

基于可解释深度学习的电力负荷预测模型^{*}

李妙彤¹ 王永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:深度学习模型在时间序列预测中得到了广泛的应用,然而,传统的深度学习点预测模型更多关注未来某个特定时刻的预测值,无法描述复杂时间序列预测的不确定性。此外,大多数深度学习模型的预测过程是不透明的,使用者对深度学习预测模型的内部机理缺乏认识,导致模型预测的可解释性偏低。针对上述问题,引入了分位数回归理论,刻画复杂时间序列预测的不确定性特征;构建可解释深度学习模型并应用于纽约州首府地区的短期电力负荷预测。结果表明,预测模型在两个数据集上都具有较好的区间预测结果,置信水平为95%时,该模型在1月和7月的PICP值分别为94.28%、93.23%,区间覆盖率趋于置信水平。相比于对比模型,模型的预测精度高、泛化能力强,能够提升短期电力负荷预测中的稳定性,可为电网管理者的相关决策提供数据支撑。

关键词:深度学习;可解释性;分位数回归;电力负荷;区间预测

中图分类号: TM715 **文献标识码:** A **国家标准学科分类代码:** 630.50

Power load forecasting model based on interpretable deep learning

Li Miaotong¹ Wang Yong¹ 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 Institute of Technology, Xuzhou 221018, China;

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

Abstract: Deep learning model has been widely used in time series prediction. However, the traditional deep learning point prediction model pays more attention to the predicted value at a certain moment in the future, and cannot describe the uncertainty of complex time series prediction. In addition, the prediction process of most deep learning models is opaque, and users lack understanding of the internal mechanism of deep learning prediction models. As a result, the interpretability of the model prediction is low. To tackle the above issues, quantile regression theory is introduced to describe the uncertainty characteristics of complex time series prediction and an interpretable deep learning model is constructed and applied to power load prediction in a region of New York State. The results show that the prediction model in this paper has good interval prediction results on the two data sets. The confidence level is 95%, the PICP values of the model in January and July are 94.28% and 93.23%, respectively. The interval coverage tends to the confidence level. Compared with the comparison model, the proposed model has high prediction accuracy and strong generalization ability. It can improve the stability of short-term power load prediction and provide data support for the power grid manager's decision making.

Keywords: deep learning; interpretability; quantile regression; power load; interval prediction

收稿日期:2023-02-20

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

0 引言

准确可靠的电网调度计划是电力系统运行中的重要组成部分,在保证电力系统稳定运行的前提下,灵活处理电力系统的意外事故,避免造成不必要的损失。因此,在电网的管理中,制定合理的电网调度对保证电力系统的安全可靠性是很有必要的^[1-2]。电力负荷预测作为发电厂的发电配置与电网调度间的重要纽带,高精度的电力负荷预测结果可以为电网调度提供理论依据,帮助电力行业管理人员制定合理的电网调度计划,并且可以维持电网的供需平衡,进而保证电力系统安全稳定地运行^[3]。

目前,传统的深度学习在电力负荷的点预测方面应用广泛。赵辉等^[4]结合支持向量回归(support vector regression, SVR)能够处理非线性序列的优点,将小波分解—卷积神经网络和 SVR 应用于短期负荷预测,并取得了较好的预测效果,但是 SVR 方法不能处理大规模的数据训练。曾德斌等^[5]利用粒子群优化(particle swarm optimization, PSO)算法优化 BP 神经网络,该方法可以训练大规模的数据,对短期电力负荷进行预测,但是容易出现过拟合的现象。邹浩等^[6]提出了改进 PSO-Elman 神经网络(Elman neural network, ENN),并将其应用于短期电力负荷预测,该方法比传统的 ENN 精度高。

鉴于传统的深度学习模型训练过程耗时且容易出现过拟合,学者们提出了改进深度学习方法,该方法有诸多的层能够学习不同的数据特征,在短期电力负荷预测上具有较强的预测性能。程焕新等^[7]提出了改进的循环神经网络(recurrent neural network, RNN),在精确刻画负荷变化的同时克服了数据随机性的难点。为了进一步解决新能源时代的负荷随机性的问题,徐岩等^[8]将 PSO 优化后的门控循环单元(gated recurrent unit, GRU)神经网络用于短期电力负荷预测,结果表明该方法比 BP 神经网络和 SVR 的预测精度高。考虑到负荷受外部影响因素的影响,李德璐等^[9]提出了基于卷积神经网络(convolutional neural networks, CNN)的负荷预测,该方法可以有效提取负荷数据的特征,提高了时间复杂度。王晓辉等^[10]利用改进 PSO 算法优化长短期记忆(long short-term memory, LSTM)神经网络的超参数,与传统 BP 模型相比该方法具有较好的预测精度,模型的稳定性更强。针对电力负荷数据由于时序特征复杂而导致的精度不高问题,黄海荣等^[11]提出一种基于经验模态条件生成对抗网络(conditional generation adversarial network, CGAN),该模型比其他深度学习模型的预测误差小,安全性高。上述深度学习模型预测精度较高,在电力负荷预测领域的应用也最为广泛。但是深度学习模型是一个黑盒模型,模型的网络层数较多,复杂性较高,模型内部的预测过程也较难解释^[12]。挖掘输入特征与目标特征间的相关性,进而提升了模型的预测性能和可解释性是很有必要的。

上述提到的传统的深度学习预测模型大多都是基于

确定性的点预测方法,可以得到高精度的预测结果。由于电力负荷时间序列数据受到外界不确定因素的影响,容易出现波动特征。点预测方法只能得到单一点的预测值,未能提供负荷值可能的波动范围。为了量化电力负荷的不确定性,构建区间预测模型对短期电力负荷进行区间预测是很有必要的,从而加强电力系统的调度控制,减少由于发电不足而造成的安全隐患问题^[13]。区间预测可以为未来负荷预测值提供波动范围,预测精度高,预测区间更可靠,可以解决了点预测模型的单一值问题。

本文构建了基于可解释深度学习的电力负荷区间预测模型。首先,该方法针对电力负荷时间序列的波动性、非平稳性等复杂特征,引入分位数回归(quantile regression, QR)理论构造负荷预测区间,得到电力负荷预测值可能的波动范围;其次,考虑到深度学习预测过程的不透明性,选择输入特征维度,挖掘输入特征与目标变量之间的潜在联系;最后,在纽约州首府地区的电力负荷数据集上进行实验仿真。结果表明,本文方法对短期电力负荷具有较好的预测性能,模型的泛化能力强,可以得到准确且可靠的预测结果,为电网调度管理带来有力的数据支撑和理论依据。

1 神经网络分位数回归模型

1.1 长短期记忆网络

LSTM 网络是为了解决 RNN 由于训练时间过长以及网络层数的增多而造成的梯度消失和梯度爆炸的缺点而提出的^[14]。

相比于 RNN 单个循环结构,LSTM 单个循环结构内部共有 4 个状态,输入门 i_t 、遗忘门 f_t 、输出门 o_t 以及记忆单元状态 C_t 。LSTM 通过门控单元来控制网络中信息的传递,不仅使得循环网络保持一个稳定持久的单元状态不断向下传递,而且能够判断信息是被遗忘还是继续传递下去^[15]。LSTM 网络模型的具体结构如图 1 所示。




图1 LSTM网络结构

首先,LSTM网络采用遗忘门 f_t 来决定哪些信息需要保存或者丢弃,遗忘门将 $t-1$ 时刻的输出 h_{t-1} 以及 t 时刻新的输入 x_t 作为 sigmoid 函数的输入,从而计算遗忘门 f_t 。

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

式中: f_t 为遗忘门; σ 为 sigmoid 激活函数; W_f 和 b_f 分别为遗忘门的权值和偏置; h_{t-1} 为 $(t-1)$ 时刻的输出; x_t 为 t 时刻的输入。

然后, LSTM 网络采用输入门 i_t 决定更新哪些值, 输入门将 $t-1$ 时刻的输出 h_{t-1} 以及 t 时刻新的输入 x_t 作为 sigmoid 函数的输入, 从而计算输入门 i_t ; 并使用 tanh 层来获取 t 时刻的暂定状态 $\hat{C}_t$ 。

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

$$\hat{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

式中: i_t 为输入门; tanh 为激活函数; W_i 和 b_i 分别为输入门的权值和偏置; $\hat{C}_t$ 为 t 时刻的暂定状态; W_c 和 b_c 分别为暂定状态 $\hat{C}_t$ 的权值和偏置。

其次, LSTM 网络采用遗忘门 f_t 、输入门 i_t 以及 $(t-1)$ 时刻的单元状态 C_{t-1} 来决定如何更新 t 时刻的单元状态 C_t 。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{C}_t \quad (4)$$

式中: C_t 为 t 时刻的单元状态; C_{t-1} 为 $t-1$ 时刻的单元状态。

最后, LSTM 网络采用输出门决定输出哪些信息, 输出门将 $t-1$ 时刻的输出 h_{t-1} 以及 t 时刻新的输入 x_t 作为 sigmoid 函数的输入, 从而计算输出门 o_t ; 并使用 tanh 层来处理单元状态的数值, 将其控制在 $[-1, 1]$, 获取 t 时刻的最终输出 h_t , 即为 LSTM 模型的最后输出。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

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

式中: o_t 为输出门; W_o 和 b_o 分别为输出门的权值和偏置; h_t 为隐藏层的输出。

1.2 分位数回归

通常所说的回归是均值回归仅对问题进行确定点的数值预测是不够的, 并且均值回归不能解决非对称分布的数据, QR 可以说明解释变量与响应变量的条件分位数之间的关系, 通过倾斜绝对值函数对正负误差赋予非对称权值, 它的优点是在传统均值回归的基础上计算响应变量的条件分位数^[16], 根据不同分位点可以输出多个负荷预测值, 进而构造区间预测。假设解释变量为 $\mathbf{X} = [x_1, x_2, \dots, x_n]$, 响应变量为 $\mathbf{Y} = [y_1, y_2, \dots, y_n]$, n 为样本总量, 分位数回归的表达式为:

$$Q_{y_i}(\tau | x_i) = x_i \beta(\tau) \quad t = 1, \dots, n \quad (7)$$

$$\beta(\tau) = [\beta_0(\tau), \beta_1(\tau), \dots, \beta_n(\tau)]' \quad (8)$$

式中: $Q_{y_i}(\tau | x_i)$ 为 τ 分位点下的条件分位数预测值; $\beta(\tau)$ 为回归系数向量, 它随分位点 τ 变化, $\tau \in (0, 1)$ 。

$\beta(\tau)$ 可通过加权最小绝对离差和来求解。

$$\hat{\beta}(\tau) = \operatorname{argmin} \left(\sum_{i=1}^n \varphi_{\tau}(y_i - x_i \beta(\tau)) \right) \quad (9)$$

$$\varphi_{\tau}(\vartheta) = \begin{cases} \tau \vartheta, & \vartheta \geq 0 \\ (\tau - 1) \vartheta, & \vartheta < 0 \end{cases} \quad (10)$$

$$\vartheta = y_i - x_i \beta(\tau) \quad (11)$$

式中: $\hat{\beta}(\tau)$ 为 $\beta(\tau)$ 的估计值; $\varphi_{\tau}(\alpha)$ 为检查函数; x_i 和 y_i 分别为解释变量和响应变量。

1.3 LSTM 分位数回归模型

短期电力负荷具有复杂性, 由此借助神经网络来处理电力负荷复杂的非线性序列, 因此将神经网络与分位数回归进行结合。本文借助分位数回归模型输出多个分位点下的预测值, 将 LSTM 和 QR 相结合, 构建 QR-LSTM 网络模型, QR-LSTM 模型的结构如图 2 所示。该模型在不同的置信水平下, 可以输出多个分位点的负荷预测值。设 LSTM 神经网络隐含层有 K 个神经元, 得到 QR-LSTM 模型的输出为:

$$Q_{y_i}(\tau | x_i, \mathbf{W}, \mathbf{b}) = f \left(\sum_{k=1}^K W_k(\tau) h_k(\tau) + b_k(\tau) \right) \quad (12)$$

式中: $Q_{y_i}(\tau | x_i, \mathbf{W}, \mathbf{b})$ 为 QR-LSTM 模型 t 时刻的输出; $W_k(\tau)$ 和 $b_k(\tau)$ 分别为 τ 分位点下神经网络隐含层输出与全连接层输入之间的权值和偏置; $h_k(\tau)$ 为 τ 分位点下隐含层的输出值; $f(\cdot)$ 为激活函数。




图2 QR-LSTM模型结构

2 基于可解释深度学习的预测模型

2.1 深度学习可解释性模型构建

本文提出的基于可解释深度学习的电力负荷预测模型, 使用 LSTM 网络解决了电力负荷时间序列数据之间的依赖性, 使用分位数回归输出电力负荷时间序列在不同分位点下的条件分位数预测值, 构建区间预测模型对电力负荷时间序列中存在的确定性信息进行量化。此外, 为了阐述深度学习模型预测过程中的内部机制, 引入 Shapley 值对模型的输入特征维度进行选择, 选择最佳输入维度进行训练, 并且将该方法应用于实际电力负荷的预测, 取得了良好的结果, 预测流程如图 3 所示。

步骤 1) 电力负荷数据集预处理。该部分包括数据集划分、选择训练集数据输入特征维度。

步骤 2) 构建 QR-LSTM 预测模型。该部分包括模型训练和模型预测, 将训练好的 QR-LSTM 模型用于测试集进行预测, 最后采用评价指标平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)。




图3 可解释深度学习的电力负荷预测模型流程

RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)、分位数评分(quantile scoring, QS)来对比观测值和预测值。

步骤3)使用QR-LSTM模型输出条件分位数预测值。该部分主要设置多个分位点,QR-LSTM模型输出不同分位点时的电力负荷预测值。

步骤4)预测区间构造。该部分分别求出不同分位点时条件下分位数预测值的均值和方差,不同分位点的预测值服从高斯分布,则预测区间上下限为:

$$L_t^a = \mu_t - Z_{1-\frac{\alpha}{2}} \sqrt{\sigma_t^2} \quad (13)$$

$$U_t^a = \mu_t + Z_{1-\frac{\alpha}{2}} \sqrt{\sigma_t^2} \quad (14)$$

式中: L_t^a 、 U_t^a 分别是预测区间下限和上限; μ_t 为均值; σ_t^2 为方差; $Z_{1-\frac{\alpha}{2}}$ 为临界值; $1-\alpha$ 为置信水平。

步骤5)区间预测模型的评价。本文使用PICP和PINAW来评估区间预测模型性能。

2.2 预测模型评价指标

电力负荷时间序列预测得到的结果为具体的负荷值,负荷实际值与回归模型得到的负荷预测值之间的误差对于回归模型的性能尤为重要,因此选择MAE、RMSE、MAPE和QS等评价指标来评价点预测模型的性能^[17]。

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (16)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (17)$$

式中: y_t 为第 t 个测试样本的实际值; $\hat{y}_t$ 为第 t 个测试样本的预测值; n 为测试样本总量。MAE、RMSE、MAPE能够很好的估计实际值与预测值之间的误差,若实际值与预测值之间的误差越小,相应的回归模型的预测性能也就越好,因此误差评价指标的值越小越好。

QS评价预测模型的锐度,QS值越小,预测模型的锐度特性就越优,具体计算公式如下:

$$Q(\hat{y}_t^\tau, y_t) = \begin{cases} \left(1 - \frac{\tau}{100}\right) (\hat{y}_t^\tau - y_t), & y_t < \hat{y}_t^\tau \\ \frac{\tau}{100} (y_t - \hat{y}_t^\tau), & y_t \geq \hat{y}_t^\tau \end{cases} \quad (18)$$

$$Q(total) = \frac{1}{nm} \sum_{t=1}^n \sum_{\tau=1}^m Q(\hat{y}_t^\tau, y_t) \quad (19)$$

式中: $Q(\hat{y}_t^\tau, y_t)$ 为第 t 个测试样本的分位数评分; $\hat{y}_t^\tau$ 为第 t 个测试样本在第 τ 分位点处的分位数; y_t 为第 t 个测试样本的实际值; n_τ 为分位数的个数; n 为测试样本总量; $Q(total)$ 为总测试样本的分位数评分。

为了度量预测区间的可靠性和不确定性程度,选择预测区间覆盖率(prediction interval coverage probability,

PICP)和预测区间归一化平均宽度(prediction interval normalized average width, PINAW)来评价区间预测模型的性能^[18]。

$$PICP = \frac{1}{n} \sum_{i=1}^n k_i \quad (20)$$

$$k_i = \begin{cases} 1, & y_i \in (L_i, U_i) \\ 0, & y_i \notin (L_i, U_i) \end{cases} \quad (21)$$

$$PINAW = \frac{1}{nR} \sum_{i=1}^n (U_i - L_i) \quad (22)$$

$$R = y_{\max} - y_{\min} \quad (23)$$

式中: k_i 为布尔变量; y_i 为实际值; n 为测试样本总量; L_i 和 U_i 分别为预测区间的下限和上限; R 为归一化因子; $y_{\max}$ 和 $y_{\min}$ 分别为实际值的最大值和最小值。PICP 值越大, 区间覆盖率越高, 覆盖能力越强; PINAW 值越小, 区间宽度越窄, 区间预测性能越好。

3 实例分析

3.1 数据集来源及模型可解释性

本文方法在纽约州首府地区 2019 年 1 月和 7 月的电

力负荷时间序列数据集上进行了实验验证。该地区的电力负荷数据是以半小时的时间间隔采集的, 实验数据集按 8:2 的比例划分。

本文依次选择相应数据作为模型的输入进行验证模型的最佳输入个数, 最终得到模型的最佳输入长度为 4, 其 Shapley 值的具体计算公式如下:

$$E_i = \sum \frac{(|s| - 1)! (m - |s|)!}{m!} \times \gamma \quad (24)$$

$$\gamma = E(s) - E(s - \{i\}) \quad (25)$$

式中: i 为模型的输入数据; E_i 为 Shapley 值; s 为交易 i 的组合; $|s|$ 为组合中的输入数据个数; m 为参与模型预测的输入数据的总个数; $s - \{i\}$ 为在组合中除去成员 i 。

3.2 实验结果分析

为了验证本文提出可解释性 QR-LSTM 模型的预测性能, 选择基于 SVR、ENN、GRU 分位数回归模型分别在该地区 2019 年 1 月和 7 月的数据集上进行对比实验, 选择该地区 2019 年 1 月 26 日~1 月 31 日、2019 年 7 月 26 日~7 月 31 日的负荷数据进行预测。计算了 4 种模型的 MAE、RMSE、MAPE、QS 值, 实验结果如表 1 所示。

表 1 各模型的点预测结果比较(2019 年 1 月和 7 月)

预测模型	1 月份				7 月份			
	MAE/MW	RMSE/MW	MAPE/%	QS	MAE/MW	RMSE/MW	MAPE/%	QS
SVR	14.95	19.41	0.97	13.53	17.91	23.40	1.05	19.85
ENN	66.66	85.02	4.33	71.40	107.28	125.02	6.49	28.74
GRU	93.74	114.17	6.13	45.64	103.70	122.78	6.47	63.26
LSTM	68.88	83.36	4.45	31.53	80.54	95.37	4.79	20.63

由表 1 可以看出, 在两个数据集上, SVR 模型在确定性点预测上的效果较好; 在 2019 年 1 月份数据集上, LSTM 模型的 MAPE 的值为 4.45%, 预测精度相对较高, QS 的值为 31.53, 分别比 ENN 模型和 GRU 模型低 39.83、14.11。同样地, 在 2019 年 7 月份数据集上, LSTM 模型的 MAPE 值为 4.79%, QS 值为 20.63, 在两个数据集上模型的预测精度相似, 该实验结果表明本文所提出模型的泛化能力较强, 能够对不同的电力负荷数据集进行预测。

为了验证本文所提出模型的短期电力负荷区间预测性能及其泛化能力, 分别在该地区 2019 年 1 月份和 7 月份的电力负荷数据集上进行预测。首先在 2019 年 1 月份数据集上进行对比实验, 选择基于 SVR、ENN、GRU 的分位数回归模型在同一数据集上进行对比实验。分别计算了 4 种模型在置信水平为 85%、90%、95% 时的 PICP 和 PINAW 值, 如表 2 所示。由表 2 可以看出, 当置信水平由 85% 增加到 95% 时, 4 个模型的 PICP 值都逐渐变高, 逐渐逼近于置信水平。

表 2 各模型在不同置信水平下的区间预测结果比较(基于 2019 年 1 月份负荷数据集)

(%)

预测模型	PICP			PINAW		
	85	90	95	85	90	95
QR-SVR	59.93	62.63	65.66	22.71	25.87	30.91
QR-ENN	86.53	83.16	90.24	102.96	117.26	140.14
QR-GRU	76.77	80.13	85.52	204.57	232.98	278.44
QR-LSTM	86.53	90.57	94.28	123.60	140.77	168.24

从表 2 可以看出, QR-LSTM 模型在纽约州首府地区 2019 年 1 月份的电力负荷数据集上区间覆盖率较高, 区间预测性能也最优。当置信水平为 95% 时, QR-LSTM 模型

的 PICP 值分别为 94.28%, 本文模型比模型 QR-SVR、QR-ENN、QR-GRU 分别高 28.62%、4.04%、8.76%, 同样可以看出, 在置信水平为 90%、85% 时, 本文模型的 PICP 值都

高于对比模型。结果表明该模型区间预测覆盖率较高,接近于置信水平,区间覆盖能力较强,预测性能达到最优,可以对短期电力负荷进行预测。很好地量化了电力负荷时间序列由于外界不确定因素带来的干扰,使得预测结果在一

个区间范围内,可以衡量电力负荷的不确定性。

为了验证模型的泛化能力,同样选择纽约州首府地区2019年7月份电力负荷数据集进行区间预测,实验结果如表3所示。

表3 各模型在不同置信水平下的区间预测结果比较(基于2019年7月份负荷数据集)

(%)

预测模型	PICP			PINAW		
	85	90	95	85	90	95
QR-SVR	73.74	77.44	80.81	21.72	24.74	29.56
QR-ENN	66.33	76.09	89.56	114.36	130.24	155.66
QR-GRU	74.41	77.44	86.20	119.37	135.95	162.47
QR-LSTM	80.71	87.44	93.23	87.53	99.69	119.14

由表3可知,在2019年7月份的负荷数据集上,本文所提出模型的区间预测性能优于其他对比模型。当置信水平为95%时,QR-LSTM模型的PICP值为93.23%,接近于置信水平,PINAW值为119.14%,分别比QR-ENN模型和QR-GRU模型低36.52%、43.33%。实验结果表明本文模型的区间预测覆盖能力较强,预测区间更加可靠。综上所述,本文提出的基于可解释深度学习的短期电力负荷区间预测模型在不同数据集上表现良好,预测性能优于对比模

型,实验结果表明,该模型具有较强的泛化能力。

为了使得本文所用模型的区间预测结果变化更加地直观,分别绘制了QR-LSTM模型在纽约州首府地区2019年1月和7月电力负荷数据集上不同置信水平下的区间预测结果,如图4和5所示,图中横坐标代表预测的时间点,以每30 min为间隔,纵坐标代表电力负荷值,图中主要对置信水平为80%、85%、90%、95%时的区间预测结果进行分析。




图4 QR-LSTM模型在该地区2019年1月份的区间预测结果

图4为纽约州首府地区2019年1月26日~1月31日的电力负荷数据进行预测;图5为纽约州首府地区2019年7月26日~2019年7月31日的电力负荷数据进行预测。

由图4和5可以看出,本文提出的模型在不同数据集上的区间预测性能优异,区间覆盖率随着置信水平的增加而变高。对比可以得到本文使用的可解释的深度学习区间预测模型的区间覆盖率基本可以涵盖电力负荷实际值,对电力负荷时间序列的预测效果良好。该模型不仅可以挖掘电力负荷时间序列的非线性特征、量化电力负荷时间

序列由于受到天气、季节、节假日等不确定因素的造成的非平稳性和波动性特征,使得预测值在一个波动范围内,捕捉电力负荷序列有效的不确定性信息;而且可以很好地解释深度学习模型预测过程输入特征和目标特征间的相关性。

4 结论

本文针对传统的深度学习点预测模型量化不能电力负荷的不确定性信息,提出了一种基于可解释深度学习的短期电力负荷区间预测模型,可以得到未来负荷值的波动




图5 QR-LSTM模型在该地区2019年7月份的区间预测结果

区间,通过可靠的预测区间度量电力负荷数据的不确定性,通过对比实验得出以下结论。

1)本文预测模型可以输出不同分位点下的电力负荷条件分位数预测值,构造电力负荷预测区间,量化了电力负荷数据的不确定性信息。

2)该预测模型验证了电力负荷多输出和输入特征之间的相关性,得到模型的最佳输入维度为4,从而提高电力负荷预测过程的可解释性。

3)将该模型用于两个数据集,结果表明模型在两个数据集上的预测精度更高,区间覆盖率都比较高,模型的泛化能力强。

4)通过实验对比4种区间预测模型的预测精度,发现本文模型的预测区间覆盖率较高,预测区间也更加可靠,可以提供更多有关预测结果的不确定性信息,为制定电网调度计划提供数据支撑。

参考文献

- [1] 胡雅蓉,王彦文,王晨光. 新能源对电网调度管理的影响分析[J]. 集成电路应用, 2023, 40(2): 306-308.
- [2] NIE Y, JIANG P, ZHANG H. A novel hybrid model based on combined preprocessing method and advanced optimization algorithm for power load forecasting[J]. Applied Soft Computing, 2020, 97: 106809.
- [3] 余登武,刘敏,蒲凡诺,等. 基于深度学习分位数回归的电力负荷区间预测方法[J]. 广东电力, 2022, 35(9): 1-8.
- [4] 赵辉,杨赛,岳有军,等. 基于小波分解-卷积神经网络和支持向量回归的短期负荷预测[J]. 科学技术

与工程, 2021, 21(25): 10718-10724.

- [5] 曾德斌,许江淳,杨杰超,等. 基于数据挖掘的PSO-BP短期电力负荷预测[J]. 自动化仪表, 2020, 41(5): 93-97.
- [6] 邹浩,窦震海,张博,等. 基于提升小波和改进PSO-Elman神经网络的短期负荷预测[J]. 电测与仪表, 2020, 57(21): 119-125.
- [7] 程焕新,黄震. 基于改进PSO优化RNN的短期电力负荷预测模型[J]. 电子测量技术, 2019, 42(20): 94-98.
- [8] 徐岩,向益锋,马天祥. 基于粒子群算法优化参数的VMD-GRU短期电力负荷预测模型[J]. 华北电力大学学报(自然科学版), 2023, 50(1): 38-47.
- [9] 李德璐,赵金脉,李大华,等. 基于卷积神经网络的负荷预测[J]. 能源工程, 2022, 42(6): 75-79.
- [10] 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.
- [11] 黄海荣,吴君,郁丹,等. 基于经验模态条件生成对抗网络的短期负荷预测[J]. 自动化仪表, 2022, 43(12): 25-29,37.
- [12] 陈孝文,苏攀,李夏青,等. 基于时域融合Transformers的可解释预测模型及其应用研究[J]. 武汉理工大学学报(信息与管理工程版), 2022, 44(2): 307-313.
- [13] HU J, LIN Y, TANG J, et al. A new wind power interval prediction approach based on reservoir computing and a quality-driven loss function[J]. Applied Soft Computing, 2020, 92: 106327.

- [14] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. 仪器仪表学报, 2021, 42(4): 111-120.
- [15] 邢红涛, 郭江龙, 刘书安, 等. 基于 CNN-LSTM 混合神经网络模型的 NO_x 排放预测[J]. 电子测量技术, 2022, 45(2): 98-103.
- [16] 杨召, 徐姣新. 基于分位数回归平均的电力负荷统计建模与预测[J]. 计算机应用与软件, 2021, 38(11): 98-103, 204.
- [17] 江兵, 杨春, 杨雨亭, 等. 基于 ACO 优化 BP 神经网络的变压器热点温度预测[J]. 电子测量与仪器学报, 2022, 36(10): 235-242.
- [18] 张金良, 刘子毅. 基于混合模型的超短期风速区间预

测[J]. 电力系统保护与控制, 2022, 50(22): 49-58.

作者简介

李妙彤, 硕士研究生, 主要研究方向为电力负荷预测、预测理论与方法。

王永, 博士, 教授, 主要研究方向为数据分析、管理信息系统等。

肖玲(通信作者), 博士, 副教授, 主要研究方向为能源预测、电力负荷预测、预测理论与方法等。

E-mail: xiaoling5231@163.com

江河, 博士, 副教授, 主要研究方向为统计建模和机器学习等。