

基于混合预处理神经网络模型的股价预测*

李建磊, 石伟康

华北水利水电大学数学与统计学院, 河南 郑州 450046

摘要: 在股价预测领域, 多元时间序列中通常存在多个变量之间的复杂相互关联, 同时受到多种因素的影响, 这增加了准确预测的难度. 为了应对这一挑战, 提出了一种创新的混合预处理技术方法. 首先, 利用经验小波变换 (EWT) 同时提取时间序列的低频和低频成分; 接着, 引入了动态时间规整 (DTW) 和差分动态时间规整 (DDTW) 来度量不同分量之间的相似性, 从而有效地识别了股价时间序列中的关联模式和相似性. 在进一步的分析中, 采用滑动窗口处理高频分量, 并进行主成分分析, 同时对低频分量进行直接主成分分析. 最后, 将这些方法应用于多个神经网络预测模型中, 发现模型的性能和预测精度都有显著提升.

关键词: 股价预测; 经验小波变换; 动态时间规整; 主成分分析; 神经网络

中图分类号: TP183 文献标志码: A 文章编号: 2097-0137(XXXX)XX-0001-09

Stock price prediction based on hybrid preprocessing neural network model

LI Jianlei, SHI Weikang

School of Mathematics and Statistics, North China University of Water Resources and Electric Power, Zhengzhou 450046, China

Abstract: In the field of stock price prediction, there often exists complex interrelationships among multiple variables in multivariate time series, simultaneously influenced by various factors, which increases the difficulty of accurate prediction. To address this challenge, we propose an innovative hybrid preprocessing technique. Firstly, we utilize Empirical Wavelet Transform (EWT) to simultaneously extract the low-frequency and high-frequency components of time series. Subsequently, we introduce Dynamic Time Warping (DTW) and Differential Dynamic Time Warping (DDTW) to measure the similarity between different components, effectively identifying correlated patterns and similarities in stock price time series. In further analysis, we employ a sliding window approach for high-frequency components and conduct Principal Component Analysis (PCA), while directly applying PCA to low-frequency components. Finally, we apply these methods to multiple neural network prediction models and observe significant improvements in model performance and prediction accuracy.

Key words: stock price prediction; empirical wavelet transform; dynamic time warping; principal component analysis; neural network

* 收稿日期: 2024-01-05 录用日期: 2025-11-09 网络首发日期: XXXX-XX-XX

基金项目: 河南省自然科学基金 (232300421143);

河南省高等学校重点科研项目计划基础研究 (25ZX013)

作者简介: 李建磊 (1982 年生) 男; 研究方向: 数据分析预处理技术; E-mail: lijianlei@ncwu.edu.cn

通信作者: 石伟康 (1997 年生) 男; 研究方向: 小波分析预处理技术; E-mail: 2422074736@qq.com



ZR20240010

时间序列预测(Ediger et al., 2007)是一项关键的研究领域,它关注于分析和处理随时间变化(Kumar et al., 2010)的数据序列,以预测未来的趋势(Cheong, 2009)、模式(Krithikaivasan et al., 2007)或数值(Garcia et al., 2005).这一领域的研究对于各种行业都至关重要,例如金融市场分析(Li, 2022)、天气预报、能源需求预测(Pegalajar et al., 2022)以及库存管理等.准确的时间序列预测可以帮助企业和组织做出更明智的决策(Andreeski et al., 2020),优化资源分配(Ampountolas, 2019),减少不确定性,提高效率.

近年来,神经网络因其强大的非线性建模能力而被广泛应用于股价预测.尽管神经网络在某些特定的时间序列问题上表现出色,但其训练过程通常需要大量计算资源,并且其预测精度有时不尽如人意.

为了提高预测精度,各个领域融合了多种预处理技术和专业知识,来提高模型的性能.例如,Quilty et al. (2018)提出基于预处理进行分类的算法,这个算法通常可以分为直接类和间接类.这种分类是根据因果和时间序列类别进行分类的.这种精细的数据准备工作有助于更加精确地建模基础数据,从而在整体上提高预测结果的准确性.为了减少预测误差,研究人员开发了一系列数据预处理方法.这些方法包括基于分解的方法(Mi et al., 2019),基于维度推导的方法、信号去噪方法(Qian et al., 2019)、基于小波分解(WD)的算法(Lei et al., 2008)、基于经验模式分解(EMD)的算法(Wang et al., 2016)、原子备用分解(ASD)(崔明建等, 2014)、季节指数调整(SIA)(Wang et al., 2015)、内在时间尺度分解(ITD)(Zhang et al., 2016)和变分模式分解(VMD)(Naik et al., 2018).Fijani et al.(2019)提出的创新混合模型融合了基于CEEMDAN、VMD的两层分解技术以及ELM和LSSM的预测模型,展示了在水质参数预测领域的强大应用潜力.Lin et al.(2020)开发了一种集成WPD和EMD预处理方法的混合模型,专门用于原油价格预测.通过信号去噪的WPD方法显著降低原油价格中的噪声,随后经验模态分解技术将去噪后的价格转换为不同的IMF.利用复杂的长记忆GARCH-M模型对这些IMF进行预测,通过综合不同IMF的预测结果,构建了一个综合性能更强的混合模型.Deng et al.(2020)提出的混合模型融合了EWT和VMD分解技术、ARIMA和ENN预测模型,主要用于短期风速预测.这些方法的应用展示了在股价预测领域的强大潜力,有助于提高预测精度,并为投资者和决策者提供更可靠的决策支持.

在本文中,研究的核心在于先对多元时间序列(Widiputra et al., 2021)进行细致的特征选择和分类,本文利用经验模小波变换(EWT)(Xue et al., 2019)、动态时间规整(DTW)(Jain, 2019)及其变种差分动态时间规整(DDTW),提高时间序列数据的辨识度和理解度.EWT的应用主要是为了捕捉时间序列中的初始趋势和噪声波动,而DTW和DDTW则重点在于识别时间序列中的相关模式和相似性.随后,我们引入了动态时间主成分分析(DTPCA)这一创新方法,通过结合滑动窗口技术和主成分分析,分析同类别时间序列的高频和低频分量,揭示影响时间序列的长期和短期因素.这个步骤的关键在于深入理解和分解时间序列数据中的复杂结构,为后续的预测模型提供更加精确的输入数据.

1 研究方法

1.1 时间序列分解

经验小波变换结合了经验模态分解(EMD)和小波变换(WT)的优势,自适应地进行信号分析,同时具备高频分辨率、计算复杂度低以及完整的数学理论基础.这使得EWT成为非平稳信号处理的有效方法(王东庆等, 2023).

对原始信号进行FFT分析,将信号的Fourier频谱规范化在 $[0, \pi]$,并分割成连续的 N 段 $[A_1, A_2, \dots, A_N]$,频谱上将产生 $N + 1$ 条边界线.设 ω_n 为区间分界线,则 $A_n = [\omega_{n-1}, \omega_n]$,其中 $\omega_0 = 0, \omega_n = \pi$ 为区间边界线,信号频谱的分割示意图如图1所示.

过度相位的宽度由下式给出: $\tau_n = \gamma \times \omega_n, 0 < \gamma < \min \left\{ \frac{\omega_{n+1} - \omega_n}{\omega_{n+1} - \omega_n} \right\}$.

频带区间划分完成后,根据Meyer理论,每个区间 A_n 上的尺度函数 $\phi_n(\omega)$ 和小波函数 $\psi_n(\omega)$ 定义如下:

$$\phi_n(\omega) = \begin{cases} 1, & |\omega| < (1 - \gamma)\omega_n, \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right], & (1 - \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_n, \\ 0, & \text{其他.} \end{cases}$$




图1 分割示意图

Fig. 1 Segmentation diagram

$$\psi_n(\omega) = \begin{cases} 1, & (1 + \gamma)\omega_n < |\omega| < (1 - \gamma)\omega_{n+1}, \\ \cos\left[\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_{n+1}}(|\omega| - (1 - \gamma)\omega_{n+1})\right)\right], & (1 - \gamma)\omega_{n+1} \leq |\omega| \leq (1 + \gamma)\omega_{n+1}, \\ \sin\left[\frac{\pi}{2}\beta\left(\frac{1}{2\gamma\omega_n}(|\omega| - (1 - \gamma)\omega_n)\right)\right], & (1 - \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_n, \\ 0, & \text{其他.} \end{cases}$$

式中取 $\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3)$; $\tau_n = \gamma\omega_n, 0 < \gamma < 1$; $\gamma < \min\left\{\frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n}\right\}$.

构造经验小波变换的细节系数 $W_x(n, t)$ 和近似系数 $W_x(0, t)$:

$$W_x(n, t) = \langle x(t), \psi_n(t) \rangle = F^{-1}\left[\hat{x}(\omega) \overline{\psi_n(\bar{\omega})}\right], \quad W_x(0, t) = \langle x(t), \psi_0(t) \rangle = F^{-1}\left[\hat{x}(\omega) \overline{\psi_0(\bar{\omega})}\right].$$

将原始信号表示为近似值和细节值的叠加, 得到经验小波变换的重构信号

$$X(t) = W_x(0, t)\phi_0(t) + \sum_{n=1}^N W_x(n, t)\psi_n(t).$$

则原始信号分解后的各个模态分量为 $c_0 = W_x(0, t)\phi_0(t), c_n(t) = W_x(n, t)\psi_n(t), n = 1, \dots, N - 1$.

1.2 相似性度量

动态时间弯曲 (DTW, Dynamic Time Warping) 是一种用于测量两个序列之间相似度的算法. 主要用于时间序列数据, 尤其在语音识别和信号处理等领域中得到广泛应用. DTW 的核心思想是通过“弯曲”时间轴来找出两个时间序列之间的最佳匹配, 即使它们在时间或速度上有所不同 (李海林等, 2018).

给定两条时间序列 $S = \{s_1, s_2, \dots, s_n\}$ 和 $Q = \{q_1, q_2, \dots, q_m\}$, 以任意两点间的距离确立 $n \times m$ 的距离矩阵 $D_{n \times m}$, 其中

$$D(i, j) = \|s_i - q_j\|_\omega$$

为点 s_i 和 q_j 间的距离, $i = 1, 2, \dots, n, j = 1, 2, \dots, m$, 当 $\omega = 2$ 时为欧氏距离. 为了计算 S 和 Q 的动态时间弯曲距离 $DTW(S, Q)$, 需要找到一条最优的弯曲路径

$$P_{best} = \{p_1, p_2, \dots, p_k\} \quad (\max\{n, m\} \leq k \leq n + m + 1)$$

使得 S 和 Q 的累积距离值达到最小, p_k 表示该弯曲路径元素在距离矩阵中的位置, 即 $p_k = (i, j)_k$ 表示 s_i 和 q_j 间的匹配关系. 一般存在着多条弯曲路径, 有效的弯曲路径 P 必须符合给出的 3 个要求:

- 1) 边界性: $p_1 = (1, 1), p_k = (n, m)$;
- 2) 单调性: 给定 $p_k = (i, j)$ 和 $p_{k+1} = (i', j')$, 有 $i' \geq i, j' \geq j$;
- 3) 连续性: 给定 $p_k = (i, j)$ 和 $p_{k+1} = (i', j')$, 有 $i' \leq i + 1, j' \leq j + 1$.

在众多有效的路径中, 找到唯一的最优路径使得累积距离达到最小, 即 $D(S, Q) = \min\left\{\frac{1}{K} \sum_{k=1}^K D(p_k)\right\}$.

利用动态规划方法构造一个代价矩阵 γ , 其中每个元素通过下式得到:

$$\gamma(i, j) = D(i, j) + \min\{\gamma(i - 1, j - 1), \gamma(i - 1, j), \gamma(i, j - 1)\},$$

其中 $i = 1, 2, \dots, n, j = 1, 2, \dots, m, \gamma(0, 0) = 0, \gamma(i, 0) = \gamma(0, j) = +\infty. \gamma(n, m)$ 便是动态时间弯曲度量 S 和 Q 的

最小累积代价, 可知 $DTW(S, Q) = \gamma(n, m)$.

差分动态时间弯曲 (DDTW, Differential Dynamic Time Warping) 是动态时间弯曲 (DTW) 的一种变体, 在 DDTW 中, 首先对每个时间序列执行一阶差分. 这个过程通过计算序列中每个点与其前一个点之间的差值来完成, 从而获得表示序列局部变化的新序列. 然后, 使用传统的 DTW 算法来比较这些一阶差分序列.

1.3 主成分分析

多元主成分分析 (PCA, Principal Component Analysis) (Nedaivoda et al., 2019) 是一种统计方法, 用于分析多变量数据的主要特征和结构. PCA 特别适用于处理具有多个相关变量的复杂数据集. 在 PCA 中, 目标是从原始数据中提取一组较少的“主成分”, 这些主成分能够捕捉数据中的大部分变异性或信息. 这些主成分是原始变量的线性组合, 按照它们解释数据变异性的能力排序.

PCA 的核心思想是找到一个线性变换, 将原始多维数据投影到一个较低维度的空间中, 这个空间由若干主成分构成, 这些主成分捕获了数据的主要变异性. 设来自总体的样本数据矩阵为

$$X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = \begin{pmatrix} X_1^T \\ X_2^T \\ \vdots \\ X_n^T \end{pmatrix},$$

则样本的协方差矩阵和样本的相关矩阵分别为

$$S = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{x})(X_i - \bar{x})^T = (s_{ij})_{p \times p}, \quad R = (r)_{p \times p} = \left(\frac{s_{ii}}{\sqrt{s_{ii}} \sqrt{s_{jj}}} \right)_{p \times p},$$

其中 $\bar{x} = \frac{1}{n} \sum_{i=1}^n X_i$.

在实际问题中, 我们通常利用样本方差 S 替代总体方差或者利用样本协方差 R 替代总体的协方差计算. 本文将 PCA 和滑动窗口技术结合, 来提取数据短期波动的特征.

2 混合预处理的神经网络模型

本节主要介绍文章提出的混合预处理的模型框架, 搭建模型. 流程图见图 2.

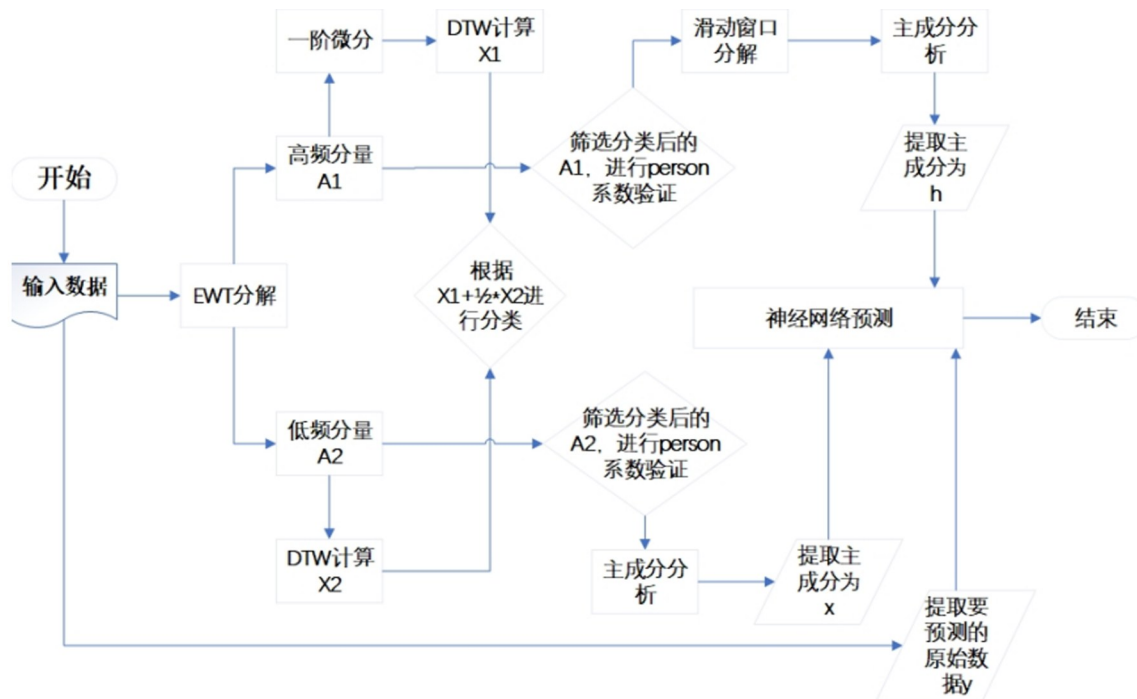


图 2 流程图

Fig. 2 Flow chart

3 实验及结果

为了验证混合预处理模型的优势,本文挑选以下模型进行对比:BP神经网络、LSTM神经网络、RNN循环神经网络(Egrioglu et al., 2023)、AM-LSTM混合神经网络(Liu et al., 2023)、CNN-BILSTM混合神经网络(Farid et al., 2021). 为了提高神经网络模型的精度和实验的对比度,我们统一使用注意力机制. 模型参数见表1.

表1 模型参数¹⁾
Table 1 Model parameters

模型	TIME STEP	BATCH SIZE	训练次数	Hidden dim	学习率	dropout	Predict Length
BP	20	32	500	64	0.01	—	—
LSTM	20	32	500	64	0.01	—	—
RNN	20	32	500	64	0.01	—	—
AM-LSTM	20	32	500	64	0.01	0.2	1
CNN-BILSTM	20	32	500	64	0.01	0.1	1

—: 没有测量.

以下是用于评价模型的评估指标:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i|^2}, \quad MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_i - y_i|}{y_i} \times 100.$$

本实验数据集来自 kaggle, 精选了加拿大顶级股票的每日股票数据. 数据集包含了 30 只股票自 2010 年 1 月至 2023 年 10 月的收盘价. 混合预处理后的神经网络模型输入维度为 3, 输出维度为 1. 无混合预处理的神经网络模型输入为 30, 输出维度为 1. 数据长度为 3 460, 其中 75% 为训练集, 其他为测试集.

从表2中我们可以明显看出混合预处理的CNN-BILSTM模型的表现最好,其RMSE、MAE和MAPE值

表2 模型评估结果
Table 2 Model evaluation results

模型	指标	BP	LSTM	RNN	AM-LSTM	CNN-BILSTM
混合预处理	RMSE	10.68	3.07	2.85	4.12	0.44
	MAE	8.48	1.87	1.75	2.81	0.32
	MAPE	0.09	0.02	0.02	0.03	0.009
无	RMSE	16.36	12.00	12.63	11.74	14.60
	MAE	14.40	9.63	10.38	9.77	12.10
	MAPE	0.16	0.10	0.11	0.11	0.13

分别是0.44、0.32和0.009,远低于其他模型. 在没有数据预处理的情况下,所有模型的表现都有所下降,误差指标普遍增加. 在这种情况下,AM-LSTM表现最好,其RMSE、MAE和MAPE值分别为11.74、9.77和0.11. 而BP模型再次表现最差. 总的来说,CNN-BILSTM模型在混合预处理的情况下表现最佳. 这说明不同的数据预处理方法对模型的性能有显著影响.

图3~4显示了经过混合预处理和未经过预处理的五个不同神经网络模型的绝对误差分布情况. 我们可以观察到几个显著的变化:混合预处理的绝对误差分布图要更平坦且接近0值,特别是对于CNN-BILSTM模型,这表明经过混合预处理后,BP模型的预测在大部分情况下非常接近真实值. 其他模型的误差分布曲线相比于未经混合预处理的情况更加平坦和宽广,这通常意味着预处理提高了这些模型在不同情况下的泛




图3 混合预处理神经网络绝对误差分布

Fig. 3 Distribution of absolute errors in the hybrid preprocessing neural network

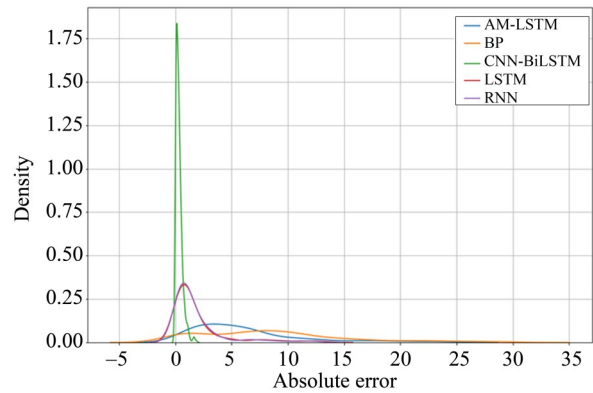


图4 绝对误差分布

Fig. 4 Distribution of absolute errors

化能力. 对于AM-LSTM模型,其误差分布峰值减小,这表明混合预处理增加了该模型预测的准确性. 因此混合预处理改变了模型的泛化特性使得这些模型更鲁棒,预测的准确性和精度大大提高.

图5~6是预测的100个数据. 我们从模型的预测准确性和预测曲线的趋势跟踪能力两个方面进行分析: 对于AM-LSTM模型无预处理:预测曲线未能捕捉到实际值的波动,预测值整体低估了实际值,显示出较大的系统性偏差. 有预处理:预测曲线显著改善,更好地捕捉到了实际值的波动趋势,预测值和实际值的吻合度提高,显示出混合预处理提升了模型对时间序列数据的理解能力. 对于BP模型无预处理:预测曲线的波动幅度与实际值相比差异较大,未能有效捕捉到数据的动态变化. 有预处理:预测曲线与实际值更为接近,虽然在某些点上仍存在偏差,但整体趋势跟踪能力得到了显著提升. 对于LSTM模型无预处理:预测曲线与

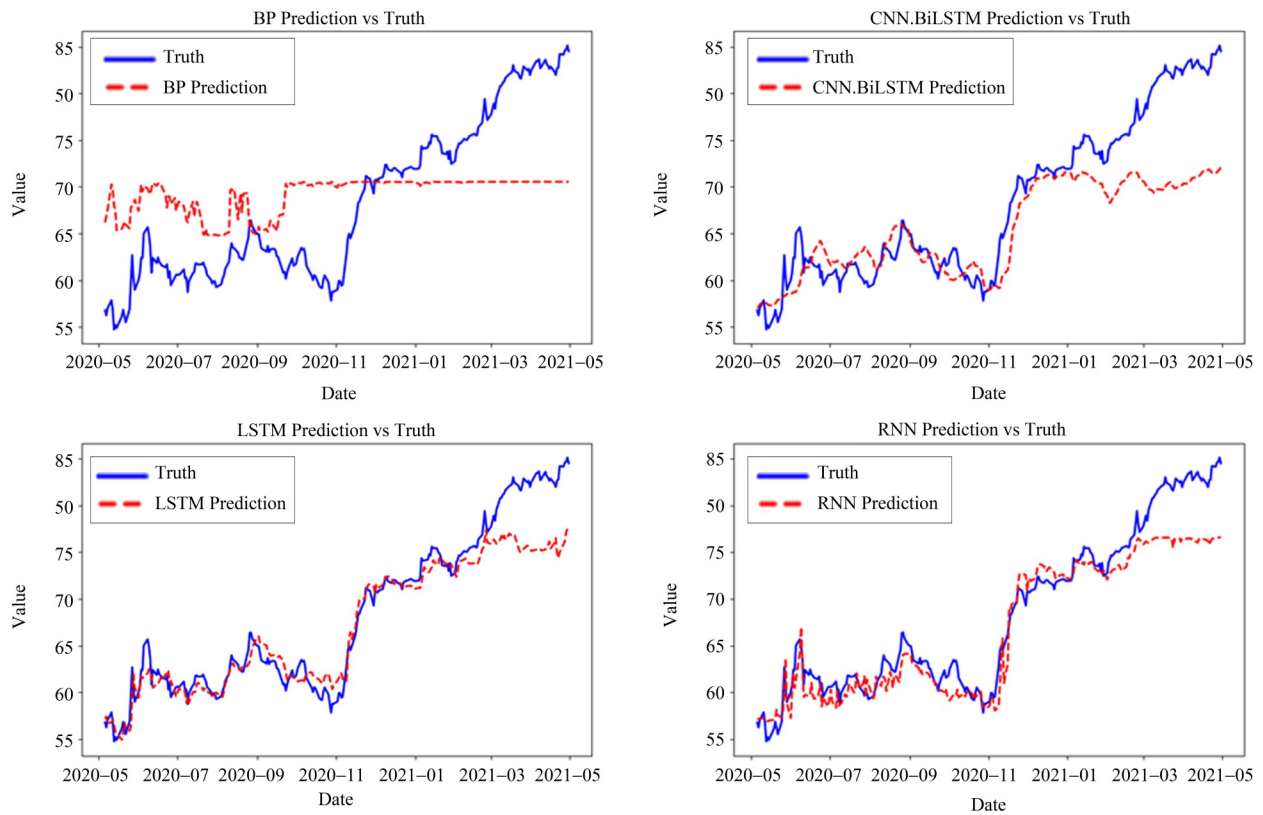


图5 无预处理预测结果

Fig. 5 Prediction charts without preprocessing




图6 混合预处理预测结果

Fig. 6 Prediction charts with hybrid preprocessing

实际值有明显的偏离,特别是在数据的波峰和波谷部分,说明模型对数据中的极值反应不足.有预处理:预测曲线的波动趋势与实际值相符,尽管在某些时间点的预测精度仍有改进空间,但整体上模型的预测性能得到了提高.

对于RNN模型无预处理:预测曲线呈现出一定程度的滞后效应,且在波动性较大的区域与实际值存在较大偏差.有预处理:预处理后的预测曲线更加平滑,并且在大部分时间点上能够更好地跟随实际值的变化,说明混合预处理有助于模型捕捉到更加复杂的时间序列特征.而混合预处理的CNN-BiLSTM模型预测精度过高,远优于其他模型和无预处理的预测结果.

从上述比较中可以看出,混合预处理显著提升了各个模型在时间序列预测任务上的性能.混合预处理增强了模型对于数据结构和模式的捕捉能力.在预测曲线的准确性和趋势跟踪方面,预处理后的模型在多数情况下都显示出更好的表现.

4 结论

股价预测领域的研究表明,预处理步骤在提高时间序列预测模型性能方面起着至关重要的作用.预处理不仅有助于模型更好地理解数据的结构,还能够提高模型对未来趋势变化的敏感性和准确性.强调了复杂的预处理步骤在多元时间序列预测中的关键性作用.未来的研究方向可以进一步探索和优化预处理步骤,以进一步改善模型的预测性能.此外,模型的架构和超参数设置也是影响预测性能的重要因素,需要在后续研究中进行仔细的调整和测试.

在股价预测中,采用适当的预处理方法对提高预测模型的性能至关重要.混合预处理方法已被证明可以显著提高预测精度,这一观点得到了通过图形展示的预测曲线与真实值的贴近程度以及较低的误差指标所证实.因此,为了在实际应用中获得最佳的预测效果,应考虑采用综合性的数据预处理步骤,结合强大的

神经网络模型,例如 CNN-BILSTM-SA 模型,以确保模型能够充分学习和捕捉时间序列数据的复杂动态特征.这种综合方法有望提高股价预测的准确性,为投资者和决策者提供更可靠的决策支持.

参考文献:

- 崔明建,孙元章,柯德平,等,2014.基于原子稀疏分解理论的短期风电功率滑动预测[J].电力自动化设备,34(1):120-127.
- 李海林,梁叶,王少春,2018.时间序列数据挖掘中的动态时间弯曲研究综述[J].控制与决策,33(8):1345-1353.
- 王东庆,周建华,伏云发,2023.EWT算法在单通道脑电信号眼电伪迹自动去除中的研究[J].电子测量与仪器学报,37(2):121-129.
- AMPOUNTOLAS A, 2019. Forecasting hotel demand uncertainty using time series Bayesian VAR models[J]. *Tour Econ*, 25(5): 734-756.
- ANDREESKI C, MECHKAROSKA D, 2020. Modelling, forecasting and testing decisions for seasonal time series in tourism[J]. *Acta Polytech Hung*, 17(10): 149-171.
- CHEONG C W, 2009. Modeling and forecasting crude oil markets using ARCH-type models[J]. *Energy Policy*, 37(6): 2346-2355.
- DENG Y, WANG B F, LU Z M, 2020. A hybrid model based on data preprocessing strategy and error correction system for wind speed forecasting[J]. *Energy Convers Manag*, 212: 112779.
- EDIGER V Ş, AKAR S, 2007. ARIMA forecasting of primary energy demand by fuel in Turkey[J]. *Energy Policy*, 35(3): 1701-1708.
- EGRIOGLU E, BAS E, 2023. A new hybrid recurrent artificial neural network for time series forecasting[J]. *Neural Comput Appl*, 35: 2855-2865.
- FARID A B, FATHY E M, SHARAF ELDIN A, et al, 2021. Software defect prediction using hybrid model (CBIL) of convolutional neural network (CNN) and bidirectional long short-term memory (Bi-LSTM)[J]. *PeerJ Comput Sci*, 7: e739.
- FIJANI E, BARZEGAR R, DEO R, et al, 2019. Design and implementation of a hybrid model based on two-layer decomposition method coupled with extreme learning machines to support real-time environmental monitoring of water quality parameters[J]. *Sci Total Environ*, 648: 839-853.
- GARCIA R C, CONTRERAS J, van AKKEREN M, et al, 2005. A GARCH forecasting model to predict day-ahead electricity prices[J]. *IEEE Trans Power Syst*, 20(2): 867-874.
- JAIN B J, 2019. Making the dynamic time warping distance warping-invariant[J]. *Pattern Recognit*, 94: 35-52.
- KRITHIKAIIVASAN B, ZENG Y, DEKA K, et al, 2007. ARCH-based traffic forecasting and dynamic bandwidth provisioning for periodically measured nonstationary traffic[J]. *IEEE/ACM Trans Netw*, 15(3): 683-696.
- KUMAR U, JAIN V K, 2010. ARIMA forecasting of ambient air pollutants (O_3 , NO, NO_2 and CO)[J]. *Stoch Environ Res Risk Assess*, 24(5): 751-760.
- LEI C, RAN L, 2008. Short-term wind speed forecasting model for wind farm based on wavelet decomposition[C]//2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2008: 2525-2529.
- LI X H, 2022. Application of neural networks in financial time series forecasting models[J]. *J Funct Spaces*, 2022: 7817264.
- LIN L, JIANG Y, XIAO H L, et al, 2020. Crude oil price forecasting based on a novel hybrid long memory GARCH-M and wavelet analysis model[J]. *Phys A Stat Mech Appl*, 543: 123532.
- LIU J, TANG X H, GUAN X, 2023. Grain protein function prediction based on self-attention mechanism and bidirectional LSTM[J]. *Brief Bioinform*, 24(1): bbac493.
- MI X W, LIU H, LI Y F, 2019. Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine[J]. *Energy Convers Manag*, 180: 196-205.
- NAIK J, DASH S, DASH P K, et al, 2018. Short term wind power forecasting using hybrid variational mode decomposition and

- multi-kernel regularized pseudo inverse neural network[J]. *Renew Energy*, 118: 180–212.
- NEDAIVODA I V, PRIMIN M A, MASLENNIKOV Y V, 2019. Algorithm for analysis of magnetocardiogram signals: The principal component method[J]. *J Commun Technol Electron*, 64: 1414–1421.
- PEGALAJAR M C, RUIZ L G B, 2022. Time series forecasting for energy consumption[J]. *Energies*, 15(3): 773.
- QIAN Z, PEI Y, ZAREIPOUR H, et al, 2019. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications[J]. *Appl Energy*, 235: 939–953.
- QUILTY J, ADAMOWSKI J, 2018. Addressing the incorrect usage of wavelet-based hydrological and water resources forecasting models for real-world applications with best practices and a new forecasting framework[J]. *J Hydrol*, 563: 336–353.
- WANG J Z, QIN S S, ZHOU Q P, et al, 2015. Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China[J]. *Renew Energy*, 76: 91–101.
- WANG S X, ZHANG N, WU L, et al, 2016. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method[J]. *Renew Energy*, 94: 629–636.
- WIDIPUTRA H, MAILANGKAY A, GAUTAMA E, 2021. Multivariate CNN-LSTM model for multiple parallel financial time-series prediction[J]. *Complexity*, 2021(1): 9903518.
- XUE B, HONG H, ZHOU S Z, et al, 2019. Morphological filtering enhanced empirical wavelet transform for mode decomposition[J]. *IEEE Access*, 7: 14283–14293.
- ZHANG L L, LI M S, JI T Y, et al, 2016. Short-term wind power prediction based on intrinsic time-scale decomposition and LS-SVM[C]//2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia), 2016: 41–45.

(责任编辑 冯兆永)