analyze the characteristics of PV output and the user-side load as well as the correlation between the two and their respective influencing factors before constructing input data, and selects the influential factors with high correlation as the input feature set of the net load prediction model. Secondly, the LSTM neural network prediction model integrating self-attention mechanism is constructed to deeply explore the characteristics of load sequence. The grey Wolf algorithm is used to optimize the parameters of the prediction model and determine the model with the best prediction effect. Finally, an example simulation shows that the proposed method can effectively improve the prediction accuracy of net load with distributed PV.

**Keywords:** distributed photovoltaic; correlation analysis; self-Attention mechanism; LSTM; grey wolf optimization algorithm; load forecasting