基于等级相关性与注意机制的短期电价预测

刘 川

（南京南自华盾数字技术有限公司，江苏 南京 210000）

摘 要 短期电价受负荷及历史电价等多重因素影响，波动性强且尖峰频发，准确预测对电力市场主体的报价决策具有重要意义。针对现有研究在模型输入选取上多依赖经验，容易采纳与电价相关性较弱的历史数据，进而影响预测精度的问题，本文提出一种基于Spearman等级相关性算法与注意力机制的长短期记忆网络（ATT-LSTM）短期电价预测网络。首先，采用Spearman等级相关分析历史负荷、历史电价与目标电价之间的相关性，筛选出相关程度较高的滞后特征作为模型输入。然后构建ATT-LSTM网络，利用注意力机制自适应分配不同输入特征对预测结果的贡献权重，提升模型在电价尖峰与跳跃点的拟合能力。基于澳大利亚电力市场实测数据的算例结果表明，该网络在平均绝对误差与均方根误差上均优于对比模型，验证了所提特征筛选策略与预测模型的有效性。

关键词 短期电价预测；特征筛选；注意力机制；长短期记忆网络

中图分类号：TM73；F426.61 **文献标志码**：A DOI：10.3969/j.issn.2097-3365.2026.30.022

0 引言

随着我国电力体制改革的深入推进，电力现货市场建设不断加快，电价作为电力市场的核心信号，其波动直接影响发电企业的报价收益、售电公司的经营策略与电力用户的用电成本[1]。新能源大规模并网进一步加剧了电价的不确定性，准确进行短期电价预测对市场各方规避交易风险、优化资源配置具有重要意义[2]。电价受供需关系、负荷、新能源出力等因素作用，呈强波动、强非线性特征，常伴尖峰跳跃，预测难度大[3]。负荷与电价密切相关，合理利用负荷与历史电价信息是提高预测精度的关键。现有预测方法分传统时间序列与人工智能两类。以自回归差分移动平均模型（AutoRegressive Integrated Moving Average，ARIMA）为代表的传统方法基于线性假设，难以刻画电价的非线性与突变特征[4]。以支持向量回归（Support Vector Regression，SVR）为代表的机器学习方法特征提取依赖人工经验，表达能力有限[5]。近年来，卷积神经网络（Convolutional Neural Network，CNN）、长短期记忆网络（Long Short-Term Memory，LSTM）等深度学习模型被广泛用于电价预测[6]。然而，现有研究在提升模型结构的同时，对输入特征的选取关注不足。模型输入通常包含多日多时刻的历史负荷与电价数据，不同输入变量与目标电价的相关程度差异较大，若不加以区分地全部输入，不仅增加计算负担，还可能引入与电价相关性较弱的信息，制约预测精度的提升[7]。因此，本文提出基于斯皮尔曼等级相关分析与注意力机制的长短期记忆网络（ATT-LSTM）预测方法，先筛选相关性较高的滞后特征作为输入，再以注意力机制突出关键时点信息，最后基于澳大利亚电力市场实测数据验证所提方法的有效性。

1 基于Spearman等级相关的特征筛选

输入特征的选取直接影响预测精度。历史负荷、历史电价与预测时刻电价的相关程度随滞后时间远近而不同，不加区分地全部输入易引入冗余。为此，采用斯皮尔曼等级相关筛选特征，该方法先将数值转为秩次再求相关，对尖峰等极端值不敏感，结果更稳健。设某候选变量观测序列为 $\{x_1, x_2, \cdots, x_n\}$，预测时刻电价序列为 $\{y_1, y_2, \cdots, y_n\}$，二者对应的秩次序列分别为 $\{R_i\}$、$\{S_i\}$，则斯皮尔曼相关系数 ρ_k 为：

$$\rho_k=\frac{\sum_{i=1}^{n}(R_i-R^-)\cdot(S_i-S^-)}{\sqrt{\sum_{i=1}^{n}(R_i-R^-)^2\cdot\sum_{i=1}^{n}(S_i-S^-)^2}} \quad (1)$$

式（1）中：R^-、S^- 分别为两组秩次的均值，n 为样本数。$\rho_k\in[-1, 1]$，其绝对值越接近1，表明该候选变量与预测时刻电价的相关性越强。

设预测时刻为t，目标变量为该时刻电价 Y_t。考虑到预测时 Y_t 对应的实时负荷尚未发生，候选输入仅取滞后变量，构成候选集：

$$C=\{Y_{t-1}, \cdots, Y_{t-48}, Y_{t-96}; L_{t-1}, \cdots, L_{t-48},\} \quad (2)$$

式（2）中：Y_{t-k}、L_{t-k} 分别为滞后k个采样时刻的历史电价与历史负荷。数据采样间隔为30 min，一天含

作者简介：刘川（1987-），男，本科，工程师，研究方向：电力信息化。

48 个时刻，故滞后 48、96 对应前一日、前两日同一时刻，用于刻画电价与负荷的日周期性。滞后 1、2 等邻近时刻用于刻画电价走势的短期惯性。

分别计算候选集中各变量与 Y_t 的相关系数 ρ_k，并检验其显著性，构造统计量：

$$t=\frac{\rho_k\sqrt{n-2}}{\sqrt{1-\rho_k^2}} \tag{3}$$

在原假设该候选变量与 Y_t 不相关成立时，t 近似服从自由度为 n-2 的 t 分布。综合 ρ_k 大小与显著性检验结果，按以下规则筛选输入特征：（1）对于历史负荷变量，模型输入选取相关系数较高、且随滞后时间缩短而逐渐增强的邻近时刻负荷（前 1 ～ 3 个时刻，即 L_{t-1}、L_{t-2}、L_{t-3}），其直接反映预测时刻前的用电需求态势。（2）对于历史电价变量，则选取相关性强且具日周期含义的滞后电价（L_{t-1}、Y_{t-48}、Y_{t-96}），剔除与预测时刻间隔过远、相关性弱且易引入冗余的变量。

2 基于注意力机制的 LSTM 预测模型

将筛选得到的滞后电价与负荷特征作为预测模型的输入。为充分挖掘其中的时序信息，构建基于注意力机制的长短期记忆网络（ATT-LSTM）预测模型，其结构由输入层、LSTM 层、注意力层与全连接层构成。输入层接收筛选得到的滞后电价与负荷特征序列。LSTM 层沿时间方向依次读取输入，输出各时刻的隐状态。注意力层对各时刻隐状态加权求和，突出对预测未来电价更为关键的历史时刻。全连接层将加权求和得到的上下文向量映射为预测电价。LSTM 通过引入门控机制，有选择地保留与遗忘历史信息，有效缓解传统循环网络在处理长序列时的梯度消失问题。其记忆单元由遗忘门、输入门、候选门与输出门构成。设 t 时刻的输入为 x_t，上一时刻隐状态为 h_{t-1}，则各门控输出及单元状态更新为：

$$f_t=\sigma(W_f\cdot[h_{t-1};x_t]+b_f) \tag{4}$$

$$i_t=\sigma(W_i\cdot[h_{t-1};x_t]+b_i) \tag{5}$$

$$o_t=\sigma(W_o\cdot[h_{t-1};x_t]+b_o) \tag{6}$$

$$g_t=tanh(W_c\cdot[h_{t-1};x_t]+b_c) \tag{7}$$

$$c_t=f_t\odot c_{t-1}+i_t\odot g_t \tag{8}$$

$$h_t=o_t\odot tanh(c_t) \tag{9}$$

式（4）～（9）中：σ 为 sigmoid 激活函数，tanh 为双曲正切激活函数，W_f、W_i、W_o、W_c 与 b_f、b_i、b_o、b_c 分别为各门的权重矩阵与偏置，表示逐元素相乘。$\odot$ 为候选单元状态，c_t 为 t 时刻的单元状态，h_t 为 t 时刻的隐状态。由于电价序列常在平稳段与尖峰、跳跃段之间快速切换，门控机制使模型能够在电价发生突变时及时遗忘旧的运行状态、写入新的价格信息，从而更好地捕捉电价状态的动态变化。

对于 LSTM 输出的隐状态序列 $\{h_1,h_2,\cdots,h_T\}$，不同历史时刻对预测未来电价的重要程度并不相同：邻近时刻反映了电价的短期惯性，前一日相同时刻的隐状态蕴含着日周期信息，尖峰、跳跃点附近的状态则包含了电价剧烈波动的关键特征。为充分利用这些信息，引入注意力机制对各时刻隐状态自适应加权。

$$e_t=v_a^{\mathrm{T}}tanh(W_a\cdot h_t+b_a) \tag{10}$$

$$a_t=\frac{exp(e_t)}{\sum_{j=1}^{T}exp(e_j)} \tag{11}$$

$$c=\sum_{j=1}^{T}a_t\cdot h_t \tag{12}$$

式（10）中：v_a^{T} 是可学习参数，e_t 为 t 时刻隐状态的注意力得分，a_t 为经 softmax 归一化后的注意力权重，满足 $\sum a_t=1$，c 为加权求和得到的上下文向量。注意力权重越大，表明该时刻的历史状态对预测电价越重要，模型据此将有限的计算资源集中于关键历史时刻，有助于提升在电价尖峰与跳跃点处的预测精度。

3 算例分析

3.1 数据集与预处理

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[8]。由于电价与负荷量纲不同、数值差异较大，建模前对二者分别进行归一化处理，将其映射到 [-1,1] 区间，预测完成后对输出结果反归一化，还原为实际电价。

价格跳跃与价格尖峰是电价序列的典型特征。实际电力市场中，非正常价格跳跃、零电价以及价格尖峰时有发生。尤其在高风电渗透率、电源结构复杂的澳大利亚市场，电价曲线中的价格尖峰更为密集[9]。由于价格跳跃的发生时间和幅度难以被现有方法准确预测[10]，这类特性构成了电价预测的主要难点之一。为验证该模型在跳跃点和尖峰点上的预测表现，以波动率较高、价格尖峰较多的澳大利亚市场实测数据开展算例分析。

3.2 相关性分析结果

按照第 1 节方法，分别计算各候选滞后变量与预测时刻电价之间的斯皮尔曼相关系数，结果如表 1 所示。表 1 中，Y_{t-k}、L_{t-k} 分别表示滞后 k 个采样时刻的历史电价与历史负荷。由表 1 可见：负荷与电价的相关系数随滞后时间缩短而逐渐增大，邻近的 L_{t-1} ～ L_{t-3} 与预测时刻电价的相关性均维持在 0.8 以上，表明近期用电需求态势对电价具有较强影响。电价自相关在 Y_{t-1} 处最强，且 Y_{t-48}、Y_{t-96} 仍保持较高水平，体现出明显的日周

期特征。滞后较远的变量相关系数则明显下降。因此，以预测时刻当天前3个时刻的负荷量、当天前1个时刻的电价以及前一日、前两日同一时刻的历史电价作为ATT-LSTM模型的输入特征集。

表1 候选输入变量与预测时刻电价的相关系数

输入变量	相关系数	输入变量	相关系数
L_{t-1}	0.826	Y_{t-1}	0.991
L_{t-2}	0.819	Y_{t-2}	0.985
L_{t-3}	0.807	Y_{t-3}	0.972
L_{t-4}	0.774	Y_{t-48}	0.921
L_{t-48}	0.741	Y_{t-96}	0.873
L_{t-96}	0.695	Y_{t-336}	0.812

3.3 评估指标

为定量评价模型的预测精度，选取平均绝对误差（MAE）与均方根误差（RMSE）作为评价指标。设测试集共n个时段，y_i为第i个时段的电价真实值，y_i'为对应的模型预测值，则二者的计算式为：

$$MAE=(1/n)\sum_{i=1}^{n}\left|y_i-y_i'\right| \quad (13)$$

$$RMSE=\sqrt{(1/n)\sum_{i=1}^{n}(y_i-y_i')^2} \quad (14)$$

式（13）、（14）中MAE反映预测误差的平均水平，RMSE对较大误差更为敏感，能够突出反映电价大幅波动时段的预测偏差。

3.4 预测结果对比

为验证本文所提网络的有效性，将ATT-LSTM与LSTM、CNN-LSTM两种模型在相同的训练集与测试集上进行对比实验，采用平均绝对误差（MAE）与均方根误差（RMSE）作为评价指标，结果如表2所示。由表2可知，ATT-LSTM模型的MAE与RMSE分别为1.2085和1.9893，均低于LSTM与CNN-LSTM两种模型，其中MAE较LSTM降低31.3%、较CNN-LSTM降低10.5%，RMSE较LSTM降低21.1%、较CNN-LSTM降低7.9%，表明该模型的预测精度优于对比模型。

表2 不同运行模式的成本

评估指标	MAE	RMSE
LSTM	1.7586	2.5217
CNN-LSTM	1.3498	2.1604
ATT-LSTM	1.2085	1.9893

ATT-LSTM预测精度的提升，主要源于特征筛选与注意力机制两方面的共同作用。一方面，通过Spearman等级相关筛选，保留了与预测时刻电价相关性较强的滞后特征，剔除了相关性较弱的变量，使模型能够聚焦有效信息，降低了冗余对预测精度的不利影响；另一方面，即使输入特征已经过筛选，各历史时刻对预测的重要程度仍不相同：LSTM对各时刻隐状态不加区分地统一处理，难以突出关键信息，而ATT-LSTM通过注意力机制为不同时刻自适应分配权重，使其在预测时更关注贡献较大的历史时刻，尤其在电价尖峰与跳跃处能够获得更充分的信息支持，从而进一步提升了整体预测精度。

4 结论

针对电价预测输入特征选取易引入冗余的问题，本文提出基于Spearman等级相关与ATT-LSTM的短期电价预测网络，先筛选相关性强且具日周期意义的滞后特征，再以注意力突出关键历史时刻。二者结合能够使模型更准确地刻画电价的波动特征。澳大利亚市场算例表明，该网络误差低于LSTM与CNN-LSTM，验证了特征筛选策略与预测模型的有效性。

参考文献：

[1] 勾玄.基于机器学习电价预测的发电企业报价策略研究[D].成都：四川大学,2021.
[2] 郑志勇,陈田原,胡哲,等.短期电价预测的机器学习方法：现状、挑战与展望[J].河南科学,2025,43(01):90-98.
[3] 刘雪娟.混合机器学习算法在电价预测中的研究与应用[D].兰州：西北师范大学,2024.
[4] 龙飞,张峥毅.基于CEEMDAN分解重构去噪和小波变换卷积-iTransformer的短期负荷预测[J/OL].电子测量技术,1-12[2026-09-05][2026-09-08].https://kns.cnki.net/kcms2/article/abstract?v=qnK7kQe7qCAkz_TtA72ggPGxQQFU_TYVBtrmXPIM5An0o1s00Kdv-YXTZxlLzncni_hIbOcVpEHo_BFVlFbxWZF1rklHKX0JeeTnLi_OUjlNxkCLymaPvuvhjmqZdp_L9OZaJ-pc3tZaewPwVyJSNXCZTwFvrsD12Mp6RZj-1b7MOHjFIfALhQ==.
[5] 何勇琪,戴扬宇,王俊,等.基于模态分解与机器学习的电力市场出清价格预测[J/OL].现代电力,1-16[2026-09-01][2026-09-08].https://kns.cnki.net/kcms2/article/abstract?v=qnK7kQe7qCCMHRX_3fyMsQa-5U8jyMd37pKdOP1CxlYCBVLP4wIKo8V6Uj0TW2MyshA1S5sbVGbnUaslDRZ6rkn5xG-KrMdJ0svOKMDYKlZ1igTXXHznaLjWW2sQ1vBKjFHe4CfL51wgcGDrVynljG6j2mxQnrK8aLxxiNYxKgXBUjBODbiaMg==.
[6] 顾慧杰,周华锋,彭超逸,等.基于CEEMDAN-BERT-LSTM的现货市场电力价格预测[J].电力需求侧管理,2025,27(05):112-117.
[7] 吉兴全,曾若梅,张玉敏,等.基于注意力机制的CNN-LSTM短期电价预测[J].电力系统保护与控制,2022,50(17):125-132.
[8] 曾若梅.基于神经网络的短期电价预测[D].青岛：山东科技大学,2023.
[9] 韩啸.居民用电负荷波动下含机械加工设备区域的市场电价动态预测[J].模具制造,2026,26(06):232-234.
[10] 王开舒.基于分解-重构框架的电价预测研究[D].武汉：华中科技大学,2025.