

DOI: 10.19783/j.cnki.pspc.211472

基于注意力机制的 CNN-LSTM 短期电价预测

吉兴全¹, 曾若梅¹, 张玉敏¹, 宋峰², 孙鹏凯¹, 赵国航¹

(1. 山东科技大学电气与自动化工程学院, 山东 青岛 266590;

2. 国家电网山东电力公司烟台供电公司, 山东 烟台 264000)

摘要: 短期电价预测结果的准确性对存在多元化竞争格局的电力市场具有重要意义。为提高在电价跳跃点和尖峰点的预测精度及预测效率, 针对多因素融合影响的电价序列与其影响因素间隐含的非线性关系, 提出了一种基于 ATT-CNN-LSTM 的短期电价预测方法。首先, 采用灰色关联度分析法分析负荷因素与电价之间的关联程度, 筛选出关联度较高的数据作为最优模型输入。其次, 通过注意力机制(Attention, ATT)自适应分配输入数据的权重, 以权重大小区分强弱特征数据。再利用卷积神经网络(Convolution Neural Networks, CNN)对数据集进行二次特征提取及降维处理, 优化输入长短期记忆神经网络(Long Short-Term Memory, LSTM)中的数据, 从而提升 LSTM 网络的预测精度与训练速度。对澳大利亚电力市场的实测数据进行算例分析, 通过与其他主流算法对比, 验证了所提方法具有更高的预测精度和计算效率。

关键词: 注意力机制; 卷积神经网络; 长短期记忆神经网络; 电价预测; 灰色关联度分析

CNN-LSTM short-term electricity price prediction based on an attention mechanism

Ji Xingquan¹, Zeng Ruomei¹, Zhang Yumin¹, Song Feng², Sun Pengkai¹, Zhao Guohang¹

(1. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China;

2. Yantai Power Supply Company, State Grid Shandong Electric Power Company, Yantai 264000, China)

Abstract: The accuracy of short-term electricity price forecasts is of great significance to the electricity market with a diversified competitive landscape. To improve prediction accuracy and efficiency at the jump and peak points of electricity price, a short-term electricity price prediction method based on ATT-CNN-LSTM is proposed for the implied nonlinear relationship between the electricity price series influenced by the fusion of multiple direct and influencing factors. First, the grey correlation degree analysis method is used to analyze the correlation degree between load factors and electricity prices, and the data with a higher correlation degree is selected as the optimal model input. Secondly, the weight of the input data is adaptively allocated through the attention mechanism (ATT), and the strong and weak feature data are distinguished by the weights. Then, a convolution neural network (CNN) is used to perform secondary feature extraction and dimensionality reduction of the data set to optimize the data input into the long short-term memory (LSTM) network, thereby improving the prediction accuracy and training speed of the LSTM network. The actual measurement data of the Australian electricity market is used for a case study, and the comparison with other mainstream algorithms verifies that the proposed method has higher prediction accuracy and computational efficiency.

This work is supported by the Youth Fund of National Natural Science Foundation of China (No. 52107111).

Key words: attention mechanism; convolutional neural network; long-short term memory neural network; electricity price forecast; grey relation analysis

0 引言

我国目前已初步形成了电力市场主体的多元化

竞争格局, 开放了竞争性环节电力价格。电价是电力市场的核心, 掌握短期电价的变化趋势可以提高售电主体的收益, 用户可以提前做好生产计划以降低成本, 因此短期电价预测成为电力市场的焦点。

目前对短期电价的预测方法可分为两类, 第一类为时间序列法^[1], 即利用电价时间序列的相关性, 通过已有样本建立电价时间序列模型, 从而进行样

基金项目: 国家自然科学基金青年项目资助(52107111); 山东省自然科学基金青年项目资助(ZR2021QE117); 青岛西海岸新区2020年科技项目资助(源头创新专项)(2020-92)

本外电价预测的方法^[2]。较为经典的时间序列模型有累积式自回归滑动平均(Auto Regressive Integrated Moving Average, ARIMA)模型^[3]和广义自回归条件异方差(Generalized Auto Regressive Conditional Heteroskedastic, GARCH)模型^[4]等。时间序列法具有建模简单与易于实施的特点^[5]。文献[6]在 ARIMA 电价预测模型的基础上,同时对电价预测模型的误差进行预测,并用预测的误差修正电价提高整体预测精度,但该方法需要不断增加模型的阶数以达到精度要求。文献[7]提出一种基于小波变换和非参数 GARCH 模型的时间序列电价预测方法,用小波变换将原始数据分解重构后用 ARIMA 建模预测,再利用非参数 GARCH 模型对预测残差的随机波动率建模以修正预测电价。但此类方法只适用于电价波动小的简单电力市场,并且无法处理非线性和多变量关系。第二类为神经网络法,常用的有 BP 神经网络^[8]、极限学习机^[9]、支持向量机^[10]及随机森林^[11]等,处理多变量问题是神经网络法的优势,其不仅可以找出电价序列与电价影响因素的隐式映射关系,还能降低预测时间,提高预测精度。然而传统单一神经网络模型如循环神经网络(Recurrent Neural Network, RNN)无法处理大数据量的数据集,易出现梯度消失和梯度爆炸现象,导致预测精度越来越难以满足电力市场的要求。因此,如何改进神经网络模型以提高电价预测精度成为问题的关键。

为提高神经网络模型的预测性能,文献[12]提出将注意力机制(Attention, ATT)与门控循环单元(Gate Recurrent Unit, GRU)组合的短期电价预测模型,注意力机制能改善前馈神经网络不能处理时序数据的缺陷,GRU 网络虽能提升预测的速度,但运行结果不稳定。文献[13]将经验模态分解(Empirical Mode Decomposition, EMD)与长短期记忆神经网络(Long Short-Term Memory, LSTM)相结合,将电价序列提取为周期分量和趋势分量,用 LSTM 网络分别预测后,再用支持向量回归(Support Vector Regression, SVR)叠加预测序列,生成预测价格序列。但是对“尖峰”电价等序列异常值处理效果不佳,并且未考虑负荷量等影响因素。文献[14]提出基于图卷积神经网络与 LSTM 网络的时空预测算法,通过建立描述地域分布的电力市场数据并使用图卷积神经网络提取所研究区域和周围地区的信息后,将信息构成时间序列输入到 LSTM 网络进行预测,利用北欧电力交易所运营数据进行算例分析,该算法可以有效地融入统一电力市场的地域信息从而提升算法的预测性能。

电价与负荷量之间存在一定的相关性,同时上一时刻的电价与该时刻电价也存在密切关系。

LSTM 网络善于发现和利用长序列数据的内在规律,在预测精度方面具有优势^[15],但是当特征量较大时, LSTM 的性能会因为过拟合而下降,且所需时间较长,因此不能直接输入带有大量特征的电价数据,需要先对输入的时序数据进行特征提取^[16]。卷积神经网络(Convolution Neural Networks, CNN)对输入的时序数据只能捕捉局部信息,必须通过层叠来获取全局的联系增强视野,而注意力机制可以灵活地捕捉全局与局部的联系,补齐 CNN 的短板。基于此,本文提出基于注意力机制的 CNN-LSTM 短期电价预测模型,以解决传统电价预测模型存在的计算效率低、在电价跳跃点与尖峰点预测精度不高的问题。通过澳大利亚实测数据进行仿真分析,验证了本文预测模型可有效提高在电价跳跃点和尖峰点的预测精度及整体预测效率。

1 方法介绍

CNN 具有局部连接、权重共享等特点,优化了输入 LSTM 模型的电价序列,但依旧难以解决长序列依赖问题,而加入 ATT 可以捕捉长序列中的依赖关系,同时能有效突出影响电价的因素,故本文提出基于 ATT 的 CNN-LSTM 短期电价预测模型。

1.1 ATT

ATT 将有限的计算能力集中到电价序列中的重点信息,从而达到节省计算资源、快速获得最有效信息的目的。ATT 通过加权求和,得到电价序列中每个元素的注意力权重,而注意力权重代表输入信息的重要程度,对权重的自适应分配,提高了模型训练效率和收敛速度,使 ATT 在图像识别、自然语言处理方面得到了广泛的应用^[17]。图 1 为注意力机制工作原理图,其中电价序列元素值为 Value, 序列元素地址为 Key, 查询元素称为 Query, 先对 Query 与每个 Key 中元素值 Value 计算相似度,得到权重系数;再用 soft max 函数归一化权重系数;最后将权重和 Value 进行加权求和,得出 Attention 值。

基于 ATT 的计算步骤如下所述。

1) 对 Query 和 Key 进行相似度计算

$$e_{ij} = D(q_i, p_j) \quad (1)$$

式中: $D(\cdot)$ 表示点积函数; q_i 、 p_j 分别表示查询元素与元素地址集合中的第 i 个和第 j 个元素; e_{ij} 表示元素 i, j 之间的相似度。

2) 对相似度进行归一化

$$\alpha_{ij} = \text{soft max}(e_{ij}) \quad (2)$$

式中: α_{ij} 表示归一化后的相似度; $\text{soft max}(\cdot)$ 表示归一化指数函数。

3) 加权求和

$$c_i = \sum_{j=1}^N \alpha_{ij} q_j \quad (3)$$

式中, c_i 表示权值。

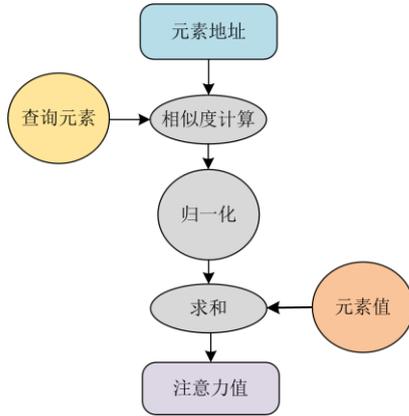


图1 注意力机制工作原理图

Fig. 1 Schematic working diagram of ATT

1.2 卷积神经网络

CNN 的基本结构由输入层、卷积层、池化层、全连接层以及输出层构成^[18]。图2为卷积神经网络示意图,卷积层通过卷积核提取输入电价时间序列的不同特征。池化层位于卷积层之后,通过池化操作减少卷积层间的连接数量,对电价时间序列进行降维和二次特征提取,两者合称为卷积单元。最后经过全连接层汇总所有卷积单元提取的局部特征,并进行分类。

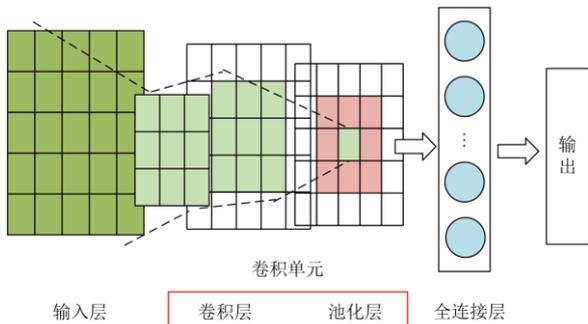


图2 卷积神经网络示意图

Fig. 2 Schematic diagram of CNN

CNN 能从数据中自动学习特征,并且具有局部连接、权值共享、池化操作以及多层结构的特点^[19],大大降低了电价预测模型的复杂程度,通过梯度下降的优化方法,减少过拟合,有更强的泛化能力。对于某些序列的处理,这种一维卷积神经网络的效果可以媲美循环神经网络,而且计算代价要小很多^[20]。卷积层、池化层以及全连接层的计算公式分别为

$$H_i = f(H_{i-1} * W_i + b_i) \quad (4)$$

$$Z_i = \text{subsampling}(Z_{i-1}) \quad (5)$$

$$Y(i) = (L = l_i | H_0; (W, b_a)) \quad (6)$$

式中: H_i 表示卷积层; W_i 表示权值向量; “*” 表示卷积运算; b_i 表示偏置参数; b_a 表示偏移向量; $f(\cdot)$ 表示激励函数; Z_i 表示上采样层; subsampling 表示采样过程; $Y(\cdot)$ 表示输出; \mathbb{L} 表示损失函数; l_i 表示类别标签。

1.3 LSTM 模型

LSTM 通过门结构来控制传输状态,分为遗忘门、选择记忆门和输出门,如图3所示。

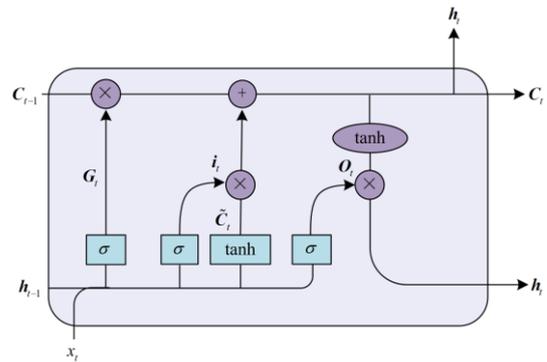


图3 LSTM 网络结构图

Fig. 3 LSTM network structure diagram

遗忘门决定上一单元状态被遗忘的程度,可表示为

$$G_t = \sigma(W_f g[h_{t-1}, x_t] + b_f) \quad (7)$$

式中: G_t 为 t 时刻遗忘门的状态矩阵; h_{t-1} 为上一时刻状态单位的状态矩阵; x_t 为 t 时刻的输入值; $\sigma(\cdot)$ 为激活函数; W_f 为遗忘门的权重矩阵; b_f 为遗忘门常参数矩阵; “g” 表示 LSTM 的点乘操作。

选择记忆门与一个激活函数控制加入新信息的范围。利用遗忘门与选择记忆门输出的共同作用更新本单元的单元状态。

$$i_t = \sigma(W_s g[h_{t-1}, x_t] + b_s) \quad (8)$$

$$C_t^0 = \tanh(W_c g[h_{t-1}, x_t] + b_c) \quad (9)$$

$$C_t = G_t C_{t-1} + i_t C_t^0 \quad (10)$$

式中: i_t 、 C_t^0 、 C_t 分别为 t 时刻输入门、中间量输入、元组状态的状态矩阵; \tanh 为双曲正切激活函数; W_s 、 W_c 分别为输入门、中间量输出的权重矩阵; b_s 、 b_c 为记忆门常参数矩阵。

输出门控制当前单元被过滤的程度,可表示为

$$O_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (11)$$

$$h_t = O_t \tanh(C_t) \quad (12)$$

式中： O_t 为 t 时刻输出门的状态矩阵； W_o 为输出门的权重矩阵； b_o 为输出门常参数矩阵。

2 灰色关联度

灰色关联度分析(Grey Relation Analysis, GRA)是一种多因素统计分析方法^[21]，在一个灰色系统中，以因素的数据序列为依据，用数学的方法研究因素间的几何对应关系，序列与参考序列曲线的几何形状越接近，则它们之间的灰色关联度越大，反之越小。灰色关联度分析可对系统发展变化态势提供量化的度量，非常适合电价、负荷量等动态历程的分析^[22]。比较序列与参考序列所有对应元素的关联系数 ζ_i 可表示为

$$\zeta_i(k) = \frac{\min_i \min_k \Delta r + \rho \max_i \max_k \Delta r}{\Delta r + \rho \max_i \max_k \Delta r} \quad (13)$$

式中： $\Delta r = |x_0(k) - x_i(k)|$ ； ρ 为分辨系数，通常取 0.5。

为了反映比较序列与参考序列之间的关联关系，求出比较序列所有关联系数的均值，称为关联序 r_{0i} ，关联序 r_{0i} 越大，相关性越强，计算公式为

$$r_{0i} = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (14)$$

式中： m 为元素个数；下标“0”表示参考序列； i 表示比较序列。

3 ATT-CNN-LSTM 模型设计

3.1 数据归一化处理

电价和负荷的量纲不同，数值差别较大。为了保证不同变量对输出值的影响力相同，同时保证收敛速度，提升模型精度，对电价与负荷进行归一化处理，将其数值归算到 $[-1, 1]$ 。

$$x' = \frac{x - (x_{\max} - x_{\min})/2}{(x_{\max} - x_{\min})/2} \quad (15)$$

式中： x 为实际值； x' 为归一化后的值； x_{\max} 为变量的极大值； x_{\min} 为变量的极小值。

为了使输出的电价预测值具有现实意义，需对输出数据进行反归一化处理，计算公式为

$$x = 0.5[x'(x_{\max} - x_{\min}) + (x_{\max} + x_{\min})] \quad (16)$$

3.2 模型参数设计

ATT-CNN-LSTM 预测模型的参数设置为：卷积层数为 1，过滤器数为 16，卷积核的大小为 5×5 ，学习率为 0.0009，训练轮数为 400，批训练大小为 32，优化器为 Adam^[23]。参数选定方法为网格搜索法。

3.3 评价指标选取

本文选取平均绝对误差(Mean Absolute Error, MAE)与均方根误差(Root Mean Squared Error, RMSE)作为衡量预测精度的指标。MAE 的计算公式为

$$MAE = \frac{\sum_{i=1}^n |y_i - y'_i|}{n} \quad (17)$$

RMSE 的计算公式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y'_i - y_i)^2}{n}} \quad (18)$$

式中： n 为预测数； y'_i 为电价预测值； y_i 为电价真实值。

3.4 ATT-CNN-LSTM 模型求解

考虑到扩大视野需要叠加多层卷积区的缺陷，为了弥补 CNN 只有局部卷积感受视野，本文模型将 ATT 与 CNN 结合，对输入的时间序列样本进行一次特征提取后，作为 CNN 卷积层的输入，能够减少 CNN 计算量的同时加快特征提取的速度。CNN 进行二次特征提取后，对输出的时间序列进行降维处理。由于 LSTM 网络的模型结构相对复杂，因此输入长时间序列时，模型训练耗时较长，而将 ATT-CNN 提取特征并降维后的时间序列输入到 LSTM 中，在提升 LSTM 预测精度的同时，也可以减少 LSTM 的运行时间。ATT-CNN-LSTM 预测模型求解的流程如图 4 所示。

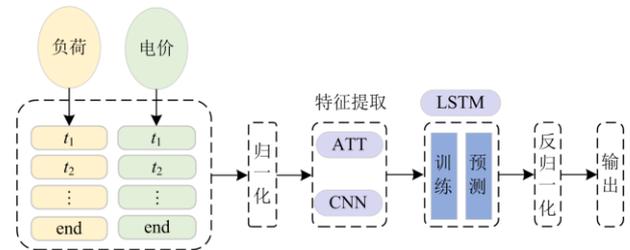


图 4 ATT-CNN-LSTM 模型流程图

Fig. 4 Flow chart of ATT-CNN-LSTM model

基于 ATT-CNN-LSTM 短期电价预测模型的主要步骤如下。

步骤 1：相关性分析。分析影响电价的负荷和电价因素，确定输入序列。

步骤 2：数据预处理。对输入的时间序列进行归一化处理。

步骤 3：特征提取。将归一化后的时间序列用 ATT-CNN 提取其重要特征。

步骤 4：电价预测。将 ATT-CNN 处理过的时间序列输入到 LSTM 单元进行模型训练。

步骤 5: 输出。把预测出的数据反归一化并输出结果。

通过上述步骤, 达到提高预测精度及计算效率的目的。

4 算例分析

本文选取澳大利亚电力市场 2010 年 1 月 1 日至 2011 年 4 月 13 日的实测数据作为数据集, 该数据集包括电价和实时负荷时间序列, 每 30 min 进行一次采样, 剔除掉异常数据后共包含 20 352 个时段^[24]。所有实验均基于 Windows10 操作系统, 软件为 PYTHON, CPU 为 Inter I7-8700k, 3.2 GHz, GPU 为 Intel GTX-1660TI, 并采用 GPU 进行训练与测试。预测模型中应用的训练集、测试集所选取的具体时段和时段数如表 1 所示。

表 1 时段表
Table 1 Time set

数据类型	选取时段	时段数
数据集	2010 年 1 月 1 日—2011 年 4 月 13 日	20 352
训练集	2010 年 1 月 1 日—2010 年 12 月 31 日	17 520
测试集	2011 年 1 月 1 日—2011 年 3 月 1 日	2832

4.1 电价数据特征

电价具有较强的波动性, 根据波动率强弱可将电力市场分为稳定市场(如英国市场)、近似稳定市场(如新西兰市场)和不稳定市场(如澳大利亚市场)^[2], 波动率高的市场电价更难预测。

电价也具有跳跃和价格尖峰特性。电力市场中常出现价格的非正常跳跃、零电价和价格尖峰, 高风电渗透率下电源结构复杂的澳大利亚市场曲线有较多的价格尖峰^[25], 如图 5 所示。价格跳跃和价格尖峰给电价预测带来了巨大的挑战, 现有的方法很难预测出价格跳跃的准确时间和跳跃高度^[2]。为了

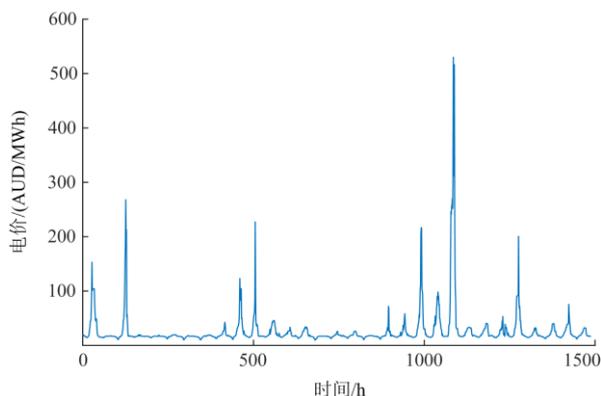


图 5 澳大利亚市场电价曲线

Fig. 5 Australian market electricity price curve

体现本文模型在跳跃点、尖峰点的预测效果, 选用波动率高、价格尖峰多的澳大利亚市场实测数据进行算例分析。

4.2 数据相关性分析

电价和实时负荷密切相关, 两者相互影响^[26]。若仅考虑历史电价, 则模型预测结果误差较大, 模型的外推能力较弱。因此本文使用 GRA 对输入数据相关性进行分析, 选取某时间段负荷量与历史电价作为影响因素并计算其与实时电价的相关性。由于每天的负荷量波动曲线趋势基本一致, 因此随机选取一天的特定时刻即可分析数据总体相关性。本文选取 02:00、06:00、10:00、14:00、21:00 的数据, 使用 GRA 进行相关性分析。具体相关系数如表 2 所示。表中: L 表示负荷量; U 表示电价; t 表示时刻; 数字表示距离该天、该时刻的时间。

表 2 输入样本与电价相关系数表

Table 2 Correlation coefficient table of the input sample and electricity price

输入样本	相关系数	输入样本	相关系数
L_t^{10}	0.7583	U_t^{-7}	0.8277
L_t^9	0.8086	U_t^{-6}	0.9742
L_t^8	0.6623	U_t^{-5}	0.9685
L_t^7	0.7732	U_t^{-4}	0.8689
L_t^6	0.8554	U_t^{-3}	0.9873
L_t^5	0.8654	U_t^{-2}	0.9923
L_t^4	0.7852	U_t^{-1}	0.9821
L_t^3	0.8313	L_{t-3}	0.8071
L_t^2	0.8338	L_{t-2}	0.8126
L_t^1	0.8371	L_{t-1}	0.8314
U_t^{-10}	0.6116	U_{t-1}	0.9923
U_t^{-9}	0.8218	U_{t-2}	0.9899
U_t^{-8}	0.6420	—	—

由表 2 可知, 负荷量与选定时刻电价的相关系数在 3 天前已趋于稳定; 历史电价与选定时刻电价的相关系数在前 5 天时已达到 0.9 以上, 其后虽略有波动, 但幅度不大。在当天前 3 个时刻的负荷量与选定时刻电价的相关系数都维持在 0.8 以上, 且随时间逐渐增加, 而前两个时刻的电价与选定时刻电价的相关系数接近 1。综上所述, 本文使用前 3 天的负荷量、前 5 天的电价、当天前 3 个时刻负荷量、当天前两个时刻电价以及选定时刻历史电价作为模型输入。

4.3 整体预测效果分析

为了验证本文所提 ATT-CNN-LSTM 模型具有

更强的学习能力, 预测结果更精准, 分别采用 ATT-CNN-LSTM 模型、LSTM 模型及 CNN-LSTM 模型对澳大利亚电价进行 300 h 的电价预测, 并对 3 种预测结果进行对比分析, 如图 6 所示。

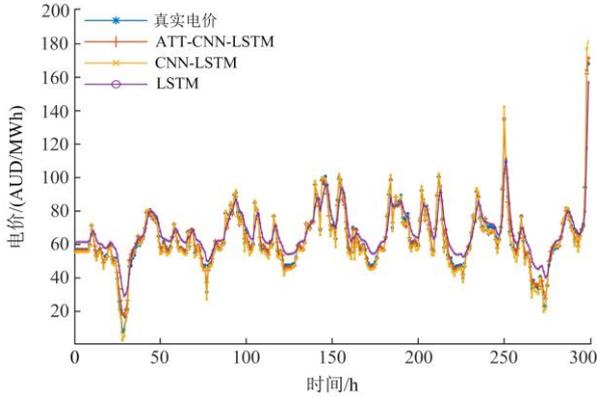


图 6 不同预测模型的结果整体对比

Fig. 6 Overall comparison of the results of different prediction models

由图 6 可知, 3 种预测模型的预测值与实际值相比整体趋势一致, 而本文所提 ATT-CNN-LSTM 模型预测值更为贴近真实值, LSTM 模型预测值偏离真实值较大。主要原因在于, CNN 能从原始输入序列中进行网络学习, 避免手工提取特征导致误差积累的缺点; 而在 CNN 前加入 ATT 环节, 可优先提取重要信息, 优化输入 LSTM 网络的数据, 因此 ATT-CNN-LSTM 网络中能更有效地提取输入电价、负荷量时间序列的特征, 使预测精度提升。

为进一步展现本文所提 ATT-CNN-LSTM 模型在整体预测精度上的优越性, 表 3 列出了 3 种模型的 MAE 与 RMSE。

表 3 不同预测模型的评价指标对比

Table 3 Comparison of evaluation indexes of different prediction models

评价指标	LSTM	CNN-LSTM	ATT-CNN-LSTM
MAE	1.7641	1.3644	1.2803
RMSE	2.5337	2.1740	2.0414

由表 3 可见, ATT-CNN-LSTM 模型的 MAE 分别比 LSTM 模型和 CNN-LSTM 模型减少 27% 和 6%; RMSE 分别比 LSTM 模型和 CNN-LSTM 模型减少 19% 和 6%。这是因为 ATT 可捕捉长序列中的依赖关系, 弥补了传统 LSTM 模型的不足, 因此对于长输入序列, ATT-CNN-LSTM 的预测精度相比于传统 LSTM 预测模型与 CNN-LSTM 预测模型更高, 评价指标更佳。说明了该算法具有良好的精确性。

4.4 电价跳跃点与尖峰点分析

为进一步证明本文所提预测模型在电价跳跃点与尖峰点处的优越性, 选取 33 个跳跃跨度大、突变速度快的典型电价跳跃点与尖峰点时刻进行展示。ATT-CNN-LSTM 模型、CNN-LSTM 模型与真实值拟合效果如图 7 所示。

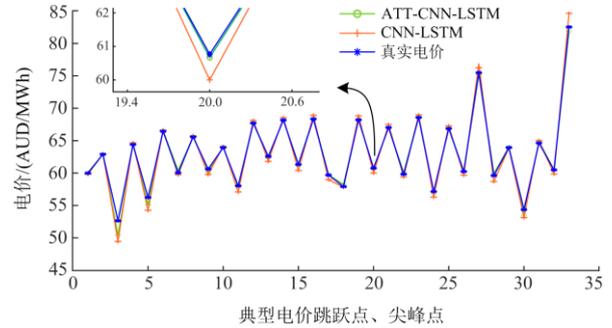


图 7 两种预测模型典型电价跳跃点、尖峰点对比图

Fig. 7 Comparison of typical electricity price jump points and peak points between the two forecasting models

由图 7 可知, 权重的大小与特征是否明显呈正相关的特性, 故 ATT 在重要特征点分配更大的权重, 使得 ATT-CNN-LSTM 模型预测结果在每一个典型电价跳跃点和尖峰点的预测电价与真实电价几乎吻合, 而 CNN-LSTM 模型预测结果在典型电价跳跃点、尖峰点处的值与真实值的偏差较大。

表 4 列出了两种算法的 MAE 与 RMSE。由表 4 可见, ATT-CNN-LSTM 预测模型在电价尖峰点和跳跃点处的 MAE 与 RMSE 分别比 CNN-LSTM 预测模型降低了 0.3032 和 0.2674。因为 ATT 在电价尖峰点与跳跃点上分配的权重更大, 故 ATT-CNN-LSTM 预测模型在电价跳跃点和尖峰点表现出良好性能。

表 4 典型电价跳跃点、尖峰点的评价指标对比

Table 4 Comparison of evaluation indicators of typical electricity price jump points and peak points

评价指标	CNN-LSTM	ATT-CNN-LSTM
MAE	0.5705	0.2673
RMSE	0.7709	0.5035

4.5 计算效率分析

为了验证本模型在计算效率方面的优势, 分别记录了 3 种预测模型预测 10 次 300 时段所需的平均时间, 如表 5 所示。

由表 5 可知, 在预测数量相同的情况下, ATT-CNN-LSTM 预测模型的平均运行时间比 CNN-LSTM 与 LSTM 模型分别减少了 0.34 s 与 0.48 s。这是因为 ATT 与 CNN 相结合后, 在提取时序数据的特征

上会更有效率,同时 ATT 的每一步计算不依赖于上一步的计算结果,可以与 CNN 一样并行处理,故 ATT-CNN-LSTM 预测模型的计算效率高于其他模型。

表 5 不同预测模型平均运行时间对比

Table 5 Comparison of the average running time of different prediction models

预测模型	平均运行时间/s
LSTM	9.04
CNN-LSTM	8.90
ATT-CNN-LSTM	8.56

5 结论

为解决传统电价预测模型在电价跳跃点和尖峰点预测精度低,同时存在计算效率低的问题,本文提出一种基于注意力机制的 CNN-LSTM 短期电价预测方法。通过澳大利亚电力市场的算例分析可得出以下结论。

ATT-CNN-LSTM 预测模型相比 CNN-LSTM 和 LSTM 预测模型,不仅能提高整体预测结果的精度,而且能提高电价跳跃点和尖峰点的预测精度,同时在计算效率上有所提升。因此,验证了本文所提模型在提高短期电价预测精度与计算效率上的有效性。

目前我国正在大力构建以新能源为主体的新型电力系统,新能源发电具有波动大的特点,给短期电价预测带来挑战。本文暂未考虑发电侧的影响,将光伏、风力等新能源发电作为短期电价预测的影响因素是下一步工作的重点。

参考文献

- [1] 武伟, 刘希玉, 杨怡, 等. 时间序列分析方法及 ARMA, GARCH 两种常用模型[J]. 计算机技术与发展, 2010, 20(1): 247-249, 253.
WU Wei, LIU Xiyu, YANG Yi, et al. Analysis method of time array and two model of ARMA and GARCH[J]. Computer Technology and Development, 2010, 20(1): 247-249, 253.
- [2] 张显, 王锡凡. 短期电价预测综述[J]. 电力系统自动化, 2006, 30(3): 92-101.
ZHANG Xian, WANG Xifan. Review of the short-term electricity price forecasting[J]. Automation of Electric Power Systems, 2006, 30(3): 92-100.
- [3] AMINI M H, KARGARIAN A, KARABASOGLU O. ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation[J]. Electric Power Systems Research, 2016, 140: 378-390.
- [4] LI Qi, CHEN Huaping, ZHU Fukang. Robust estimation for Poisson integer-valued GARCH models using a new hybrid loss[J]. Journal of Systems Science & Complexity, 2021, 34(4): 1578-1596.
- [5] 熊高峰, 韩鹏, 聂坤凯. 时间序列分解在短期电价分析与预测中的应用[J]. 电力系统及其自动化学报, 2011, 23(3): 95-100.
XIONG Gaofeng, HAN Peng, NIE Kunkai. Application of time series decomposition to short term electricity price analysis and forecasting[J]. Proceedings of the CSU-EPSA, 2011, 23(3): 95-100.
- [6] 周明, 严正, 倪以信, 等. 含误差预测校正的 ARIMA 电价预测新方法[J]. 中国电机工程学报, 2004, 24(12): 67-72.
ZHOU Ming, YAN Zheng, NI Yixin, et al. A novel ARIMA approach on electricity price forecasting with the improvement of predicted error[J]. Proceedings of the CSEE, 2004, 24(12): 67-72.
- [7] 邓佳佳, 黄元生, 宋高峰. 基于非参数 GARCH 的时间序列模型在日前电价预测中的应用[J]. 电网技术, 2012, 36(4): 190-196.
DENG Jiajia, HUANG Yuansheng, SONG Gaofeng. Day-ahead electricity price forecasting using time series model based on nonparametric generalized autoregressive conditional heteroskedasticity[J]. Power System Technology, 2012, 36(4): 190-196.
- [8] SZKUTA B R, SANABRIA L A, DILLON T S. Electricity price short-term forecasting using artificial neural networks[J]. IEEE Transactions on Power Systems, 1999, 14(3): 851-857.
- [9] 靳果, 朱清智, 孟阳, 等. 基于多层极限学习机的电能质量扰动多标签分类算法[J]. 电力系统保护与控制, 2020, 48(8): 96-105.
JIN Guo, ZHU Qingzhi, MENG Yang, et al. Power quality disturbances multi-label classification algorithm based on a multi-layer extreme learning machine[J]. Power System Protection and Control, 2020, 48(8): 96-105.
- [10] HOU K, SHAO G, WANG H, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 119-125.
- [11] 魏勤, 陈仕军, 黄炜斌, 等. 利用随机森林回归的现货市场出清价格预测方法[J]. 中国电机工程学报, 2021, 41(4): 1360-1367.
WEI Qin, CHEN Shijun, HUANG Weibin, et al. Forecasting method of clearing price in spot market by random forest regression[J]. Proceedings of the CSEE, 2021, 41(4): 1360-1367.

- [12] 谢谦, 董立红, 庠向阳. 基于 Attention-GRU 的短期电价预测[J]. 电力系统保护与控制, 2020, 48(23): 154-160.
XIE Qian, DONG Lihong, SHE Xiangyang. Short-term electricity price forecasting based on Attention-GRU[J]. Power System Protection and Control, 2020, 48(23): 154-160.
- [13] 勾玄, 肖先勇. 基于经验模式分解与 LSTM 神经网络的短期电价预测模型[J]. 西安理工大学学报, 2020, 36(1): 129-134.
GOU Xuan, XIAO Xianyong. Short-term electricity price forecasting model based on empirical mode decomposition and LSTM neural network[J]. Journal of Xi'an University of Technology, 2020, 36(1): 129-134.
- [14] 韩升科, 胡飞虎, 陈之腾. 基于 GCN-LSTM 的日前市场边际电价预测[J]. 中国电机工程学报, 2021, 41(6): 1-12.
HAN Shengke, HU Feihu, CHEN Zhiteng. Day ahead market marginal price forecasting based on GCN-LSTM[J]. Proceedings of the CSEE, 2021, 41(6): 1-12.
- [15] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.
- [16] LI W, BECKER D M. Day-ahead electricity price prediction applying hybrid models of LSTM-based deep learning methods and feature selection algorithms under consideration of market coupling[J]. Energy, 2021, 237.
- [17] 李明扬, 孔芳. 融入自注意力机制的社交媒体命名实体识别[J]. 清华大学学报(自然科学版), 2019, 59(6): 461-467.
LI Mingyang, KONG Fang. Social media named entity recognition incorporating self-attention mechanisms[J]. Journal of Tsinghua University (Science and Technology), 2019, 59(6): 461-467.
- [18] 王维博, 张斌, 曾文入, 等. 基于特征融合一维卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(6): 53-60.
WANG Weibo, ZHANG Bin, ZENG Wenru, et al. Power quality disturbance classification of one-dimensional convolutional neural networks based on feature fusion[J]. Power System Protection and Control, 2020, 48(6): 53-60.
- [19] TENG Hui, HASSAN A S. Construction and drug evaluation based on convolutional neural network system optimized by grey correlation analysis[J]. Computational Intelligence and Neuroscience, 2021: 1-9.
- [20] 刘忠, 陈星宇, 邹淑云, 等. 计及碳排放的风-光-抽水蓄能系统容量优化配置方法[J]. 电力系统自动化, 2021, 45(22): 9-18.
LIU Zhong, CHEN Xingyu, ZOU Shuyun, et al. Optimal capacity configuration method for wind-photovoltaic-pumped-storage system considering carbon emission[J]. Automation of Electric Power Systems, 2021, 45(22): 9-18.
- [21] 梁涛, 杨改文, 董玉兰. 基于灰色关联度的变权组合模型的齿轮箱温度故障预测[J]. 太阳能学报, 2020, 41(12): 199-207.
LIANG Tao, YANG Gaiwen, DONG Yulan. Gearbox temperature fault prediction based on variable weight combination model based on gray correlation[J]. Acta Energetica Solaris Sinica, 2020, 41(12): 199-207.
- [22] 王浩, 王艳, 纪志成. 基于 SAIGM-KELM 的短期风电功率预测[J]. 电力系统保护与控制, 2020, 48(18): 78-87.
WANG Hao, WANG Yan, JI Zhicheng. Short-term wind power forecasting based on SAIGM-KELM[J]. Power System Protection and Control, 2020, 48(18): 78-87.
- [23] CHANG Zihan, ZHANG Yang, CHEN Wenbo. Electricity price prediction based on hybrid model of Adam optimized LSTM neural network and wavelet transform[J]. Energy, 2019, 187.
- [24] RODRIGEZ C, ANDERS G. Energy price forecasting in the Ontario competitive power system market[J]. IEEE Transactions on Power Systems, 2004, 19(1): 366-374.
- [25] 李军徽, 冯喜超, 严干贵, 等. 高风电渗透率下的电力系统调频研究综述[J]. 电力系统保护与控制, 2018, 46(2): 163-170.
LI Junhui, FENG Xichao, YAN Gangui, et al. Survey on frequency regulation technology in high wind penetration power system[J]. Power System Protection and Control, 2018, 46(2): 163-170.
- [26] HU A S, LIE T T, GOOI H B. Load forecast for customers under real time pricing systems[C] // International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, April 4-7, 2000, London, UK: 538-543.

收稿日期: 2021-11-01; 修回日期: 2022-04-18

作者简介:

吉兴全(1970—), 男, 博士, 教授, 研究方向为配电网优化、状态估计和故障诊断; E-mail: xqji@sdust.edu.cn

曾若梅(1997—), 女, 硕士研究生, 研究方向为智能算法在电力系统中的应用; E-mail: suzulin@163.com

张玉敏(1986—), 女, 通信作者, 博士, 讲师, 研究方向为电力系统经济运行、优化调度和电力市场。E-mail: zhangyumin@mail.sdu.cn

(编辑 许威)