

DOI:10.19322/j.cnki.issn.1006-4710.2020.01.018

基于经验模式分解与 LSTM 神经网络的短期电价预测模型

勾玄, 肖先勇

(四川大学 电气工程学院, 四川 成都 610065)

摘要: 在开放的电力市场中, 日前电价预测是个重要的研究方向。本文提出了一种基于经验模式分解(EMD)与长短期记忆神经网络(LSTM)的序列电价预测模型, 使用 EMD 提取电价序列中的周期分量与趋势分量, 利用 LSTM 分别对周期分量与趋势分量进行序列预测, 输出各分量的预测结果, 通过支持向量机回归(SVR)叠加各分量的预测序列生成预测价格序列。最后, 以美国 PJM 电力市场的电价数据为算例, 与 ARIMA 模型、单一 LSTM 神经网络模型的预测结果进行比较, 验证了 EMD-LSTM-SVR 模型能够提高短期电价预测精度。

关键词: 短期电价预测; 经验模式分解; 长短期记忆网络; 电力市场

中图分类号: TM-9 **文献标志码:** A **文章编号:** 1006-4710(2020)01-0129-06

Short-term electricity price forecasting model based on empirical mode decomposition and LSTM neural network

GOU Xuan, XIAO Xianyong

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Short-term electricity price forecasting is an important research domain in electricity market. In this paper, a hybrid model for short-term electricity price forecasting based on empirical mode decomposition (EMD) and long short-term memory neural network (LSTM) is proposed. First, EMD is used to extract the periodic component and trend component in the series, and then LSTM is used to predict the periodic component and trend component respectively; finally, the forecast price sequence is generated by the support vector machine regression (SVR) superposing forecast series of each component. Taking the data of US PJM power market as a case study, the EMD-LSTM-SVR model is confirmed to improve the prediction accuracy of short-term electricity price comparing with the results of ARIMA model and single LSTM model.

Key words: short-term electricity price forecasting; empirical mode decomposition; LSTM; power market

在售电侧放开的大环境下, 电力市场的价格机制对市场各主体的公平交易、市场各参与者之间的供需互动具有重要的影响。准确预测短期电价, 将为电力市场上各参与方提供有效的决策指导, 能够通过有效调整市场策略而获取相应的经济利益, 从而提升市场在调节能源资源配置上的效率^[1]。

在一个较为成熟的电力市场中, 文献[2]~[3]

认为所有的市场参与者都没有操控市场的能力, 也就是说可以忽略市场力的影响, 电价是商品市场自由交易的产物, 不能被人为控制, 电价的预测属于商品价格时间序列预测的范畴。同时, 电能又兼有不可大规模存储的特殊性, 必须满足时刻供需平衡, 这使得电价的预测又不同于一般商品的价格预测。现实中, 气候变化、经济波动、特殊节假日等诸多外生

收稿日期: 2019-08-23; 网络出版日期: 2020-04-22

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1294.N.20200421.1719.019.html>

基金项目: 四川省科技计划资助项目(2018GZDZX0044)

第一作者: 勾玄, 男, 硕士生, 研究方向为电力市场等。E-mail: xuan_gou@163.com

通信作者: 肖先勇, 男, 教授, 博导, 博士, 研究方向为电能质量与优质供电、电力市场、智能电网等。E-mail: xiao_xianyong@163.com

因素都会对用电需求产生影响,需求直接影响商品的价格,从而使得电价常表现出高度的随机波动性,这也就使得高准确度的电价预测颇具挑战性。

目前,研究较为广泛的电价预测模型主要分为线性的统计学模型和非线性的机器学习模型两类^[4]。对于线性模型,通常使用统计理论和数学方程来推断时间序列的预测值,其中比较著名的有线性回归模型、指数平滑模型和自回归积分滑动平均(ARMA)模型^[5-8]。非线性的机器学习方法是从时间序列数据中学习特征再进行预测,算法比较复杂但准确度较高,相关方法有人工神经网络(ANN)、支持向量回归模型(support vector regression, SVR)、模糊综合评估等^[9-11]。

经验模式分解(empirical mode decomposition, EMD)算法将原始序列分解成多个具有局部时变特性的本征模态函数,针对各函数的特点分别预测后形成最终结果,该方法具有优良的时频聚集性^[12],因此对于预测电价这种突变信号有较强的先天优势。文献^{[13]~[16]}等已将 EMD 与 SVR、RBF 神经网络、粒子群优化等组合形成不同的混合算法对短期电价进行预测,实验结果表明,混合模型较单一算法模型而言预测精度有所提升,但各类混合模型均有其不同的特点和适用范围。

基于深度学习的长短期记忆(LSTM)神经网络可以同时兼顾数据的时序性和非线性^[14],模型适用范围广。已有研究^[17-18]将这种方法应用于负荷预测上,相比于传统的预测方法,其预测精度和对外部影响的鲁棒性均表现得更为优良^[19]。但将这种方法运用于电价预测研究还比较少见^[20]。

本文提出了一种基于经验模式分解与长短期记忆神经网络的 EMD-LSTM-SVR 序列电价预测模型,使用 EMD 提取序列中的周期分量与趋势分量,利用 LSTM 分别对周期分量与趋势分量进行序列预测输出各分量的预测结果,通过支持向量机回归(SVR)叠加各分量的预测序列生成预测价格序列。最后,以美国 PJM 电力市场的电价数据为算例,与传统的 ARIMA 时间序列预测模型、单一 LSTM 神经网络模型的预测结果进行了比较,验证了 EMD-LSTM-SVR 模型能够克服单一模型的局限性,预测精度高,具有一定的参考价值。

1 基本算法

1.1 经验模式分解

经验模式分解(EMD),也称 Hilbert-Huang 变换(HHT),它将复杂的时间序列信号分解为若干个

“本征模函数”(intrinsic mode functions, IMF)和一个余项 res 之和,是一种较新的针对非线性、非平稳数据的完全自适应时频分析方法,近年来已被成功应用于很多重要的数据分析领域,由于其精确化、形象化和可视化的特点,在工程应用中具有较高的价值。

本征模函数(IMF)具有两个特点:①在任意时刻,其上下包络线的均值都为零;②相邻过零点之间只有一个极值点。

具体的分解过程为:

1) 确定时间序列信号 $x(t)$ 的局部极大值和极小值,并分别进行三次样条插值,形成上包络 $x_{up}(t)$ 和下包络 $x_{down}(t)$;

2) 根据上下包络线计算包络均值 $m_1(t) = [x_{up}(t) + x_{down}(t)]/2$;

3) 通过从原始时间序列信号 $x(t)$ 中减去均值 $m_1(t)$,计算新序列 $h_1(t) = x(t) - m_1(t)$;

4) 判断 $h_1(t)$ 是否满足 IMF 的两个特点:若满足,则 $h_1(t)$ 是提取出的一个 IMF,此时用 $x_1(t) = x(t) - h_1(t)$ 代替第一步中的 $x(t)$;若 $h_1(t)$ 不是提取出的 IMF,则用 $h_1(t)$ 代替第一步中的 $x(t)$,重新分解,直到 $h_1(t)$ 满足 IMF 的特点;

5) 重复以上分解步骤即可提取到下一个 IMF,直至 $x_n(t)$ 出现一个极值点或变成一个单调函数为止,此时,已经无法再提取出新的本征模函数,剩下项 $x_n(t)$ 就是余项 r_n 。

最终,原始时间序列 $x(t)$ 被分解为 $x(t) =$

$$\sum_{i=1}^n h_i(t) + r_n$$

其中, n 为本征模函数的个数,由 $x(t)$ 决定; r_n 是最终的剩余变量,它是 $x(t)$ 的主要趋势项; $h_i(t)$ 为本征模函数,可证明这些本征模函数之间几乎是正交的。

电价曲线正是典型的非线性、非平稳数据,它受许多因素的影响,例如经济因素、季节、天气以及一些其他随机因素。本文使用 EMD 算法对电价数据进行平稳化处理,自适应地提取出几个具有周期性特征的 IMF 分量和余项 res,输入给后续模块。

1.2 长短期记忆神经网络

长短期记忆神经网络(long short-term memory, LSTM)是一种时间循环神经网络,学习时间序列的长短期依赖于信息,适合处理和预测时间序列中的间隔和延迟事件^[20]。

LSTM 神经网络是基于循环神经网络(recurrent neural networks, RNN)改进的一种算法。

RNN 可以被看作是同一神经网络的多次复制,逐次把信息传递下去,如图 1 所示,图中 A 表示 LSTM 模块。

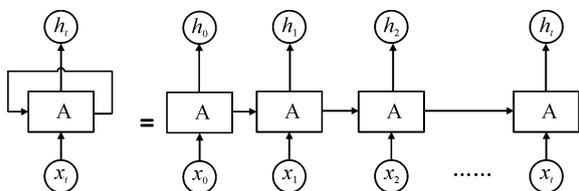


图 1 RNN 示意图

Fig. 1 Diagram of RNN structure

LSTM 在 RNN 的基础上增加了一个存储单元,如图 2 所示,解决了 RNN 梯度弥散的问题,从而实现了长期记忆功能。

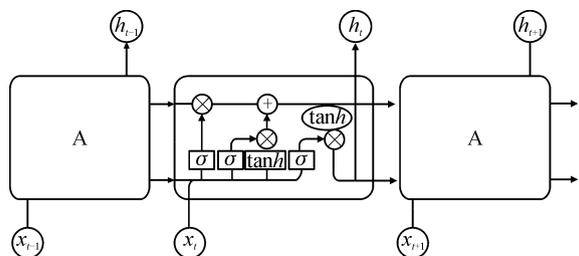


图 2 LSTM 示意图

Fig. 2 Diagram of LSTM structure

LSTM 模块当前输入状态为 t ,其存储单元由四个“门”实现,分别是:

1) 忘记门:读取上一层的输出 h_{t-1} 和当前输入 x_t ,输出 f_t 并赋值到当前的细胞状态 C_{t-1} 中;

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

2) 输入门:记忆现在的信息 i_t 和一部分忘记门输出的信息 \tilde{C}_t ;

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

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

3) 更新门:将过去的状态 C_{t-1} 和当前的记忆 \tilde{C}_t 进行合并,输出当前状态 C_t ;

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

4) 输出门:选择一部分细胞状态最终输出 h_t 。

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

$$h_t = \sigma_t \times \tanh(C_t) \quad (6)$$

其中, $\sigma(x) = \frac{1}{1 + e^{-x}}$ 为 S 型激活函数; W_f 、

W_i 、 W_C 、 W_o 、 b_f 、 b_i 、 b_C 、 b_o 都是模型中待训练的参数。

1.3 支持向量回归

支持向量机(SVM)是由 Cortes 和 Vapnik 基于统计学习理论提出的机器学习算法,它是将输入空间映射到高维空间的非线性函数,也常被称为“核

映射”。通常使用径向基核函数 RBF,定义式为:

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}\right) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (7)$$

其中, \mathbf{x} 为输入空间中任一点, \mathbf{x}' 为某一中心, σ 为函数的宽度参数,控制了径向基函数的径向作用范围。一般取 $\gamma = 1/(2\sigma^2)$ 来描述核函数的宽度, γ 是核函数中一个重要的超参数。

基于径向基核函数的回归模型在训练过程中既要考虑经验风险,也要考虑结构风险,因此定义损失函数为:

$$\begin{aligned} \min_{\omega, b, \xi_i, \xi_i^*} \quad & \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^* \\ \text{subject to} \quad & \omega^T \varphi(x_i) + b - z_i \leq \varepsilon + \xi_i \\ & z_i - \omega^T \varphi(x_i) - b \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \end{aligned} \quad (8)$$

式中: ω 和 b 是回归系数, ξ_i 和 ξ_i^* 是约束中的松弛变量, ω 、 b 、 ξ_i 和 ξ_i^* 都是模型待训练的参数; $\varphi(x_i)$ 为径向基核函数; l 表示其映射空间的维度; z_i 表示输入 x_i 对应的输出值,是训练数据中给定的标签; ε 表示误差项; C 是“惩罚系数”,使模型在训练精度和泛化误差间达到平衡。

SVR 能够快速收敛到全局最优解,已经在电价预测领域得到了广泛应用,例如文献[19]将 SVR 和 ARMA 两种模型集成 SVR-ARMA 模型进行电价预测,实现了良好的性能。本文使用 SVR 对各分量的预测结果进行回归,形成最终的预测日前电价。

2 预测方法

2.1 EMD-LSTM-SVR 混合模型

本文模拟的是对翌日进行日前电价预测的场景,在这个场景中,当日及历史电价数据均已获取,即训练一个使用滚动的时间序列来进行多步长序列预测的 seq2seq 模型。模型采取“分而治之”的思想,将原始的时间序列数据经 HHT 变换分解成一系列子数据集。如前文所述,用以训练的电价数据可以通过 EMD 方法分解为若干个 IMF 和一个代表趋势项的残余 res 的形式,然后针对每个分解项训练 LSTM 模型进行预测,再使用 SVR 模型将各个分解项的预测结果整合成最终的预测结果,如图 3 所示。

计算流程为:

1) 使用 EMD 方法将电价数据分解成若干个 IMF 项和残差项的形式;

2) 构建训练矩阵,作为每个分解项 LSTM 模

型的输入;

3) 训练模型,得到各分解项的预期输出结果;

4) 使用 SVR 模型将各分解项的预测结果整合成整体预测结果。

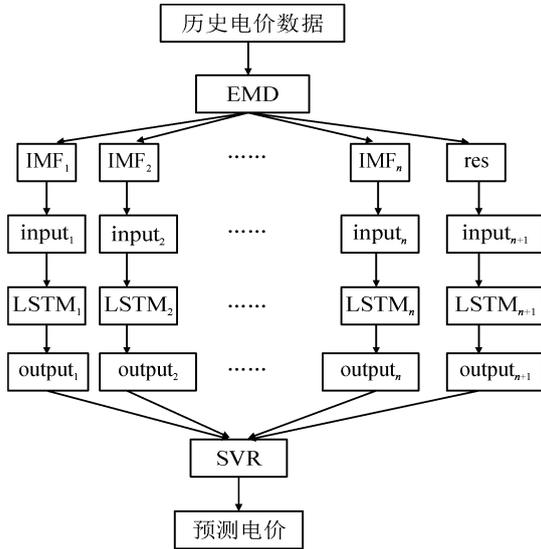


图3 EMD-LSTM-SVR混合模型

Fig. 3 Mixed model of EMD-LSTM-SVR

2.2 评价指标

本文采用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)作为衡量预测方法效果的主要指标。假设 y_i 是第 i 个预测电价数据的真实值, \hat{y}_i 是预测值, n 是样本个数,计算公式为:

$$R_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

$$R_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (10)$$

$$R_{RMSE} = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

3 算例分析

PJM 日前市场采用本地边际电价定价方式,按小时出清,本文以系统日前加权平均电价作为原始电价数据。考虑到电价在一年中会存在一定的季节性变化,本算例分别选取美国 PJM 市场 2016 年 2 月、5 月、8 月、11 月的日前电价数据作为原始数据。

3.1 数据分割

模型输入为预测日前 14 天的电价数据,输出为预测日每小时电价序列,即本文要建立一个滚动的序列预测模型,输入变量 \mathbf{X} 的序列长度为 336(14 天 \times 24 小时),输出变量 \mathbf{Y} 为预测日当天 24 个电价数据, \mathbf{X} 和 \mathbf{Y} 构成一组样本。按照该方式对原始电价数据进行变换生成样本集,并进行最大最小归一化。

3.2 模型预测

模型预测分析在 Python 3.6 环境下实现,计算机处理器为 Intel Core i5-8250,CPU 主频 1.6 GHz,内存 8 GB。

首先,对输入变量 \mathbf{X} 进行 EMD 分解。对于不同的 \mathbf{X} ,分解得到的 IMF 项数可能是不同的,但本文经过多次实验发现,IMF 的前 4 个序列已经能很好地描述输入 \mathbf{X} 的周期性趋势,余项可纳入 res 项进行处理,因此,本文将所有实验的 IMF 都设为 4 项。以 2 月电价数据中某个输入 \mathbf{X} 为例,其 EMD 分解如图 4 所示。

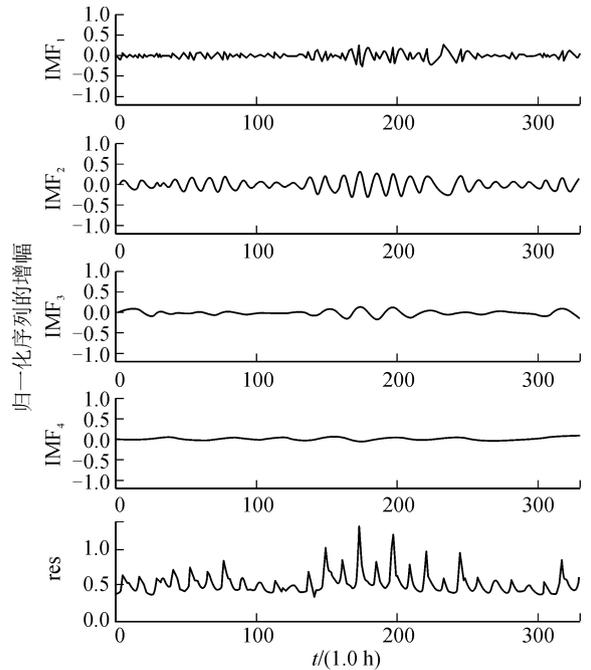


图4 EMD分解

Fig. 4 Decomposition graph of EMD

然后,对各分量训练 LSTM 神经网络,提取其中隐藏的模式。模型中的 LSTM 神经网络通过 PyTorch 1.3.1 版本实现,含有 2 个隐藏层和 1 个输出层,隐藏层神经元个数为 20,损失函数使用均方误差 MSE,优化算法为 Adam。

在 2 月测试集上验证各个 LSTM 模型的平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)如表 1 所示。

表1 LSTM 模块预测误差

Tab. 1 Prediction error by LSTMs

分量	$R_{MAE}/$ (美元 \cdot MW $^{-1}$ \cdot h $^{-1}$)	$R_{MAPE}/$ %	$R_{RMSE}/$ (美元 \cdot MW $^{-1}$ \cdot h $^{-1}$)
IMF ₁	1.66	2.18	165
IMF ₂	0.98	1.85	6.28
IMF ₃	0.69	0.98	97
IMF ₄	0.26	0.63	0.47
res	1.38	1.11	1.09

LSTM 的输出作为 SVR 模块的输入,SVR 模块通过 scikit-learn 0.22.2 版本实现,使用径向基核函数 rbf kernel,径向基宽度参数 γ 使用网格搜索在 $[0.1,1,10,100]$ 中搜寻最优值,惩罚系数 $C=1$ 。

图 5 为预测日 24h 日前电价的预测结果,与真实电价对比可见,本模型预测的电价能够准确反映当日价格的变动趋势,与真实值拟合较好。

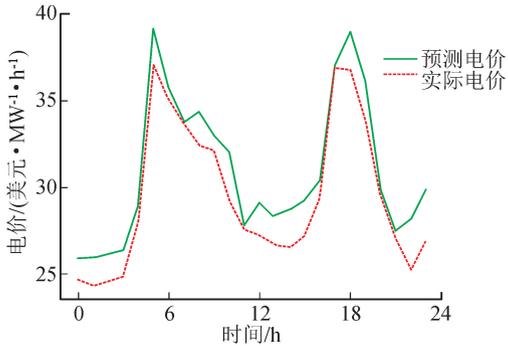


图 5 EMD-LSTM-SVR 模型预测电价
Fig. 5 Electricity price prediction based on EMD-LSTM-SVR

对 2016 年 2 月、5 月、8 月、11 月数据集分别进行了测试,本模型预测误差如表 2 所示。可以看出,本文提出的 EMD-LSTM-SVR 模型在 2 月的数据集上预测精度最好,在 11 月的数据集上预测精度不佳,原因是 2 月电价数据较平滑,而 11 月数据系列波动较大,尖峰电价较多,预测精度差。

表 2 不同数据集的预测误差

Tab. 2 Prediction error for different data sets

数据集	$R_{MAE}/$ (美元·MW ⁻¹ ·h ⁻¹)	$R_{MAPE}/$ %	$R_{RMSE}/$ (美元·MW ⁻¹ ·h ⁻¹)
2 月	0.47	1.112 5	9.94
5 月	1.25	7.923 0	13.98
8 月	0.98	6.207 1	11.06
11 月	1.44	8.889 6	16.25

3.3 结果对比

为了进一步检验本文提出的 EMD-LSTM-SVR 模型的有效性,本文还采用了单一 LSTM 神经网络模型、经典 ARIMA 模型来进行对比预测,并选择 2016 年 2 月电价数据集进行测试。ARIMA 模型使用 EViews 软件建模,按照最低 AIC(Akaike information criterion)准则选择参数,模型参数值选择 ARIMA(2,2,1)。各模型预测电价与真实值的对比如图 6 所示,在测试集上相应评价指标的对比如表 3 所示。

不难看出,基于深度学习的单一 LSTM 模型和 EMD-LSTM-SVR 模型均能较好地拟合当日实际电价曲线,ARIMA 模型表现略差。

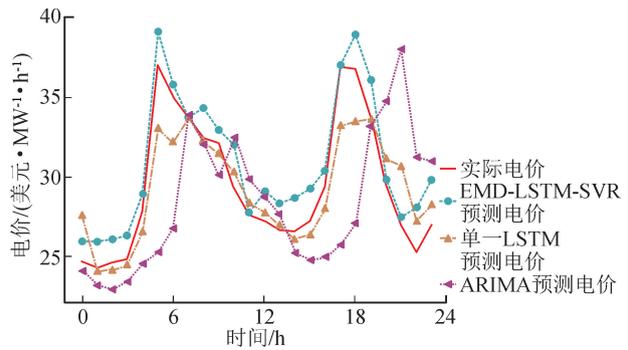


图 6 不同模型预测电价

Fig. 6 Electricity price prediction based on different models

表 3 不同模型评价指标的比较

Tab. 3 Comparison of evaluations on different models

模型	$R_{MAE}/$ (美元·MW ⁻¹ ·h ⁻¹)	$R_{MAPE}/$ %	$R_{RMSE}/$ (美元·MW ⁻¹ ·h ⁻¹)
A	1.04	8.763 5	10.01
B	0.68	4.201 3	15.83
C	0.47	1.112 5	9.94

注:A:ARIMA; B:单一 LSTM; C:EMD-LSTM-SVR。

表 3 的结果显示:从预测误差评价指标维度来看,本文提出的 EMD-LSTM-SVR 混合模型明显优于 ARIMA 模型和单一 LSTM 模型,其在 MAE 指标上提升最高可达 0.57 美元/(MW·h),在 MAPE 指标上提升最高可达 7.651%,在 RMSE 指标上提升最高可达 5.89 美元/(MW·h),体现了本模型能够克服单一模型的不足,提升预测效果的优点。

3.4 讨论

本部分讨论分析 EMD-LSTM-SVR 混合模型在电价预测中的优越性。

本模型在所列的几种模型里表现最佳,它既能兼顾序列时序性和非线性的特点,又能深入挖掘序列隐含的某些特征,预测精度较高的主要原因是针对短期电价序列预测设定了合理结构的 LSTM,并且针对本文的数据序列对 IMF 分解项数进行了限制,防止过拟合现象的发生,从而适合预测波动性较大的电价序列。

但不足的是,上述模型 RMSE 都比较大,是因为 RMSE 对异常值很敏感,当个别预测值与真实值相差较大时 RMSE 就会很大。本文的电价序列中存在一些电价“尖峰”,对于这些异常值,上述模型均没有很好的预测效果,下一步研究可以考虑极值理论建模分析。

4 结语

本文提出了一种基于经验模式分解与 LSTM 神经网络的短期电价预测方法(EMD-LSTM-SVR 模型),首先利用 EMD 将训练集数据分解成 IMF

分量和 res 余量,然后利用 LSTM 对分解出的子序列项分别建模进行单独预测,最后利用 SVR 模型得出电价的预测值。为了验证模型的预测性能,本文还以美国 PJM 市场日前电价数据为算例,与传统的 ARIMA 模型和单一 LSTM 模型进行对比实验,结果表明,本模型与传统方法相比,在减小模型预测误差方面有较好的提升,适合预测波动性较大的时间序列,在短期电价预测中有应用前景。

但本模型的主要不足在于对“尖峰”电价等序列异常值处理效果不佳,在未来的研究中可以考虑进行极值理论建模,或者纳入天气、经济指标等影响电价的因素作为输入变量,来对电价数据进行综合预测。

参考文献:

- [1] 杨晓萍,刘浩杰,黄强.考虑分时电价的风光储联合优化调度研究[J].西安理工大学学报,2016,32(4):403-409.
YANG Xiaoping, LIU Haojie, HUANG Qiang. Research on wind-solar-battery hybrid optimization based on TOU electricity price[J]. Journal of Xi'an University of Technology, 2016, 32(4): 403-409.
- [2] FLETEN S E, PETERSEN E. Constructing bidding curves for a price-taking retailer in the Norwegian electricity market[J]. IEEE Transactions on Power Systems, 2005, 20(2):701-708.
- [3] YAN H M, YAN H Z. Optimal energy purchases in deregulated California energy markets[C]//2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No. 00CH37077). IEEE, 2000, 2: 1249-1254.
- [4] REN Y, SUGANTHAN P N, SRIKANTH N, et al. Random vector functional link network for short-term electricity load demand forecasting[J]. Information Sciences, 2016, 367: 1078-1093.
- [5] 曾勇红,王锡凡,冯宗建.基于混合自回归滑动平均潜周期模型的短期电价预测[J].西安交通大学学报,2008,42(2):184-188.
ZENG Yonghong, WANG Xifan, FENG Zongjian. Short term forecast of electricity price based on mixed autoregressive moving average and hidden periodic model [J]. Journal of Xi'an Jiaotong University, 2008, 42(2): 184-188.
- [6] DARBELLAY G A, SLAMA M. Forecasting the short-term demand for electricity: do neural networks stand a better chance? [J]. International Journal of Forecasting, 2000, 16(1): 71-83.
- [7] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20(3): 273-297.
- [8] YING L C, PAN M C. Using adaptive network based fuzzy inference system to forecast regional electricity loads[J]. Energy Conversion and Management, 2008, 49(2): 205-211.
- [9] QIU X H, SUGANTHAN P N, AMARATUNGA G A J. Short-term electricity price forecasting with empirical mode decomposition based ensemble kernel machines[J]. Procedia Computer Science, 2017, 108: 1308-1317.
- [10] 廖晓辉,周冰,杨冬强,等.一种基于HHT的短期电价组合预测方法[J].郑州大学学报(工学版),2016,37(1):10-14.
LIAO Xiaohui, ZHOU Bing, YANG Dongqiang, et al. A method for short-term electricity price forecasting based on HHT[J]. Journal of Zhengzhou University (Engineering Science), 2016, 37(1):10-14.
- [11] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM [J]. Neural Computation, 2000, 12(10): 2451-2471.
- [12] 陈卓,孙龙祥.基于深度学习LSTM网络的短期电力负荷预测方法[J].电子技术,2018,47(1):39-41.
CHEN Zhuo, SUN Longxiang. Short-term electrical load forecasting based on deep learning LSTM networks[J]. Electronic Technology, 2018, 47(1): 39-41.
- [13] 杨甲甲,刘国龙,赵俊华,等.采用长短期记忆深度学习模型的工业负荷短期预测方法[J].电力建设,2018,39(10):20-27.
YANG Jiajia, LIU Guolong, ZHAO Junhua, et al. A long short term memory based deep learning method for industrial load forecasting [J]. Electric Power Construction, 2018, 39(10):20-27.
- [14] KIM H Y, WON C H. Forecasting the volatility of stock price index: a hybrid model integrating LSTM with multiple GARCH-type models[J]. Expert Systems with Applications, 2018, 103: 25-37.
- [15] ZHANG Y, LI C, LI L. Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods [J]. Applied Energy, 2017, 190: 291-305.
- [16] PANAPAKIDISI P, DAGOUMAS A S. Day-ahead electricity price forecasting via the application of artificial neural network based models[J]. Applied Energy, 2016, 172:132-151.
- [17] YAN X, CHOWDHURY N A. Mid-term electricity market clearing price forecasting: a multiple SVM approach[J]. International Journal of Electrical Power and Energy Systems, 2014, 58: 206-214.
- [18] DUDEK G. Pattern-based local linear regression models for short-term load forecasting[J]. Electric Power Systems Research, 2016, 130:139-147.
- [19] CHE J X, WANG J Z. Short-term electricity prices forecasting based on support vector regression and auto-regressive integrated moving average modeling[J]. Energy Conversion and Management, 2010, 51(10): 1911-1917.
- [20] 付文博,孙涛,梁藉,等.深度学习原理及应用综述[J].计算机科学,2018,45(6A):11-15,40.
FU Wenbo, SUN Tao, LIANG Ji, et al. Review of principle and application of deep learning[J]. Computer Science, 2018, 45(6A):11-15,40.