

基于多目标和贝叶斯优化的短期负荷区间预测^{*}

杜茂康¹ 张雪¹ 肖玲^{1,2} 江河³

(1. 重庆邮电大学经济管理学院 重庆 400065; 2. 徐州工程学院数学与统计学院 徐州 221018;

3. 江西财经大学统计学院 南昌 330013)

摘要: 新能源并网后的供电体系存在具有较高的间歇性和随机性, 这将为电力生产和调度的平衡带来巨大挑战, 而如何量化电力负荷的不确定性对电力系统安全经济地运行起着重要作用。为此, 提出一种基于多目标和贝叶斯优化(multi-objective optimization and Bayesian optimization, MOBO)的深度学习区间预测模型, 能在给定的置信水平下描述电力负荷的变化趋势。在预测模型的构建过程中, 依据分位数回归理论计算出电力负荷在不同分位点处的预测区间, 再通过有效性检验, 筛选出合理的预测模型。同时, 采用多目标优化和贝叶斯优化算法理论对深度学习模型的超参数进行调优。使用美国纽约州米尔伍德的电力负荷数据集对所提出的模型进行验证, 实验结果表明, 与其他模型相比, 模型在不同置信水平下均有着更高的预测区间覆盖率和更窄的区间平均宽度, 更能精确地描述未来电力负荷的波动范围。

关键词: 深度学习; 分位数回归; 多目标优化; 贝叶斯优化算法; 短期电力负荷; 区间预测

中图分类号: TM714 **文献标识码:** A **国家标准学科分类代码:** 470.4061

Short-term load interval forecasting based on multi-objective and bayesian optimization

Du Maokang¹ Zhang Xue¹ Xiao Ling^{1,2} Jiang He³

(1. School of Economics and Management, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 2. School of Mathematics and Statistics, Xuzhou University of Technology, Xuzhou 221018, China;

3. School of Statistics, Jiangxi University of Finance and Economics, Nanchang 330013, China)

Abstract: The grid connected power supply system of new energy has high intermittency and uncertainty, which will bring great challenges to the balance of power production and dispatching. How to quantify the uncertainty of power load plays an important role in the safe and economical operation of power system. Therefore, this paper proposes a deep learning interval prediction model based on multi-objective optimization and Bayesian optimization (MOBO), which can describe the variation trend of power load at a given confidence level. In the process of building the prediction model, we calculated the prediction interval of power load at different points according to the quantile regression theory, and then screened the reasonable prediction model through the validity test. At the same time, multi-objective optimization and Bayesian optimization algorithm theory are used to tune the hyperparameters of the deep learning model. In this paper, the power load dataset of Millwood, New York, USA is used to verify the proposed model. The experimental results show that the proposed model has greater prediction interval coverage probability and smaller prediction interval normalized average width at different confidence levels than other models, besides more accurately describes the fluctuation range of future electricity load.

Keywords: deep learning; quantile regression; multi-objective optimization; Bayesian optimization algorithm; short-term power load; interval prediction

收稿日期: 2022-10-18

^{*} 基金项目: 国家自然科学基金(71901045)、重庆市教委科学技术研究项目(KJQN202100604)、成渝双城经济圈科技创新项目(KJCX2020027)、江西省自然科学基金(20212ACB211003)项目资助

0 引言

在我国,电力行业的碳排放量占全国碳排放量的1/3以上,为推进双碳目标的达成,《中华人民共和国国民经济和社会发展第十四个五年规划和2035年远景目标纲要》明确规定:构建清洁低碳安全高效的能源体系,坚持集中式和分布式发电并举,持续推进多能互补的清洁能源基地建设^[1]。在此国家重大战略背景下,利用和开发可再生能源进行发电成为脱碳计划的重要途径,例如风力、光伏和水力等,新能源发电系统随之大规模接入电网,但由于该发电方式易受气候变换和地理位置影响,导致获得的电能具有较大的差异性和间歇性,这将给电力公司的生产和调度带来重大不确定性,从而影响到电网中电力平衡的维持。因此,准确的电力负荷预测对于捕捉不确定性发挥了至关重要的作用,为电网调度人员定制发电计划和发电厂报价提供重要的依据。

目前,电力负荷预测的研究主要围绕点预测开展,主要预测方法如下:1)经典的统计学方法^[2],如回归分析法、时间序列法和灰色预测法等;2)人工智能技术^[3-5],包括支持向量机、人工神经网络法和专家系统法。然而,点预测无法对预测结果可能的波动范围进行预测评估^[6],难以满足新能源并网后对负荷预测更能捕捉随机性的要求;区间预测却能够从本质上解决这个问题^[7],即旨在不同的置信水平下,将数据中的不确定性约束在可控的范围内。目前,国内外的区间预测方法主要包括高斯过程回归^[8]、分位数回归^[9]与灰色区间预测^[10]等。其中,基于分位数回归的概率预测方法具有灵活、高效的特点,可以与简单的线性模型或机器学习相结合^[11]。

当分位数回归与人工智能方法结合时,超参数的设置或训练对机器学习模型的预测性能,如模型的准确性、稳定性和泛化能力等产生重大影响^[12-13]。如何训练深度学习模型的超参数对抑制欠拟合以及过度拟合的出现有着关键作用,是机器学习的主要任务之一。现有的超参数调优策略如下:1)人工搜索,该方法缺乏理论的支持且非常耗时;2)网格搜索,由于受到维数的限制,导致算法效率随着被优化的超参数数量和数值范围的增大而急速下降;3)随机搜索,算法原理与网格搜索类似,其效率更高,但精度降低;4)贝叶斯优化(Bayesian optimization,BO)算法克服上述算法的不足,通过充分利用已有的评估信息来预测下一个最佳的超参数组合,这极大地减少了训练超参数组合所需的时间,使之成为最受欢迎的超参数调优策略之一^[14]。

此外,大部分区间预测的研究倾向于选择单目标函数作为超参数训练的损失函数,如经验选择方法^[15]、均方根误差^[16]以及Pinball损失函数^[17]等,这无法兼顾预测区间覆盖更多真实值、区间平均宽度更小和区间精确度更高等多个目标。一个目标的改进往往以牺牲其他目标为代价^[18],如提高区间覆盖率的同时会使区间平均宽度变大,

而缩小区间平均宽度也会导致区间的覆盖率降低。目前,少有研究将预测区间的构建视为具有多个目标的多目标问题。因此,引入多目标优化理论对建立可靠的预测区间有着重要意义。

针对上述问题,本文提出一种基于MOBO的深度学习区间预测模型。该模型利用贝叶斯优化算法在超参数训练过程中收敛速度快、扩展性强的优点,来寻找一组使多目标损失函数达到理想效果的帕累托最优解,最终使构建的预测区间能有效地捕捉负荷数据中的不确定性,从而更准确地描述未来负荷的波动范围。该方法克服了传统的点预测无法提供负荷数据中的随机性信息,同时还解决了将区间预测的构建视为单目标问题,导致产生极高的预测区间覆盖率伴随着较大的区间平均宽度等现象。

1 电力负荷预测相关理论

1.1 分位数回归(QR)

QR由Roger Koenker和Gilbert Bassett提出^[19],将真实值与预测值之间的距离最小化,更加准确地反映解释变量对于被解释变量在不同分位点下的影响,表达式为:

$$Q_y(\tau | X) = X'\beta(\tau) \quad (1)$$

式中: τ 是分位点, $\tau \in (0, 1)$; $Q_y(\tau | X)$ 是被解释变量 y 在解释变量 $X' = [x_1, x_2, \dots, x_t]$ 给定下的条件 τ 分位数; $\beta(\tau) = [\beta_0(\tau), \beta_1(\tau), \dots, \beta_t(\tau)]'$ 是回归系数向量,随着分位点 τ 的变化而变化; $t = 1, 2, 3, \dots, N, N$ 为训练样本数量。

通过式(1)可得出不同分位点 τ 处的预测值,最小化真实值和预测值的目标函数可采用pinball损失函数,表达式如下:

$$\min_{\beta} \left\{ \sum_{y \geq X'\beta} \tau |y - X'\beta| + \sum_{y < X'\beta} (1 - \tau) |y - X'\beta| \right\} \quad (2)$$

1.2 基于深度学习的分位数回归

得益于其复杂的隐含层和循环结构,深度学习具备较强的学习能力、容错能力和泛化能力等优势^[20],因此广泛应用于电力负荷的预测领域。相比于传统的负荷预测方法,深度学习对时间序列预测精度更高,对外界影响因素的鲁棒性更好。Taylor将分位数回归与人工神经网络相结合,提出了用于非线性预测的基于分位数回归的神经网络模型^[21](quantile regression neural network, QRNN),其表达式如下:

$$Q_{y_i}(\tau | X_i) = f_2 \left(\sum_{j=1}^m w_{j,\tau} f_1 \left(\sum_{i=1}^n w_{i,\tau} x_{ii} + b_{i,\tau} \right) + b_{j,\tau} \right) \quad (3)$$

式中:输入层含有 n 个单元,隐含层含有 m 个单元; X_i 是具有 x_{ii} 元素的网络输入; $Q_{y_i}(\tau | X_i)$ 是 X_i 的条件 τ 分位数; $w_{i,\tau}, w_{j,\tau}$ 为权重矩阵; $b_{i,\tau}, b_{j,\tau}$ 为偏置; f_1, f_2 是神经网络的激活函数,通常分别取Sigmoid函数和线性

函数。

QRNN 模型训练过程中实际是通过梯度下降等算法最小化损失函数^[22],从而确定使模型回归效果最佳的网络参数,损失函数通常采用平均绝对误差(mean absolute error, MAE),表达式如下:

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - Q_{y_t}| \quad (4)$$

式中: y_t, Q_{y_t} 分别为样本 t 的电力负荷真实值和预测值;根据分位数回归理论,将式(4)损失函数 MAE 换成损失函数 E_τ ,从而建立基于深度学习的分位数回归模型,来估计网络的最优权重和偏置。损失函数 E_τ 表达如下:

$$E_\tau = \frac{1}{N} \left(\sum_{t=1}^N \rho_\tau(y_t - Q_{y_t}) \right) \quad (5)$$

$$\rho_\tau(u) = \begin{cases} \tau u, & u \geq 0 \\ (\tau - 1)u, & u < 0 \end{cases} \quad (6)$$

式中:通过调节 τ 的取值,输出解释变量 X_t 在不同分位点 τ 处的分位数 $Q_{y_t}(\tau | X_t)$ 。

2 短期电力负荷区间预测及评价

2.1 预测模型评价指标

在利用预测模型得到未来电力负荷的预测结果后,需要对区间预测进行评估。本文采用点预测评价指标和区间预测评价指标来衡量模型的整体预测效果,具体包括平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)、预测区间覆盖率(prediction interval coverage probability, PICP)、预测区间平均宽度(prediction interval normalized average width, PINAW)以及温克勒评分(Winkler score, WS)。

1) 点预测评价指标

MAPE 用来评价真实值和预测值之间的偏差^[23],当 MAPE 为 0% 时,表示完美模型,当 MAPE 时大于 100% 则表示劣质模型。其定义如下:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{Q_{y_t} - y_t}{y_t} \right| \times 100\% \quad (7)$$

式中: N 表示测试的样本数量。

RMSE 的值越小,表示误差越小。其定义如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - Q_{y_t})^2} \quad (8)$$

2) 区间预测评价指标

可靠的预测区间有着更高的覆盖率和更窄的宽度。为了定性地评估预测区间的这两方面,采用文献[24]的评价指标 PICP 和 PINAW。PICP 也称为预测区间置信水平,表示未来负荷将被预测区间的上下限覆盖的概率,越大的区间覆盖率意味着预测区间包含更多的真实值,预测区间的质量越高。

$$PICP = \frac{1}{N} \sum_{t=1}^N \delta_t \quad (9)$$

$$\delta_t = \begin{cases} 1, & y_t \in [L_t^a, U_t^a] \\ 0, & y_t \notin [L_t^a, U_t^a] \end{cases}$$

式中: U_t^a 和 L_t^a 为预测区间的上下限。虽然 PICP 是预测区间准确性的关键指标,但极宽的预测区间覆盖率不能为决策提供有效的信息,因此引入 PINAW 来评价预测区间的质量。

$$PINAW = \frac{1}{N \times R} \sum_{t=1}^N (U_t^a - L_t^a) \quad (10)$$

式中: R 表示预测区间平均宽度,通常 PICP 尽可能大的前提下,具有越小的 PINAW,预测区间的预测精度越高。

WS 是评价预测区间质量的一个综合指标,WS 评分越小,意味着不确定预测的效果越好^[25],其定义如下:

$$S_t^a = \begin{cases} v_t^a + \frac{2(L_t^a - y_t)}{\alpha}, & y_t < L_t^a \\ v_t^a, & L_t^a \leq y_t \leq U_t^a \\ v_t^a + \frac{2(y_t - U_t^a)}{\alpha}, & U_t^a < y_t \end{cases} \quad (11)$$

$$WS = \frac{1}{N} \sum_{t=1}^N S_t^a$$

式中: α 与置信水平有关($\alpha = 0.1$ 表示 90% 置信水平); $v_t^a = U_t^a - L_t^a$ 为在置信水平 $100(1 - \alpha)\%$ 下预测区间的宽度。

2.2 基于多目标和贝叶斯优化的深度学习区间预测模型

本文基于 QRNN 模型将 4 种常见的深度学习模型及其混合模型,包括卷积神经网络(convolutional neural networks, CNN)、径向基函数(radial basis function, RBF)、长短期记忆网络(long-short term memory, LSTM)、循环门控单元网络(gate recurrent unit, GRU)、卷积长短期记忆网络(CNN-LSTM)以及卷积循环门控单元(CNN-GRU)等,与分位数回归结合,建立基于深度学习的分位数回归模型。

为了更精准掌握未来电力负荷的波动规律,通过对消融实验得到性能较好的预测模型,采用贝叶斯优化算法对其超参数进行调整。同时,考虑到评价指标 MAPE、RMSE、PINAW、WS 与 PICP 是相互矛盾的,提高区间覆盖率的同时会使预测区间上下限与真实值的距离变大、区间平均宽度变大以及区间精锐度变低,而缩小区间平均宽度则会导致与上述描述相反的情况。因此,综合相互冲突的多个评价指标,将其作为超参数寻优的损失函数,来建立基于多目标和贝叶斯优化的深度学习区间预测模型。

首先,将点预测评价指标和区间预测评价指标作为超参数寻优的多目标函数,表达如下:

$$m^* = \operatorname{argmin} F(m) \quad (12)$$

其中,函数 $F(m)$ 可以等价地表示为:

$$F(m) = f_{MAPE}(m) + f_{RMSE}(m) - f_{PICP}(m) + f_{PINAW}(m) + f_{WS}(m) \quad (13)$$

式中: $m^* = [m_1, m_2, m_3, m_4]$ 是最小化多目标函数得到的 Pareto 最优解,即带来最大收益的超参数组合,依次代

表最大训练轮次、初始学习率、学习率衰减周期以及学习率衰减率。

其次,神经网络的偏置 b_τ 和权重 w_τ 的初始化是在神经网络中分位点 τ 处完成,并且通过最小化损失函数 ϕ'_τ 来更新,表达如下:

$$(w_\tau^*, b_\tau^*) = \operatorname{argmin} \sum_{\tau} \sum_{t=1}^N \phi'_\tau(X_t, w_\tau, b_\tau) \quad (14)$$

$$\text{s. t. } \begin{cases} \Psi'_\tau(X_t, w_\tau, b_\tau) \geq \tau(y_t - f(X_t, w_\tau, b_\tau)) \\ \Psi'_\tau(X_t, w_\tau, b_\tau) < (1-\tau)(y_t - f(X_t, w_\tau, b_\tau)) \end{cases} \quad (15)$$

最后,将优化后的超参数组合 m^* 、权重矩阵 w_τ^* 和偏置 b_τ^* ,作为预测模型的参数输入,并设其隐含层的神经元数量为 M ,则 t 时刻,输入 X_t 得到隐含层的输出向量 H_1, H_2, \dots, H_M ,再将输出向量作为全连接层的输入,得到分位点 τ 处的输出值:

$$Q_{y_t}(\tau | X_t) = f\left(\sum_{m=1}^M w_\tau^* H_m + b_\tau^*\right) \quad (16)$$

由式(16)可得不同分位点 τ 处的分位数 $Q_{y_t}(\tau | X_t)$,且 $Q_{y_t}(\tau | X_t)$ 服从 $(u(X_t), \sigma^2(X_t))$ 的高斯分布^[26], $u(X_t)$ 是测试样本 t 的平均分位数, $\sigma^2(X_t)$ 则为分位数方差。在给定置信水平 $100(1-\alpha)\%$ 下,预测区间 I_t^α 的定义如下:

$$I_t^\alpha = [L_t^\alpha, U_t^\alpha] \quad (17)$$

$$L_t^\alpha = u(X_t) - z_{1-\alpha/2} \sqrt{\sigma^2(X_t)} \quad (18)$$

$$U_t^\alpha = u(X_t) + z_{1-\alpha/2} \sqrt{\sigma^2(X_t)} \quad (19)$$

式中: L_t^α 和 U_t^α 分别为预测区间的下限和上限; $z_{1-\alpha/2}$ 是标准高斯分布的临界值,取决于置信水平 $100(1-\alpha)\%$ 。

3 案例分析

3.1 实验设置及流程

以美国纽约州米尔伍德 (Millwood) 2018 年 4 月 1 日~4 月 30 日的电力负荷数据为研究对象,该数据为纽约独立系统运营商提供的公开数据集。电力负荷数据的间隔为 5 min,采用滑动窗口对数据集预处理,其中训练数据集和测试数据集分别占原始数据集的 80% 和 20%,其中用于超参数训练和区间预测的数据集划分情况如图 1 所示。




图 1 实验数据集划分

为了增加模型的可比性和可靠性,将本文所用的各预测模型参数设置保持统一。

1) 滑动窗口的大小设置为 12,即用过去 1 h 的负荷数据预测未来 5 min 的电力负荷。

2) LSTM、GRU、CNN-LSTM 以及 CNN-GRU 网络均采用动量梯度下降法 (stochastic gradient descent momentum, SGDM) 为优化算法。

3) 各神经网络的超参数设置如下: 隐含层数量均为 30,输入特征大小为 12,最大训练轮次为 100,梯度阈为 1,初始学习率为 0.06,每次训练学习率以 0.2 倍的速度更新。

4) 分位点 τ 设置为 $[0.1, 0.9]$,间隔为 0.1,共 9 个分位点。

本文研究基于多目标和贝叶斯优化的深度学习区间预测模型在短期电力负荷中的应用,实现流程如图 2 所示。步骤如下: 1) 模型构建阶段。为了选取合理的预测模型,采用网络结构相近的 CNN、RBF、LSTM、GRU、CNN-LSTM 以及 CNN-GRU 进行对比研究,建立基于深度学习的分位数回归模型,并将预处理后的数据集输入预测模型,得到未来负荷在不同分位点处的预测区间; 2) 模型筛选阶段。先计算 PICP 指标,初步排除预测性能不达标的模型,再进一步分析所选模型的 PINAW 和 WS 指标,选取含有可靠预测区间的模型; 3) 基于 MOBO 的超参数优化阶段。兼顾 MAPE、RMSE、PICP、PIANW 以及 WS 等指标,建立多目标函数作为贝叶斯优化算法进行超参数寻优的损失函数,然后输出最佳的超参数组合; 4) 预测阶段。将优化的超参数输入所选模型,并预测未来电力负荷的波动范围; 5) 评估阶段。通过 MAPE、RMSE、PICP 以及 PINAW 指标来评估本文所提模型与其他模型的优劣。

3.2 对比试验

在 95%、90%、85% 和 80% 四个置信水平下,采用 PICP 指标对预测模型 CNNQR、RBFQR、LSTMQR、GRUQR、CNN-LSTMQR 和 CNN-GRUQR 进行初步筛选和评价,排除预测区间覆盖率低于给定的置信水平的无效预测区间,计算结果如表 1 所示。

由表 1 可以看出,在 4 个置信水平下, LSTMQR、GRUQR、CNN-LSTMQR 以及 CNN-GRUQR 四个模型中的 PICP 值大于给定的置信水平,因此,上述模型能有效量化电力负荷带来的不确定性信息。在 95% 置信水平下,上述 4 个模型的预测区间覆盖率分别为 96.96%、96.17%、97.76% 和 98.55%,都达到了预期的置信水平; 类似的,在 90% 置信水平下, LSTMQR、GRUQR、CNN-LSTMQR 以及 CNN-GRUQR 模型的预测区间覆盖率都大于 90%。相比之下, RBFQR 和 CNNQR 模型的 PICP 值在 4 个置信水平下均低于给定的置信水平,在 95% 置信水平下,上述两个模型的区间覆盖率仅为 87.56%、62.55%,应视为无效的预测区间。因此,在进一步实验

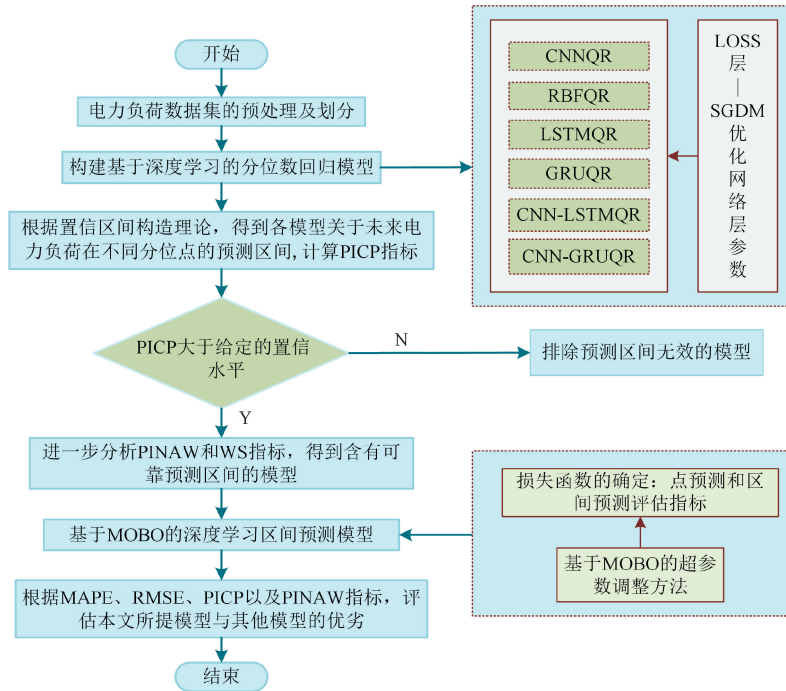


图2 短期电力负荷的区间预测流程

表1 不同置信水平下预测模型的 PICP 值

预测模型	PICP/%			
	95% 置信水平	90% 置信水平	85% 置信水平	80% 置信水平
CNNQR	62.55	55.31	49.67	45.34
RBFQR	87.56	81.85	77.44	73.10
LSTMQR	96.96	93.64	90.74	87.13
GRUQR	96.17	92.70	89.15	84.53
CNN-LSTMQR	97.76	95.73	94.07	91.11
CNN-GRUQR	98.55	96.89	94.58	91.68

中,本文排除 RBFQR 和 CNNQR 模型。

经过初步筛选,本文再通过 PINAW 和 WS 指标进一步评估所选模型,这两个指标可以对预测区间的可靠性和精确程度进行评价。表2为不同置信水平下,LSTMQR、GRUQR、CNN-LSTMQR 以及 CNN-GRUQR 模型的 PINAW 和 WS 值。图3和4所示为上述4个模型的 PINAW 和 WS 指标进行了可视结果。

由表2、图3和4可以看出,相比于两个混合模型 CNN-LSTMQR 和 CNN-GRUQR 的区间预测效果,另外两个单项模型 LSTMQR 和 GRUQR 更好,其 PINAW 和 WS 指标在4个置信水平下均更低。在95%置信水平下,CNN-GRUQR 和 CNN-LSTMQR 模型的 PINAW 指标值比 LSTMQR 模型分别高出 9.74%、14.52%,比 GRUQR 模型分别高出 9.98%、14.76%;而关于 WS 指标,CNN-GRUQR 和 CNN-LSTMQR 模型比 LSTMQR 模型分别高出 18.29、22.17,比 GRUQR 模型分别高出 18.23、

表2 不同置信水平下4种预测模型的 PINAW 和 WS 值

置信水平/%	预测模型	PINAW/%	WS
95	LSTMQR	18.68	36.54
	GRUQR	18.44	36.60
	CNN-LSTMQR	33.20	58.71
	CNN-GRUQR	28.42	54.83
90	LSTMQR	15.63	31.15
	GRUQR	15.43	31.35
	CNN-LSTMQR	27.78	50.10
	CNN-GRUQR	23.78	46.65
85	LSTMQR	13.73	27.92
	GRUQR	13.55	28.22
	CNN-LSTMQR	24.39	44.66
	CNN-GRUQR	20.88	41.58
80	LSTMQR	12.30	25.59
	GRUQR	12.14	25.99
	CNN-LSTMQR	21.85	40.68
	CNN-GRUQR	18.70	37.95




图3 不同置信水平下4种预测模型的 PINAW 值




图4 不同置信水平下4种预测模型的WS值

22.11. LSTMQR 和 GRUQR 模型的区间预测效果相近, 在 95% 置信水平下, 超过 96% 的电力负荷真实值落在预测区间内, 对应的 PINAW 和 WS 指标值均在 18% 和 36 左右。在筛选的模型中, 两个混合模型的预测区间覆盖率明显高于两个单项模型, 但混合模型的 PINAW 和 WS 指标值也更大, 即较高的 PICP 会以较大的 PINAW 和 WS 为代价, 有可能导致最终的预测结果落在一个较宽的区间内, 从而使得预测者很难精准地获取预测结果的信息。

因此, LSTMQR 和 GRUQR 模型的预测区间质量最佳; CNN-GRUQR 和 CNN-LSTMQR 模型预测效果次之; 而 RBFQR 和 CNNQR 模型中由于预测区间覆盖率不达标, 区间预测效果较差。在 CNN-GRUQR 和 CNN-LSTMQR 模型中, 两种模型结合使得模型网络层数量增多, 在电力负荷数据的拟合中, 深度学习模型的层数过多会导致模型的复杂度提升、参数过多, 从而过度拟合了训练数据




图5 GRUQR 模型在不同置信水平下的预测区间

由图 5 和 6 可以看出, 在电力负荷快速变动及低谷期间, 时间采样点 200~300、550~600 以及 800~1 000, 可以显著地观察到 MOBO-GRUQR 模型的预测区间比 GRUQR 模型更窄, 且预测区间随着电力负荷真实值的波动而往同方向变化, 有超出预定义的置信水平的电力负荷真实值被预测区间覆盖。因此, MOBO-GRUQR 模型比 GRUQR 模型更能准确地表征未来电力负荷的波动范围。同时, 由图 7 可以发现, MOBO-LSTMQR 模型中预测区

间的变化趋势和电力负荷的波动幅度保持一致; 另外, 当置信水平不断增加, MOBO-LSTMQR 模型中预测区间也逐渐变宽, 意味着覆盖的电力负荷真实值也随之增加。

3.3 基于 MOBO 的短期电力负荷区间预测

为了进一步提高区间预测的精度, 实验采用多目标优化和贝叶斯优化算法来搜寻模型的最佳超参数。由于 GRUQR 和 LSTMQR 模型在上述实验中表现出较好的预测性能, 因此, 接下来分别对 GRUQR 和 LSTMQR 模型中的超参数进行优化, 构建基于 MOBO 的深度学习区间预测模型, 即 MOBO-GRUQR 和 MOBO-LSTMQR 模型, 其超参数寻优结果如表 3 所示。

表3 MOBO-GRUQR 和 MOBO-LSTMQR 模型优化后的超参数

参数	范围	MOBO-GRUQR	MOBO-LSTMQR
最大训练轮次	[50, 500]	464	314
初始学习率	[0.001, 0.01]	0.011 42	0.099 55
学习率衰减周期	[100, 500]	444	191
学习率衰减率	[0.1, 1]	0.859 41	0.151 45

然后, 选取 80%、85%、90% 以及 95% 四个置信水平, 分别运行 GRUQR、LSTMQR、MOBO-GRUQR 和 MOBO-LSTMQR 四个预测模型, 并将其区间预测的结果可视化, 如图 5~7 以及表 4 所示。

间的变化趋势和电力负荷的波动幅度保持一致; 另外, 当置信水平不断增加, MOBO-LSTMQR 模型中预测区间也逐渐变宽, 意味着覆盖的电力负荷真实值也随之增加。

表 4 为不同置信水平下, 本文提出的模型以及对比模型的区间预测精度, 预测结果表明, MOBO-LSTMQR 模型在不同置信水平下的预测性能均优于其他预测模型。在 80% 置信水平下, MOBO-LSTMQR 模型的 PICP 指标值比 LSTMQR 模型提高了 0.87%, 同时, 其 PINAW 指




图6 MOBO-GRUQR模型在不同置信水平下的预测区间

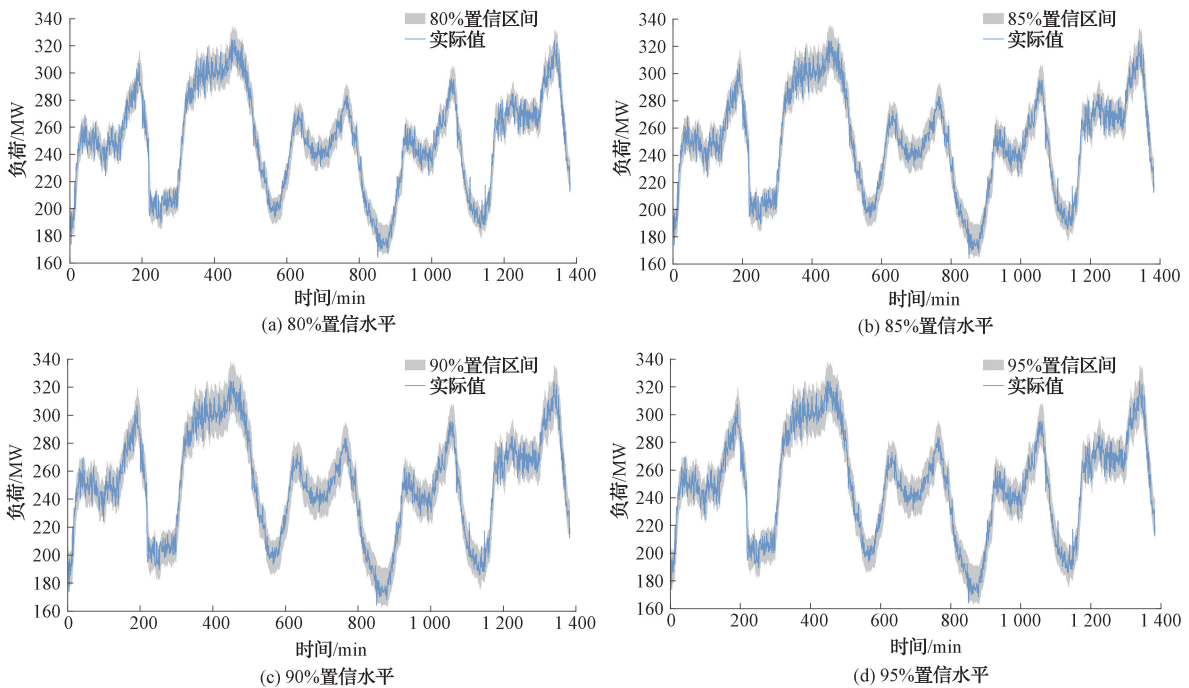


图7 MOBO-LSTMQR模型在不同置信水平下的预测区间

标值比 LSTMQR 模型降低了 0.5%；另外，虽然 MOBO-GRUQR 模型的 PICP 指标值比 GRUQR 模型增加了 1.66%，其 PINAW 指标值比 GRUQR 模型减少了 0.28%，但是相比于 MOBO-LSTMQR 模型略显逊色，MOBO-GRUQR 模型的 PICP 指标值下降了 1.81%，其 PINAW 指标值增加了 0.06%。类似地，在 85%、90% 和 95% 三个置信水平下，均有着与 80% 置信水平下相同的规律，与其他模型相比，MOBO-LSTMQR 模型的 PICP 指标值更大，其 PINAW 指标值更小。相比于其他 3 个置信水平，MOBO-LSTMQR 模型在 95% 置信水平下的预测效果更优，能覆盖更多的电力负荷真实值。随着置信水

平的提高，MOBO-LSTMQR 模型的预测性能的优越性越显著，在 95% 置信水平下，MOBO-LSTMQR 模型的预测区间覆盖了 97.18% 的电力负荷真实值，而预测区间平均宽度仅为 17.93%。基于 MOBO 的超参数调整方法可以提高模型的预测精度。4 个置信水平下的 PINAW 和 WS 指标值均表明 MOBO-GRUQR 模型优于 GRUQR 模型以及 MOBO-LSTMQR 模型均优于 LSTMQR 模型。

最后，本文从确定性预测方面，通过计算各个分位数的平均 MAPE 和 RMSE 指标值，进一步评估各模型的整体预测效果，如表 5 所示。根据表 5 可知，点预测评价指标的结果与区间预测评价指标的结果保持一致，其结果表

表4 不同模型在4个置信水平下的预测指标

置信水平/%	预测模型	PICP/%	PINAW/%
95	GRUQR	96.17	18.44
	MOBO-GRUQR	97.18	18.02
	LSTMQR	96.96	18.68
	MOBO-LSTMQR	97.18	17.93
90	GRUQR	92.70	15.43
	MOBO-GRUQR	93.71	15.08
	LSTMQR	93.64	15.63
	MOBO-LSTMQR	94.00	15.00
85	GRUQR	89.15	13.54
	MOBO-GRUQR	89.95	13.24
	LSTMQR	90.74	13.73
	MOBO-LSTMQR	91.83	13.17
80	GRUQR	84.53	12.14
	MOBO-GRUQR	86.19	11.86
	LSTMQR	87.13	12.30
	MOBO-LSTMQR	88.00	11.80

表5 不同预测模型的分位数平均误差

预测模型	MAPE/%	RMSE
LSTMQR	3.39	10.00
MOBO-LSTMQR	3.21	9.53
GRUQR	3.51	10.10
MOBO-GRUQR	3.36	9.86
CNN-LSTMQR	4.55	13.16
CNN-GRUQR	5.33	15.51

明,基于 MOBO 的超参数调整方法降低了模型的预测误差。相比于其他模型,MOBO-GRUQR 和 MOBO-LSTMQR 模型的预测误差更小,MAPE 指标值降低了 0.03%~2.12%,且 RMSE 指标值降低了 0.14~5.98。其中,MOBO-LSTMQR 模型预测精度最高,其 MAPE 和 RMSE 指标值比 MOBO-GRUQR 模型分别降低了 0.15%、0.33。

4 结论

针对新能源并网对电力系统的稳定运行带来重大不确定性的影响,传统的点预测难以提供电力负荷关于差异性和不确定性信息,而区间预测更能直观地反映未来电力负荷的波动范围和变化趋势。因此,本文提出了一种基于 MOBO 的深度学习区间预测模型,通过高效的预测区间来约束数据中的不确定性,更好地规避新能源并网带来不利因素的影响,从而制订出安全、经济的用发电计划。

本文通过实验得出以下结论:1)与 CNN-GRUQR 和 CNN-LSTMQR 模型相比,LSTMQR 和 GRUQR 模型中 PICP、PINAW 和 WS 指标更佳,因此,单项模型在电力负荷的区间预测中表现优于混合模型;2)相比于其他模型,

基于 MOBO 的预测模型能以更高的效率寻找到适合目标任务的超参数组合,且具有更高的预测精度,其中 MOBO-LSTMQR 模型的预测精度最高;3)基于 MOBO 的深度学习区间预测模型弥补了单目标问题无法同时考虑到多个预测区间评价指标的不足,更能有效地刻画未来电力负荷的波动性。

参考文献

- [1] 邓铭江,明波,李研,等.“双碳”目标下新疆能源系统绿色转型路径[J].自然资源学报,2022,37(5):1107-1122.
- [2] 刘士进,孙立华,郭鹏.基于 EEDM-Arima 算法的某地区电力系统负荷预测及算例分析[J].电子测量技术,2020,43(7):185-188.
- [3] 任建吉,位慧慧,邹卓霖,等.基于 CNN-BiLSTM-Attention 的超短期电力负荷预测[J].电力系统保护与控制,2022,50(8):108-116.
- [4] 张淑清,杨振宁,张立国,等.基于弹性网降维及花授粉算法优化 BP 神经网络的短期电力负荷预测[J].仪器仪表学报,2019,40(7):47-54.
- [5] 董浩,李明星,张淑清,等.基于核主成分分析和极限学习机的短期电力负荷预测[J].电子测量与仪器学报,2018,32(1):188-193.
- [6] 张林,刘继春.基于 EEMD-SE 和 PSO-KELM 的短期负荷区间预测方法[J].中国电力,2021,54(3):132-140.
- [7] LI C, TENG Y, AN L, et al. Interval prediction method based on neural networks for short-term load forecasting [C]. Asia Energy and Electrical Engineering Symposium (AEEES). IEEE, 2020: 821-824.
- [8] LI R, HUANG Y, WANG J. Long-term traffic volume prediction based on K-means Gaussian interval type-2 fuzzy sets [J]. IEEE/CAA Journal of Automatica Sinca, 2019, 6(6): 1344-1351.
- [9] BRACALE A, CARAMIA P, DE FALCO P, et al. Multivariate quantile regression for short-term probabilistic load forecasting [J]. IEEE Transactions on Power Systems, 2019, 35(1): 628-638.
- [10] CHEN Y Y, LIU H T, HSIEH H L. Time series interval forecast using GM (1, 1) and NGBM (1, 1) models [J]. Soft Computing, 2019, 23(5): 1541-1555.
- [11] 邢会歌,钱苏琴.城市二手房价格区间估计方法研究—基于神经网络分位数回归模型的分析[J].价格理论与实践,2021(5):85-88,194.
- [12] 李亚茹,张宇来,王佳晨.面向超参数估计的贝叶斯优化方法综述[J].计算机科学,2022,49(S1):86-92.
- [13] 王晓辉,邓威威,齐旺.基于超参数优化的短期电力

- 负荷预测模型 [J]. 国外电子测量技术, 2022, 41(6): 152-158.
- [14] 何军, 林广东, 申小军, 等. 基于贝叶斯优化 XGBoost 的隧道沉降量预测 [J]. 计算机系统应用, 2022, 31(7): 379-385.
- [15] 陈静杰, 梁国栋, 刘家学, 等. 基于非规则分布样本的航段油耗区间估计 [J]. 科学技术与工程, 2022, 22(14): 5935-5941.
- [16] 涂天成, 刘幸. 基于 BiGRU-Copula 的多重不确定性变量的概率区间预测方法 [J]. 电网与清洁能源, 2021, 37(7): 25-33.
- [17] 许彪, 徐青山, 黄煜, 等. 基于藤 copula 分位数回归的光伏功率日前概率预测 [J]. 电网技术, 2021, 45(11): 4426-4435.
- [18] SHI Z, LIANG H, DINAHAHI V. Direct interval forecast of uncertain wind power based on recurrent neural networks [J]. IEEE Transactions on Sustainable Energy, 2017, 9(3): 1177-1187.
- [19] WAN C, LIN J, WANG J, et al. Direct quantile regression for nonparametric probabilistic forecasting of wind power generation [J]. IEEE Transactions on Power Systems, 2016, 32(4): 2767-2778.
- [20] 朱俊丞, 杨之乐, 郭媛君, 等. 深度学习在电力负荷预测中的应用综述 [J]. 郑州大学学报(工学版), 2019, 40(5): 13-22.
- [21] 殷豪, 黄圣权, 孟安波. 基于长短期记忆网络分位数回归的短期风电功率概率密度预测 [J]. 太阳能学报, 2021, 42(2): 150-156.
- [22] 臧海祥, 刘冲冲, 滕俊, 等. 基于 CNN-GRU 分位数回归的短期母线负荷概率密度预测 [J]. 智慧电力, 2020, 48(8): 24-30.
- [23] 易淑智, 刘云凯, 杨帆, 等. 基于改进门控循环单元分位数回归的短期负荷概率预测 [J]. 智慧电力, 2021, 49(8): 84-90.
- [24] 唐戈, 余一平, 秦川, 等. 基于 CNN-LSTM 分位数回归的母线负荷日前区间预测 [J]. 电力工程技术, 2021, 40(4): 123-129.
- [25] ZHANG W, QUAN H, GANDHI O, et al. Improving probabilistic load forecasting using quantile regression NN with skip connections [J]. IEEE Transactions on Smart Grid, 2020, 11(6): 5442-5450.
- [26] WAN C, XU Z, PINSON P, et al. Probabilistic forecasting of wind power generation using extreme learning machine [J]. IEEE Transactions on Power Systems, 2014, 29(3): 1033-1044.

作者简介

杜茂康, 教授, 主要研究方向为管理信息系统、数据分析等。

张雪, 硕士研究生, 主要研究方向为电力负荷预测。

肖玲, 博士, 主要研究方向为测理论与方法、电力负荷预测等。

E-mail: xiaoling5231@163.com

江河, 博士, 主要研究方向为光伏功率预测理论、数据挖掘等。