

DOI:10.13718/j.cnki.xsxb.2021.05.023

用于智能电网电价预测的深度学习模型^①

缪俞蓉¹, 陈森博²

1. 江苏商贸职业学院 教务处, 江苏 南通 226011; 2. 南通大学 信息科学技术学院, 江苏 南通 226019

摘要: 针对机器学习方法在大型数据集上电价预测准确性低等问题, 本文提出一种基于大数据时间序列的深度学习电价预测模型, 用于智能电网的电价预测。该模型首先将收集到的数据进行预处理规范化, 采用 ReliefF 算法和互信息(Mutual Information, MI)的混合模块进行特征选择, 其次将改进后的特征赋予核主成分分析(Kernel Principal Component Analysis, KPCA)进行特征提取, 最后采用增强卷积神经网络(Enhanced Convolution Neural Network, ECNN)对电价进行有效的预测。实验结果表明: 与现有的基准方案相比, 本文所提出的模型能够更好地预测智能电网电价, 有助于智能电网更好地运行和规划发电。

关 键 词: 智能电网电价预测; 大数据; 互信息; 核主成分分析; 增强卷积神经网络

中图分类号: TP393

文献标志码: A

文章编号: 1000-5471(2021)05-0153-06

在传统电网中大部分电能在发电、输电和配电过程中被浪费, 因此引入智能电网来解决该问题。智能电网就是电网的智能化, 它以集成、高速双向通信网络为基础^[1-2], 通过先进的传感和测量技术、设备技术、控制方法以及先进的决策支持系统技术的应用, 实现电网可靠、安全、经济、高效、环境友好和使用安全的目标^[3-4]。智能电网的核心内涵是实现电网的信息化、数字化和自动化^[5], 在电力负荷和电价预测方面的数据科学研究在平衡供需、规划发电高效运行方面发挥了重要作用。智能电网根据消费者的要求提供响应, 从而满足消费者的所有要求, 因此会收集大量有关消费者电力消耗的数据^[6]。

智能电网的出现催生了众多智能分布式能源的开发, 例如电池存储、可调负载和具有双向充电功能的电动汽车^[7-8]。随着可再生能源资源的发展和分布式能源的引入以及负荷时间序列的不确定性, 有必要预测准确的价格, 以便进行可靠的有效发电并降低智能电网的电力损耗, 从而进行有效的发电调度和用电规划。然而, 在精确的电价预测中, 仍然存在计算成本高、可靠性差和执行时间长等问题。

为了解决上述问题, 文献[9]提出一种基于深度学习的预测日间用电负荷的模型, 该模型首先利用历史用电负荷数据和相关温度参数, 通过堆叠去噪自动编码器(Stacked Denoising Auto encoder, SDA)来进行特征提取, 然后训练支持向量回归(Support Vector Regression, SVR)模型来预测用电。但是要训练自动编码器需要大量的数据处理时间和参数超调。文献[10]提出一种基于经验小波变换、支持向量回归(SVR)和贝叶斯优化的混合电价预测模型, 该模型利用小波变换作为处理工具将原始信号分解成特定的模态分量, 然后采用 SVR 和双向长短期记忆作为非线性子序列预测的基本框架, 利用贝叶斯来调整参数优化模型性能。文献[11]提出一种基于混合结构深神经网络的电价预测模型, 该模型将卷积神经网络(Convolutional Neural Network, CNN)和长短期记忆(Long and Short Term Memory, LSTM)相结合来预测未来的电价。模型在 CNN 包含 2 个一维卷积层, 为了提高训练效率, 在第 2 个卷积层后加入批处理规范化; LSTM 分析 CNN 提取的特征, 并估计下一时间点的电价, 实现了更好的预测性能。

① 收稿日期: 2020-07-08

基金项目: 2018 年度江苏省高等学校自然科学研究面上项目(18KJB520015).

作者简介: 缪俞蓉, 硕士, 高级管理师, 主要从事数据挖掘及大数据技术研究.

然而,上述文献存在一定的局限性,需要在避免过度拟合的同时,提高电价预测的性能。为了克服这些局限性,本文提出一种智能电网中基于大数据时间序列的深度学习电价预测模型。为了提高分类器的性能,本文使用ReliefF算法和互信息(Mutual Information, MI)进行混合特征选择,降低了特征选择的复杂度和执行时间。为了避免特征冗余,执行核主成分分析(Kernel Principal Component Analysis, KPCA)提取特征,克服了过度拟合问题。然后,将有效特征输入到增强卷积神经网络(Enhanced Convolution Neural Network, ECNN)模型进行有效的价格预测。

1 基于深度学习的电价预测模型

该价格预测模型分解为5个步骤:①数据规范化预处理,②用于特征选择的互信息(MI)和ReliefF技术的混合模块,③核心主成分分析(KPCA)特征提取方法,④使用网格搜索进行超参数调整,⑤使用增强卷积神经网络(ECNN)进行电价预测。

1.1 数据规范化

为了获得通用规模的数据,将收集到的数据进行规范化预处理。在数据预处理阶段,需要执行数据清理和数据规范化两个步骤。数据清理用于从数据集中删除空的、未定义的和不相关的特征。数据规范化用于将数据缩放到0~1范围内。本文使用式(1)给出的归一化公式对数据进行归一化。

$$A' = \frac{A - \min(A)}{\max(A) - \min(A)} \quad (1)$$

式(1)中 A' 是数据序列的归一化分量。

1.2 混合特征选择

特征选择是用于选择更多相关特征的过程,它减少了数据集中的要素数量,并且数据分类、预测的准确性取决于输入特征,因此有必要将相关信息提供给分类器。本文采用由MI和ReliefF组成的混合模型对特征进行选择。

ReliefF是Relief的增强版本,广泛用于数据科学中的特征选择。ReliefF为每个特征赋予一个表征特征与类别相关性的权重,并根据权值进行特征选择。对于训练样本集合中的样本 R ,分别从样本 R 的同类和不同类样本集中找出 k 个近邻样本,然后随机选取多个样本更新特征权重,根据权重排名并选取有效特征。权重更新公式为

$$W = W[A] - \frac{\sum_{j=1}^k diff(A, R_i, H_j)}{m * k} + \frac{\sum_{C \neq class(R_i)} \frac{P(C)}{1 - P(class(R_i))} diff(A, R_i, M_j)}{m * k} \quad (2)$$

$$diff = \begin{cases} 0 & (\text{离散属性, 值不同}) \\ 1 & (\text{离散属性, 值相同}) \\ \text{归一化区间}[0, 1] \text{ 的实际差分} & (\text{连续属性}) \end{cases} \quad (3)$$

式(2)中 A 表示电价数据特征, R_i 表示样本点, $diff(A, R_i, H_j)$ 表示样本 R_i 和样本 H_j 在特征 A 上的差值, H_j 表示与 R_i 同类的 k 个最近邻样本, M_j 表示与 R_i 不同类的 k 个最近邻样本, m 表示时间序列的长度, $P(C)$ 表示第 C 类样本的概率,不同类样本的贡献使用其类 $P(C)$ 的先验概率加权,并将样本概率除以因子 $1 - P(class(R_i))$,保证不同类样本的概率权重总和为1。函数 $diff(A, B_1, B_2)$ 计算属性 A 中 B_1 和 B_2 之间的差。

W^F 可以归一化为

$$W^F = W^F / \max(W^F) \quad (4)$$

T_k 为特征值,如果在称为未命中的类中最近邻处观察到特征值差异,则特征值减小并获得较小的特征重要度值。如果在不同的类(称为“命中”)中的最近邻处观测到特征值差异,则特征值会增大并获得较高的重要度值。

MI计算两个随机变量 x 和 y 之间的关系,并测量通信的信息量。如果两个随机变量之间的信息为零,则表示它们相互独立并且信息增益为零。信息增益(information gain, IG)具体计算方式为

$$IG(H(f_i) - H(f_i | C)) \quad (5)$$

$$H(f_i) = - \sum_j p(x_j) \log_2 p(x_j) \quad (6)$$

$$H(f_i | C) = - \sum_j p(x_j | c_k) \log_2 (p(x_j | c_k)) \quad (7)$$

式(5)、式(6)、式(7)中 $H(f_i)$ 表示索引 i 特征的熵, $H(f_i | C)$ 表示 C 类索引 i 特征的熵, $p(x_j)$ 表示变量 x 的概率, $p(x | c)$ 表示在 c 条件下 x 的概率. 本文将阈值设为 0.1, 任何互信息增益大于 0.1 的特征值都被选择, 否则被拒绝.

计算 ReliefF 和 MI 组合的重要性, 进行最终特征选择. 阈值选择为 0.5, 拒绝重要性值小于 0.5 的任何特征值, 并选择重要性值大于 0.5 的特征值.

1.3 使用 KPCA 提取特征

为了消除特征中的冗余信息, 执行 KPCA 从已选择的特征中提取主成分. 主成分分析(PCA)是最常用的特征提取方法, 可以减少特征之间的冗余, 但它假设从高维到低维空间呈线性映射. 然而, 电价预测中的数据需要非线性映射才能找到合适的低维嵌入. 本文利用核主成分分析(KPCA)进行特征提取, 避免从所选特征中提取不相关的信息, 较好地利用了从高维到低维的复杂结构特点.

图 1 给出了不同核数的径向基 KPCA、线性 KPCA 和 PCA 之间的累积贡献率比较. 在进行主成分分析时, 得到的方差百分比称为贡献率, 累积百分比称为累积贡献率. 当累积贡献率达到 95% 时, 径向基 KPCA 能够有效地提取重要的主成分, 如图 2 所示. 因此, 本文选择径向基函数作为 KPCA 的核心, 以保证预测的准确性. 径向基 KPCA 的数据点沿坐标轴分布, 即径向基 KPCA 可以提取比其他两个内核更具代表性的主成分.

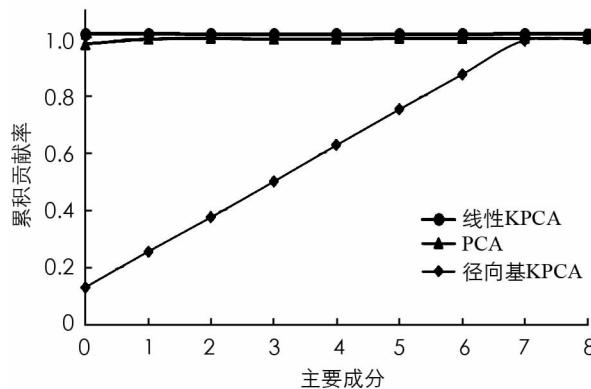


图 1 PCA、线性 KPCA 和径向基 KPCA 的性能分析

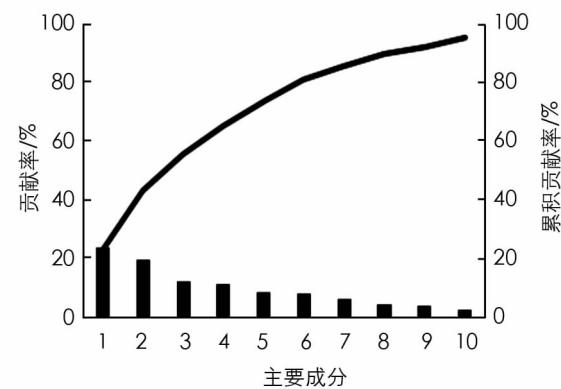


图 2 径向基 KPCA 的累计贡献率

1.4 超参数调整

分类器的调整对于准确有效地进行预测非常重要. 超参数与分类器结果有很强的相关性. 网格搜索(Grid search, GS)是用来调整参数进行优化的传统方法, 用于调整分类器参数获得较高的精度. 本文定义 ECNN 的参数子集如表 1 所示, 在此基础上通过执行 GS 寻找具有较少损失函数的参数值, GS 的结果使用 k 倍交叉验证方法进行验证.

表 1 GS 的 ECNN 参数子集

参数名称	参数值
批量大小定义样本数量	[10, 20, 40, 50, 60]
迭代次数	[10, 30, 50, 70, 100, 150]
learning_rate	[0.001, 0.01, 0.1, 0.2, 0.3]
激活函数	[softmax, relu, sigmoid, linear]
优化程序	[SGD, Adam, Adamax, Nadam]
dropout_rate	[0.0, 0.1, 0.2, 0.3, 0.4, 0.5]

1.5 使用 ECNN 进行电价预测

经过特征选择和参数调整后, 利用处理后的数据, 本文使用增强卷积神经网络 ECNN 完成最终的电价预测.

ECNN 是一个监督的深度学习模型, 其工作流程如图 3 所示. 首先, 数据采用归一化形式, 将选择和提取后的预处理数据引入到输入层, 然后使用卷积层来应用滤波器, 并将大输入卷积为小矩阵, 其中包含过滤器并执行特征映射功能, 以检查连接到输入的输出神经元. 卷积层的输入为 $m \times r$, 其中 m 是矩阵的高度, r 是矩阵的宽度. 卷积层获取输入图像并通过计算权重和偏差来学习. 激活功能为 Relu, 计算公式为

$$\text{Relu}(x) = \max(0, x) \quad (8)$$

式(8) 中 x 为输入特征. 如果 x 为非负, 则该函数返回实际值; 如果 x 为负值, Relu 返回零.

第 3 层为最大池化层, 它收集每个矩阵的最大值, 然后根据这些值创建一个小矩阵. 最大池化层结合神经元的输出由于参数数量较少而减少了计算开销. 表 2 给出了计算卷积层输出尺寸的公式.

表 2 卷积层的输出计算

输入	滤波	输出
$n \times n$	$f \times f$	$(n + 2pf + 1)^2$

表 2 中 p 是填充值, f 是过滤器的数量, n 是输入大小.

第 4 层为 Dropout 层, 避免过度拟合问题. 第 5 层为 Flatten 层, 用于将所有神经元转换成一个连接层. 完全连接层中每个神经元接收前一层所有神经元的输入, 将前一层所有的局部特征通过权重矩阵 W 重新连接起来. Dropout 用来发现从一层到另一层的连接过程中神经元的丢失率. 如果丢失率值大于阈值, 它将回到完全连接层并尝试将最大节点彼此连接, 如果神经元的损失率值小于阈值, 它将进一步移动到 Dropout 层, 以防止网络中的过度拟合问题, 然后再次应用完全连接层将所有节点彼此连接, 最后由输出层输出预测结果.

2 实验结果与分析

为了研究本文提出模型的性能, 使用 Python 来实现该模型. 本文模型在一台配置为 Intel Core i5、4 GB RAM 和 500 G 硬盘的平台上实现. 使用江苏省电网运行数据对电价进行预测, 将测试结果与基准方案 LSTM 和 CNN-LSTM^[11] 进行比对分析.

为了评价本文算法的性能, 采用平均绝对百分比误差(Mean Absolute Percentage Error, MAPE) 和预测精度(Prediction Accuracy, PA) 作为误差评价指标, 定义为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left(\frac{|v_{pi} - v_{ai}|}{v_{ai}} \right) \quad (9)$$

$$\text{PA} = \left(1 - \frac{|v_{pi} - v_{ai}|}{v_{ai}} \right) \times 100\% \quad (10)$$

式(9)、式(10) 中 N 为预测总次数, v_{pi} 和 v_{ai} 分别为第 i 时刻的电价预测值和实际值.

图 4 给出了使用 MI 和 ReliefF 混合特征选择技术进行特征选择的所有特性的重要性. 特征的重要性

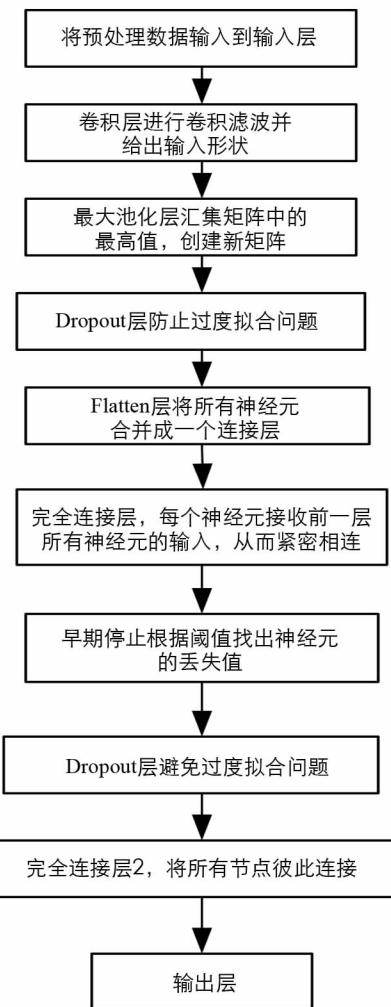


图 3 ECNN 的具体流程图

反映了不同特征与目标类之间的相关性, 它给出了从大型数据集中选择的最佳特征, 而且某些特征的重要性较高, 而另一些特征的重要性相对较低。对于仿真, 阈值为 0.08, 用于选择最相关的特征。

图 5 给出了本文模型的一周电价预测。在图 5 中, 实线表示一周的实际电价, 虚线表示一周的预测电价。从图 5 可以看出预测曲线较平滑, 实际电价和预测电价趋势基本吻合, 表明本文模型能够较好地进行电价预测。

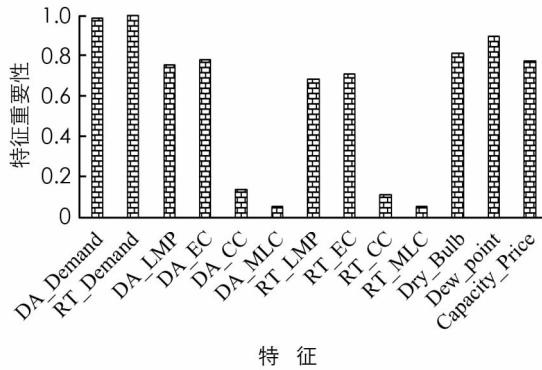


图 4 特征重要性

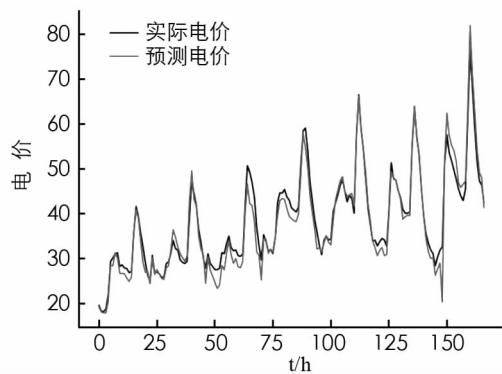


图 5 一周预测电价和实际电价曲线

表 3 给出了本文模型的测试结果与基准方案 LSTM 和 CNN-LSTM^[14] 的预测性能结果。从表 3 可以看出, 3 种算法模型对实际电价均有较好的结果, 本文算法、LSTM 和 CNN-LSTM 的 MAPE 分别为 1.45, 1.94 和 1.49, MAPE 越小表示实际预测误差越小。本文算法、LSTM 和 CNN-LSTM 的 PA 分别为 0.991 2, 0.980 6 和 0.988 9, PA 值介于 0~1 之间, 其值越接近 1 表示预测性能越好。因此, 本文算法的预测性能优于所对比的算法。这是因为本文模型使用 KPCA 提取特征克服了过度拟合问题, 并使用 ECNN 进行了智能电网电价预测。

表 3 本文算法与基准方案的预测性能比较

方法	LSTM	CNN-LSTM	本文算法
MAPE	1.94	1.49	1.45
PA	0.980 6	0.988 9	0.991 2

3 结语

本文提出一种大数据环境下的时间序列深度学习电价预测模型, 解决过度拟合和精度等问题。实现结果表明, 与现有的基准方案相比, 本文提出的模型具有更好的性能, 有助于智能电网更好地运行和规划发电。本文的主要贡献是: ①降低了特征选择的复杂度和执行时间, 减少了计算时间, 提高了框架的性能。②克服了过度拟合的问题, 提高了预测模型的精度和性能。③该框架通过 ECNN 预测价格, 在复杂数据集上表现得更好, 而 ECNN 在大核函数时间序列数据上表现得更好。

未来的工作是将本文模型结合更多的外部特性, 增加系统的存储容量, 从而进一步提高模型的性能。

参考文献:

- PENG L, LIU S, LIU R, et al. Effective Long Short-Term Memory with Differential Evolution Algorithm for Electricity Price Prediction [J]. Energy, 2018, 162: 1301-1314.
- GHADIMI N, AKBARIMAJD A, SHAYEGHI H, et al. A New Prediction Model Based on Multi-Block Forecast Engine in Smart Grid [J]. Journal of Ambient Intelligence and Humanized Computing, 2018, 9(6): 1873-1888.
- MUJEEB S, JAVAID N, AKBAR M, et al. Big Data Analytics for Price and Load Forecasting in Smart Grids [C]//Advances on Broadband and Wireless Computing, Communication and Applications. Taichung: Spring Cham, 2019.
- ZAHID M, AHMED F, JAVAID N, et al. Electricity Price and Load Forecasting Using Enhanced Convolutional Neural Network and Enhanced Support Vector Regression in Smart Grids [J]. Electronics, 2019, 8(2): 122-153.
- WANG F, LI K P, ZHOU L D, et al. Daily Pattern Prediction Based Classification Modeling Approach for Day-Ahead

- Electricity Price Forecasting [J]. International Journal of Electrical Power & Energy Systems, 2019, 105: 529-540.
- [6] AYUB N, JAVAID N, MUJEEB S, et al. Electricity Load Forecasting in Smart Grids Using Support Vector Machine [C]// Advanced Information Networking and Applications. Matsue: Spring Cham, 2020.
- [7] SHAO Z, YANG S L, GAO F, et al. A New Electricity Price Prediction Strategy Using Mutual Information-Based SVM-RFE Classification [J]. Renewable and Sustainable Energy Reviews, 2017, 70: 330-341.
- [8] 王萍, 李磊, 胡聪, 等. 云计算环境下智能电网短期负荷预测方法 [J]. 科学技术与工程, 2018, 18(7): 153-158.
- [9] TONG C, LI J, LANG C, et al. An Efficient Deep Model for Day-Ahead Electricity Load Forecasting with Stacked Denoising Auto-Encoders [J]. Journal of Parallel and Distributed Computing, 2018, 117(7): 267-273.
- [10] CHENG H Y, DING X W, ZHOU W N, et al. A Hybrid Electricity Price Forecasting Model with Bayesian Optimization for German Energy Exchange [J]. International Journal of Electrical Power & Energy Systems, 2019, 110(9): 653-666.
- [11] KUO P H, HUANG C J. An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks [J]. Sustainability, 2018, 10(4): 1280-1286.

Deep Learning Model for Smart Grid Electricity Price Prediction

MIAO Yu-rong¹, CHEN Sen-bo²

1. Dean's office, Jiangsu vocational College of Business, Nantong Jiangsu 226011, China;

2. School of Information Science and Technology, Nantong University, Nantong Jiangsu 226019, China

Abstract: Aiming at the problems of accuracy caused by machine learning method's electricity price prediction on large data sets, a deep learning electricity price prediction model based on big data time series for electricity grid electricity price prediction has been proposed in this paper. Firstly, the collected data are preprocessed and normalized, and then feature selection is performed by means of a hybrid module of ReliefF algorithm and mutual information (MI). Secondly, the improved features are given to kernel principal component analysis (KPCA). And lastly, enhanced convolution neural network (ECNN) is used to predict the electricity price effectively. The experimental results show that compared with the existing benchmark scheme, the proposed model can better predict the price of smart grid, and it is helpful for smart grid to better operate and plan power generation.

Key words: smart grid electricity price forecast; big data; mutual information; kernel principal component analysis; enhanced convolution neural network

责任编辑 夏娟