

DOI:10.3969/j.issn.1003-5060.2026.04.003

基于长时序数据多重分解降噪的药品需求预测

孟冠军, 彭裕博, 黄康, 李国强, 孙志鹏

(合肥工业大学 机械工程学院, 安徽 合肥 230009)

摘要:药品预测能够确保患者及时获得所需药品,还可有效地控制传染病的蔓延。鉴于药品需求长时序数据具有多周期性和高随机性等特点,文章提出一种基于多重分解降噪的策略并构建综合预测模型。首先,采用多周期时间序列分解(multiple seasonal-trend decomposition using LOESS, MSTL)算法和自适应噪声完全集合经验模态分解对药品需求序列进行二次分解,以充分提取时序特征;其次,针对各分解分量进行小波降噪与组合重构,有效降低数据噪声干扰;在建模阶段,结合卷积神经网络(convolutional neural network, CNN)的特征提取能力和长短期记忆(long short-term memory, LSTM)网络的时序建模优势,构建混合预测模型;为进一步提升性能,采用非洲秃鹫优化算法(African vultures optimization algorithm, AVOA)对模型超参数进行自动优化。实验结果表明,该文所提出的分解降噪策略能够有效提升模型的预测性能,并具有良好的通用性。

关键词:需求预测;药品;长时数据;多重分解;时序重构

中图分类号:TP391

文献标志码:A

文章编号:1003-5060(2026)04-0448-09

Drug demand prediction with multi-decomposition denoising for long time series data

MENG Guanjun, PENG Yubo, HUANG Kang, LI Guoqiang, SUN Zhipeng

(School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: Drug prediction can ensure that patients get the drugs they need in time. It can also effectively control the spread of infectious diseases. In view of the characteristics of multi-periodicity and high randomness of long time series data of drug demand, this paper proposes a comprehensive prediction model based on multi-decomposition denoising. Firstly, multiple seasonal-trend decomposition using LOESS(MSTL) algorithm and complete ensemble empirical mode decomposition with adaptive noise(CEEMDAN) are used to decompose the drug demand series for the second time to fully extract the time series features. Secondly, wavelet denoising (WD) and combination reconstruction are carried out for each decomposition component to effectively reduce data noise interference. In the modeling stage, a hybrid prediction model is constructed by combining the feature extraction ability of the convolutional neural network(CNN) and the time series modeling advantage of the long short-term memory(LSTM) network. In order to further improve the performance, the African vultures optimization algorithm(AVOA) is used to automatically optimize the hyperparameters of the model. The experimental results show that the decomposition denoising strategy proposed in this paper can effectively improve the prediction performance of the model and has good versatility.

Key words: demand prediction; drugs; long-term data; multiple decomposition; time series reconstruction

收稿日期:2023-12-20;修回日期:2024-06-08

基金项目:国家自然科学基金资助项目(52375051)

作者简介:孟冠军(1979—),男,安徽临泉人,博士,合肥工业大学副教授,硕士生导师,通信作者,E-mail:Mgj1997@163.com;

黄康(1968—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师。

0 引言

需求预测是指根据需求的历史数据与相关影响因素对未来的需求做出判断的方法,常常是资源规划的起点和基础^[1]。需求预测有驱动业务规划和高效运营的作用,虽然需求预测在各行业中实际应用千差万别,但其中的应用步骤与实践理论大体一致。药品需求预测在人类社会的健康、经济和社会稳定方面都具有不可替代的作用,是需求预测的热点和典型代表。

药品需求预测能够对供应链配置和资源分配进行优化^[2],提高药品供应的效率和准确性,从而更好地保障患者的医疗需求和人身健康,降低药品短缺的风险^[3]。对于药品的生产公司而言,预测出药品的供需关系,有助于减少库存成本、提高企业的销售业绩和利用经济杠杆实现自身收益最大化^[4]。然而现实环境中,对各类药品进行准确的需求预测存在很大困难,其销售情况受到诸多因素的影响,如流行疾病的传播与诊治、临床实验的验证、新兴技术及药品的发展和季节性因素等。

经分析发现,需求变化往往在时间维度上呈现出一定规律^[5],而长短期记忆(long short-term memory, LSTM)网络因其优越的预测性能和普适性常作为时序预测的代表,如使用 LSTM 配合小波降噪^[6]、粒子群优化(particle swarm optimization, PSO)算法优化 LSTM^[7]进行股价预测;变体门控循环单元(gated recurrent unit, GRU)在短期预测上效率最优,如使用卷积神经网络(convolutional neural network, CNN)结合 GRU 的组合模型来预测住宅短期的用电量^[8]。除预测模型组合外,又有学者提出组合时序分解算法,以降低输入模型数据的复杂度,如使用局部加权回归周期趋势分解(seasonal-trend decomposition using LOESS, STL)算法配合 CNN-LSTM 组合模型进行月径流的预测^[9];更进一步,有学者提出时序二次分解,降低预测难度,如文献[10]提出使用自适应噪声完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)算法配合 STL 的二次分解重构策略,进行航空客流量的预测。

综上所述,时序分解结合深度学习综合模型可实现以分解复杂数据的方式完成时序预测任务^[11],但该类模型在药品需求预测方面应用较少,且实际获取的药品长期销售数据具有高波动性和多周期性,准确预测含有噪声的复杂非线性

时间序列仍是一个挑战^[12]。以往的研究者们主要聚焦于分解算法本身和针对不同特征的子序列匹配不同预测算法,在对原始序列特征分析如是否存在多周期特征和数据含噪等方面涉及较少,这可能导致分解算法不匹配和增大预测误差。此外使用多预测模型也会使预测步骤复杂、误差累积明显,从而降低模型的预测精度和普适性。

为充分提取原复杂长时序数据中的时序特征,剔除其中的噪音,本文提出针对含噪时序、适配多周期特征的二次分解重构的通用预测模型,主要贡献如下:

1) 提出对去除异常值后的时序数据使用多周期时间序列分解(multiple seasonal-trend decomposition using LOESS, MSTL)算法^[13],该算法能够充分挖掘其多周期特征,降低分量复杂度并提升模型适配性。

2) 构思一种二次分解降噪的重构策略,使用二次分解来剥离有效数据和含噪数据,然后使用小波降噪(wavelet denoising, WD)进行降噪处理,最后根据分量特征进行分量重构。

3) 本文使用 AVOA-CNN-LSTM 组合模型对各分量进行预测,其中 CNN 模块用于分量的特征提取,而非洲秃鹫优化算法(African vultures optimization algorithm, AVOA)用于对 CNN-LSTM 模型的超参数寻优,从而极大地提升模型的准确性。

1 时序数据分析

1.1 样本熵

样本熵(sample entropy, SE)是具有良好鲁棒性的衡量时序复杂度的指标,其原理是通过衡量经过重建后的时间序列中子向量之间的距离来评估时间序列的复杂性^[14]。对于一个长度为 l 的时间序列,首先需要计算重建子序列中各对应元素之间的绝对值距离,然后根据这些距离值计算概率 $C^n(r)$,最终得出时间序列 $y(t)$ 的样本熵值 S_E ,即

$$S_E(n, r, l) = -\ln[C^{n+1}(r)/C^n(r)] \quad (1)$$

其中: n 为重建时序移动窗口的维度,本文中为 2; r 为宽容度,由 $y(t)$ 标准差 S_D 确定, $r=0.2 \times S_D(y(t))$ 。

1.2 最大信息系数

最大信息系数(maximal information coefficient, MIC)指标是衡量时序间的相关性^[15]。步骤如下:将 2 组变量 $X = \{x_i, i=1, 2, \dots, n\}$ 、 $Y =$

$\{y_i, i=1, 2, \dots, n\}$ 用有序集合 $A=(x, y)$ 表示。在 X, Y 方向上, 以特定方式将 x, y 进行网格化分割, 以确保单元格内存在绝大多数点。通过计算每个单元格中数据点对, 以确定它们之间的关系并计算 MIC 值, 记为 W_{MIC} 。整体公式如下:

$$W_{MIC}(A) = \max_{XY < B(n)} M(A)_{X,Y} = \max_{XY < B(n)} \frac{I(A, X, Y)}{\ln \min(X, Y)} \quad (2)$$

其中: $B(n) = n^\alpha$ 为样本数 n 的函数, n 代表划分的搜索网格上界, α 为本文设定的自定义参数, 取 0.3; $I(A, Y, X)$ 是在 X 和 Y 网格上 A 产生的分布中全部最大互信息。若 W_{MIC} 趋近 1, 则相关性越强; 反之, 越可能为独立变量。

2 双重分解预测模型

本文提出基于 MSTL-CEEMDAN 分解的综合集成模型, 用于分析处理历史数据并进行年度药品需求预测。该模型主要包括二次分解数据处理及重构阶段和模型调整匹配阶段。整体模型结构如图 1 所示。

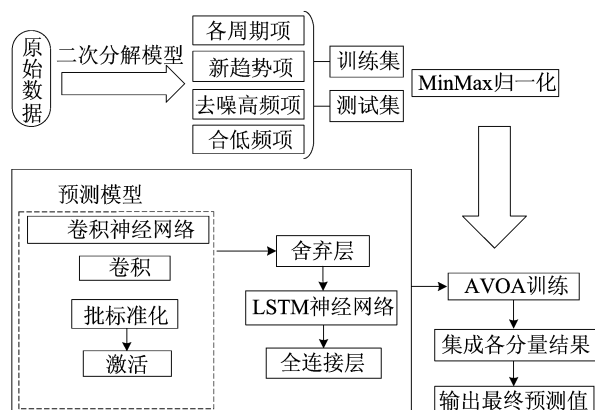


图 1 本文模型整体结构

模型主要步骤归纳如下。

1) 使用箱线图, 去除原序列中的异常值并用零值填充, 再根据最优周期确定输入 MSTL 的参数。

2) 进行 MSTL 分解, 并使用趋势项和周期项对对应位置的零值进行缺失值补偿; 再对一次分解余项使用 CEEMDAN 进行二次分解, 以充分获取有效数据, 得到具有不同频率和振幅的 IMF 分量, 记作 $(IMF_1, IMF_2, \dots, IMF_n)$ 。

3) 分析生成的 IMF_s 数据特征, 对满足特定条件的 IMF 分量进行小波降噪; 在进行相关信息系数的计算后, 选择部分二次分解的分量与趋势

分量进行重构, 同时将低复杂度分量进行合并重构; 最终生成多个季节分量序列、新趋势分量、降噪分量序列与低频冗余分量合并项。

4) 针对不同类别的分量, 使用 AVOA 对 CNN-LSTM 模型进行匹配性超参数调整, 各序列使用各自的最优参数模型进行预测。

5) 分量预测结果集成, 将各分量的预测结果线性相加得到最终的预测值。

2.1 分解模型

目前广泛使用的传统时间序列分解方法有 STL、X-13-ARIMA-SEATS 以及 X-12-ARIMA^[16]。虽然以上方法因稳健性和高效性在现实世界的许多领域中得到广泛的应用, 但这些技术只能处理具有单一季节性的时间序列。

2.1.1 MSTL 算法

MSTL 算法也称多重 STL 分解算法, 是一种全自动的加法时间序列分解算法, 用于处理含有多周期特性的时间序列。该算法分解如下:

$$X_t = S_t^1 + S_t^2 + \dots + S_t^r + T_t + R_t \quad (3)$$

其中: n 为 X_t 中存在的季节周期数; S 为季节序列; T 为趋势序列; R 为余项序列。

具体来说, MSTL 算法首先要确定时间序列中可用的不同季节模式的数量; 为了减少季节性混淆, 需将 MSTL 输入的周期先升序排列, 之后 MSTL 将 STL 算法迭代应用于每个已识别的季节频率; 接着使用 STL 的最后一次迭代计算时间序列的趋势成分, 计算余项时, 从剥离全部周期后的时间序列中减去趋势部分。

MSTL 算法流程如图 2 所示。图 2 中: 初始化迭代次数 $i=0$; $seas[]$ 为周期序列组; $deseas$ 为去周期序列; n 为输入周期数。

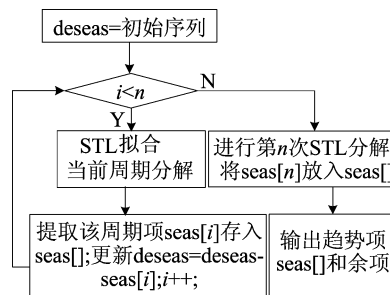


图 2 MSTL 算法分解流程

2.1.2 CEEMDAN 算法

CEEMDAN 算法^[17]通过引入自适应噪声处理、辅助 IMF_s 和集成策略等改进, 提高了信号处理的稳健性与性能, 特别是在处理复杂信号和数

据时表现更为出色。该算法表达式如下:

$$X(t) = \sum_{j=1}^N \frac{1}{M} \sum_{i=1}^M E_j(r_j(t) + \omega_j E_j(\epsilon_i(t))) + R(t) \quad (4)$$

其中: $r_1(t)$ 为 EMD 分解 $Y(t) + \epsilon_0 \omega_i(t)$ 得到的首个 IMF, 即 $r_1(t) = Y(t) - \frac{1}{M} \sum_{i=1}^M E_1(S(t) + \epsilon_0 \omega_i(t))$; 运算符 $E_j(\cdot)$ 表示由 EMD 分解序列得到的第 j 个 IMF。

2.1.3 CEEMDAN 降噪

由于 CEEMDAN 的分解原理和原数据的固有噪音, 数据分解过后会存在含有噪声较多的 IMF 分量, 其一般具有高频与周期出现的特点。可以合理地假设噪声主要存在于高频分量中^[18], 若舍弃该类分量则可能导致丢失其内包含的有效信息。因此, 采用一种综合策略对高频分量进行进一步的小波降噪处理, 以确保高频分量中的低频信息得以保留。

为分析 IMF 的特性, 引用 SE 概念区分高、低频噪声。具体而言, 对每个 IMF 计算其 S_E 值, 以评估其随机性和复杂性; 然后通过设定适当的阈值或标准, 过滤出的低频分量视为干净信号, 剩余的高频分量则被视为噪声信号; 最后对被标记为高频噪声的分量, 通过小波分析的方法进行进一步降噪处理。CEEMDAN 分解降噪的具体步骤如图 3 所示。

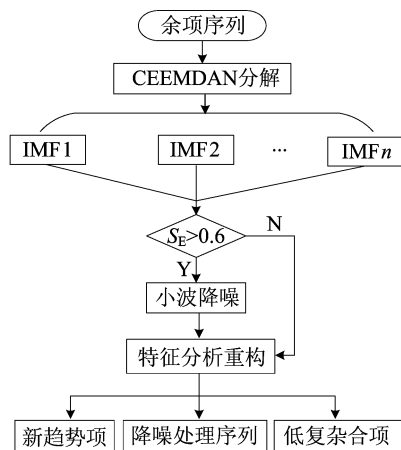


图3 CEEMDAN 分解降噪流程

2.2 预测模型

2.2.1 CNN 网络

卷积层是 CNN 的核心组件, 多用于特征提取。在卷积层之后通常会引入激活函数(如 ReLU、Sigmoid、tanh 等)以引入非线性变换, 从

而使网络能够学习更复杂的特征。

一维卷积常用于处理时间序列或一维结构的数据^[3]。时间序列 x 和卷积核 W 的卷积 y 定义为 $y = W * x$ 。若卷积核长度为 K , 则 t 时刻的卷积结果为:

$$Y_t = \sum_{k=1}^K \omega_k x_{t-k+1} \quad (5)$$

其中: x_{t-k+1} 为 $t-k+1$ 时刻数据; ω_k 为衰减率。

2.2.2 LSTM 网络

相较于传统的循环神经网络(recurrent neural network, RNN), LSTM 网络能够更有效地捕捉和处理序列中的长期关联, 因此在许多序列预测任务中表现卓越^[19-20]。

LSTM 网络的核心思想在于通过一系列门控机制实现信息的传递, 并有效化解 RNN 中的梯度消失问题, 使得该网络能够更有效地挖掘数据中的长期依赖关系。LSTM 网络结构主要包括遗忘门、输入门、输出门以及 1 个内部记忆单元。

设 f, i, o 分别表示遗忘门、输入门和输出门, \odot 表示向量乘法, W, b 表示该网络的权重矩阵和偏执量。

LSTM 的前向传播过程如下。在 t 时刻, x_t, h_t 分别为 LSTM 隐藏层的输入和输出, 记忆单元为 c_t 。输入门控制当前网络流入记忆单元数据 x_t 的大小, 即有多少数据保存到 c_t , 其值计算公式为:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (6)$$

遗忘门在 LSTM 中担当着自连接单元的控制者角色, 它决定历史信息的传递情况, 即 c_{t-1} 中的信息对 c_t 的影响可表示为:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (7)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (8)$$

输出门被用于控制当前记忆单元 c 对当前输出值 h 的影响, 即

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (9)$$

t 时刻 LSTM 单元的 h 由下式得到:

$$h_t = o_t \odot \tanh c_t \quad (10)$$

2.2.3 AVOA 算法

AVOA 与其他元启发式算法的提出过程相似, 主要参考了非洲秃鹫的导航与觅食行为^[21]。AVOA 算法具体流程如下。

1) 选定最佳秃鹫。由秃鹫当前位置计算其适应度, 最好的 2 个秃鹫选为最优和次优, 其余个体将以下式更新位置:

$$L_i(t) = \begin{cases} V_{\text{best1}}, & p < Y; \\ V_{\text{best2}}, & \text{其他} \end{cases} \quad (11)$$

其中: $L_i(t)$ 为其余个体位置; V_{best1} 、 V_{best2} 分别为最优和次优个体位置; Y 为 $[0, 1]$ 区间的给定参数; p 为 $[0, 1]$ 区间随机数; t 为目前迭代轮数。

2) 个体饱食率。秃鹫需要频繁觅食, 增大觅食空间需要提高饱食率, 反之则飞行距离降低, 同时可能会避免与更强壮的个体竞争食物。饱食率公式描述如下:

$$P_i(t+1) = \begin{cases} L_i(t) - [XL_i(t) - P_i(t)]F, & K_1 \geq r_{P_1}; \\ L_i(t) - F + r_2[(u_b - l_b)r_3 + l_b], & K_1 < r_{P_1} \end{cases} \quad (14)$$

其中: $P_i(t+1)$ 、 $P_i(t)$ 分别为第 $t+1$ 次、第 t 次迭代个体位置; X 为秃鹫保护食物随机移动的位置, $X=2r$; r 、 r_2 、 r_3 、 r_{P_1} 分别为 $[0, 1]$ 区间随机数; K_1 为探索参数; u_b 、 l_b 分别为探索空间的上、下界。

$$P_i(t+1) = \begin{cases} [XR_i(t) - P_i(t)](F + r_4) - [R_i(t) - P_i(t)], & K_2 \geq r_{P_2}; \\ R_i(t) - \left[R_i(t) \frac{r_5 P_i(t)}{2\pi} \cos P_i(t) + \frac{r_6 P_i(t)}{2\pi} \sin P_i(t) \right], & K_2 < r_{P_2} \end{cases} \quad (15)$$

$$P_i(t+1) = \begin{cases} \frac{F}{2}[(V_{\text{best1}}(t) - R_1) + (V_{\text{best2}}(t) - R_2)], & K_3 \geq r_{P_3}; \\ L_i(t) - |L_i(t) - P_i(t)| F \text{Levy}(d), & K_3 < r_{P_3} \end{cases} \quad (16)$$

其中: $R_n = V_{\text{bestn}}(t)P_i(t)/[V_{\text{bestn}}(t) - P_i(t)^2]$, $n=1, 2$; $\text{Levy}(d)$ 为随机游走, 其每一步的方向完全随机且各向同性, 步长为重尾分布。

3 实验与结果分析

3.1 数据描述

本文使用的实验数据来自于 Kaggle 的公开数据集, 从数据集中将药品按照解剖治疗化学分类系统进行分类, 统计了 2014—2019 年 8 个类别的销售数据。本研究将对‘N02BE’-阵痛解热类药物的销售量进行建模预测。以 2014—2017 年的销售数据作为训练集, 2018 年全年数据作为测试集进行模型对比消融实验。此外, 还对‘N05B’-精神安定类药品与‘R06’-全身用抗组胺药进行预测, 以验证模型的通用性。

3.2 评价准则

本文采用均方根误差(root mean square error, RMSE) E_r 、平均绝对百分比误差(mean absolute percentage error, MAPE) E_m 、标准化均方根误差(normalized root mean square error, NRMSE) E_n 以及决定系数 R^2 作为评价指标, 旨在从不同角度对模型的预测性能进行评估。其中: E_r 、 E_m 、 E_n 越小, 表明预测值越接近真实值,

$$u = h \left[\sin\left(\omega \frac{t}{2T}\pi\right) + \cos\left(\frac{t}{2T}\pi\right) - 1 \right] \quad (12)$$

$$F = (2r_1 + 1)z \left(1 - \frac{t}{T}\right) + u \quad (13)$$

其中: F 为个体饱食率; z 为 $[-1, 1]$ 区间随机数; h 为 $[-2, 2]$ 区间随机数; ω 为用户定义的勘察参数, 该值控制进入探索阶段的概率。

3) 探索阶段。视野广阔的秃鹫觅食能力强, AVOA 算法通过下式选择不同的探索区域:

4) 开发阶段。在 AVOA 算法中, 开发阶段存在 2 种开发策略, 分别为第 1 开发阶段、第 2 开发阶段的开发策略。参数 K_2 、 K_3 决定使用某种策略更新个体位置。2 个阶段个体位置的更新公式如下:

模型的预测精度与准确性越高; R^2 越接近 1, 则表明模型的拟合程度越高。

评价指标公式如下:

$$E_r = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \hat{X}_i)^2} \quad (17)$$

$$E_m = \frac{1}{n} \sum_{i=1}^n \frac{|X_i - \hat{X}_i|}{X_i} \times 100\% \quad (18)$$

$$E_n = \frac{E_r}{\max(X) - \min(X)} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - \hat{X}_i)^2}{\sum_{i=1}^m (X_i - \bar{X})^2} \quad (20)$$

3.3 N02BE 实例

3.3.1 基于 MSTL-CEEMDAN 的时序处理

输入该分解模型的 N02BE 药品销售数据, 首先用箱线图进行异常值剔除, 然后采用 MSTL 提取数据的各周期项、趋势项和余项, 分解结果如图 4 所示。

从图 4 可以看出: 2 个季节分量的波动规律极为明显, 而趋势项波动清晰平缓, 且都能够很好地反映药品销量的时序特性; 但余项波动复杂, 其受各种不确定因素的影响且包含噪音, 无明显规律。




图 4 N02BE 的 MSTL 分解结果

为充分提取出余项中的有效数据,利用 CEEMDAN 对余项进行二次分解,得到不同振幅和频率的 7 个 IMF 分量,结果如图 5 所示。




图 5 CEEMDAN 对余项的二次分解结果

分别计算各分量的 S_E 值,并分析其复杂程度。显然,分量的复杂程度随频率的升高而增加,依照 CEEMDAN 降噪思想,对 $S_E > 0.6$ 的高频项使用小波降噪,对比结果如图 6 所示。为了对比清晰,图 6 的图例中只包含测试集结果。

计算处理后的各干净分量(使用 N 开头加以说明)与原趋势项的相关度 MIC。各分量时序特

征见表 1 所列,结果表明余项中包含了部分未充分提取的趋势变化信息。

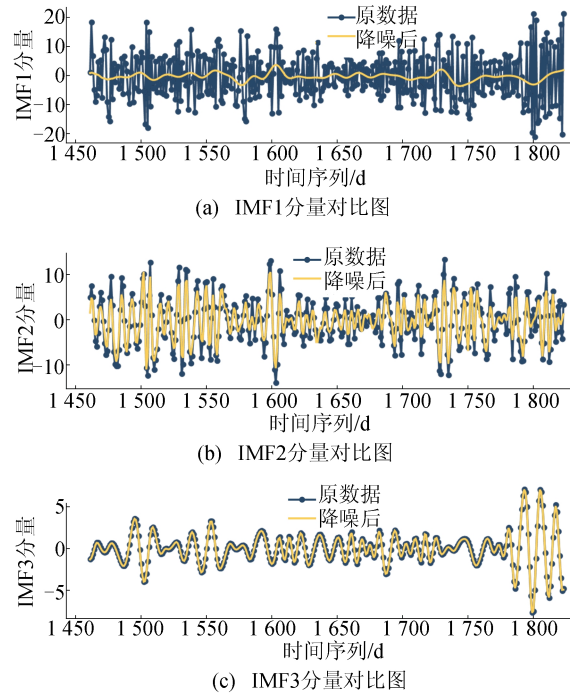


图 6 高频项小波降噪

表 1 各分量时序特征

分量	W_{MIC}	S_E
IMF1	0.064 1	1.15
IMF2	0.057 3	1.05
IMF3	0.033 4	0.65
IMF4	0.040 7	0.52
IMF5	0.063 1	0.41
IMF6	0.050 5	0.18
IMF7	0.138 6	0.04
NIMF1	0.065 3	0.48
NIMF2	0.055 1	0.83
NIMF3	0.033 3	0.65

根据上述各分量的特征分析,同时考虑误差累积和计算成本,本文依据 S_E 与 MIC 对分量进行重构。具体地,将 $W_{MIC} > 0.065$ 且 $S_E < 0.6$ 的 IMF7 与降噪后的 NIMF1 分量和原趋势分量重构成新趋势量,将 IMF 中 $S_E < 0.5$ 的分量组合成低熵分量。

3.3.2 各模型参数及超参数的确定

在对原序列特征分析时,使用快速傅里叶变换与自相关函数获取理论最优周期,联合经验周期一起形成可能周期组,最后使用先验周期对各周期进行判断,得到输入 MSTL 的周期为 3 和 6。对于输入预测模型窗口大小的确定,则通过网格化搜索和手动调整获取最优值;CNN-LSTM 的

超参数包括起始学习率、投入批次大小、隐藏层单元数、隐藏层数(通过 AVOA 进行寻优确定)。此外,为提高模型的训练精度和速度,避免过拟合,使用动态学习率、早停设置。

3.3.3 预测结果与消融实验

本文将分解后各分量统一使用 CNN-LSTM 组合模型进行预测,根据不同分量的特征对模型

进行参数调整。

各分量对 N02BE 的预测结果以及与实际数据的对比如图 7 所示。

图 7 中: NIMF1 与 NIMF2 为降噪后的对应 IMF 分量; NIMF4 为低熵 IMF 分量组合后的重构分量; NIMF 则为剩余 IMF 的组合重构。




图 7 N02BE 的预测结果

为验证本文提出的综合模型的有效性和精确性,进行消融实验并与其他预测模型对比分析,结果如图 8 所示(注:为能够清晰显示各模型的预测效果,以 4 月结果为例,使用首字母缩写表示模型成分)。通过 STL 替换 MSTL,探究多周期分解与单周期分解的性能,结果见表 2 所列。

从表 2 可以看出各个模块对综合性能提升的影响,其中 MSTL 算法的引入对综合模型的预测性能提升最大,而对于复杂时序而言,多周期分解的性能优于单周期分解。由表 2 可知,相较于其他模型,本文提出的综合模型预测性能最优,与真实值的拟合程度最好。

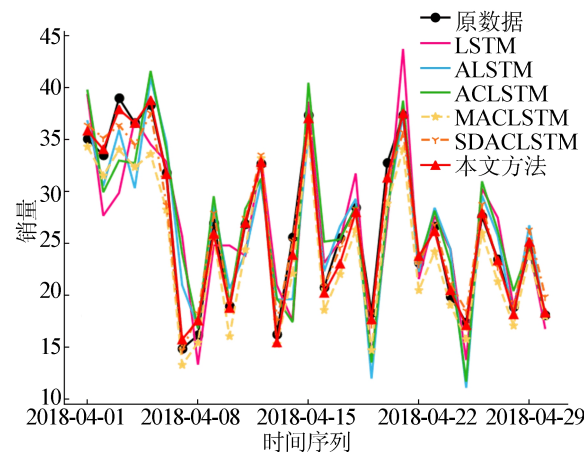


图 8 不同模型的对比

表 2 不同模型的预测性能评价

模型	E_r	E_m	E_n	R^2
LSTM	5.179 9	0.146 1	0.124 6	0.691 2
ALSTM	5.232 7	0.160 3	0.109 3	0.719 5
ACLSTM	5.063 6	0.152 1	0.096 4	0.762 0
MACLSTM	3.040 3	0.094 8	0.064 0	0.903 2
SDACLSTM	1.938 9	0.055 8	0.039 4	0.961 0
本文方法	1.317 7	0.037 2	0.024 9	0.985 5

3.4 N05B 和 R06 药品实例

为展现本文综合模型的普适性,将对该数据集中的 N05B 和 R06 类别药品进行需求预测,结果如图 9 所示。

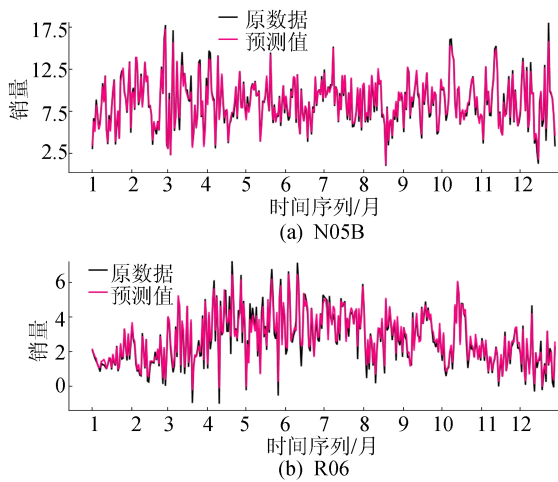


图 9 N05B 与 R06 的预测效果

本文模型对 N05B 和 R06 预测性能的评价指标见表 3 所列。

表 3 对 N05B 和 R06 的预测性能评价

药品	E_r	E_m	E_n	R^2
N05B	0.437 3	0.043 4	0.025 7	0.976 7
R06	0.314 6	0.307 7	0.038 1	0.957 1

4 结 论

提升药品的易得性是健全医疗卫生体系的基石,满足百姓的健康需求、对有限的物资进行合理化配置都离不开完备的医疗用品供应链,而供应链中最薄弱的环节之一是对药品的需求预测^[22]。因此研究药品的历史销量,产生相应的备货决策具有重要意义。

本文根据印度某城市某几种药品的销售情况作为药品供应的依据,对其未来一年的销售数据量进行了预测。

首先,针对药品销售数据的特征,使用 MSTL 算法进行了多周期分解,结果表明药品的销售存在周期特征,而高熵 IMF 小波降噪前、后的数据对比也在一定程度上验证了高频项中存在噪音的假设;然后,通过消融实验探究组合模型中各个模块的有效性,结果表明 MSTL 分解对模型的预测性能提升最大;最后,对同数据集中的 R06 与 N05B 类别药品进行实验,验证了本文预测模型的通用性。

综上所述,使用本文模型在进行药品的长期需求预测方面取得了不错的效果,可为社会医药资源配置提供参考,为企业家提供生产、运输与销售的策略依据,帮助经销商合理备货,从上而下的保障老百姓的药品需求。

[参 考 文 献]

[1] NIA A R, AWASTHI A, BHUIYAN N. Industry 4.0 and demand forecasting of the energy supply chain: a literature review [J]. Computers & Industrial Engineering, 2021, 154:107128.

[2] ZHU X, NINH A, ZHAO H, et al. Demand forecasting with supply-chain information and machine learning: evidence in the pharmaceutical industry[J]. Production and Operations Management, 2021, 30(9): 3231-3252.

[3] 王平根,梁月兰,罗文龙,等. 海南省应急药品储备信息系统的研究[J]. 中国卫生统计, 2017, 34(3): 472-473, 476.

[4] 吴璐,郭强,聂佳佳,等. 预测信息分享对药品双渠道供应链集团采购策略的影响[J]. 中国管理科学, 2023, 31(10): 276-286.

[5] BI J W, LI H, FAN Z P. Tourism demand forecasting with time series imaging: a deep learning model[J]. Annals of Tourism Research, 2021, 90: 103255.

[6] 彭燕,刘宇红,张荣芬. 基于 LSTM 的股票价格预测建模与分析[J]. 计算机工程与应用, 2019, 55(11): 209-212.

[7] 宋刚,张云峰,包芳勋,等. 基于粒子群优化 LSTM 的股票预测模型[J]. 北京航空航天大学学报, 2019, 45(12): 2533-2542.

[8] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN-GRU-based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 8: 143759-143768.

[9] 雷庆文,高培强,李建林. 时序分解和 CNN-LSTM 相融合的月径流预报模型[J]. 长江科学院院报, 2023, 40(6): 49-54.

[10] 栗慧琳,李洪涛,李智. 基于二次分解重构策略的航空客流需求预测[J]. 计算机应用, 2022, 42(12): 3931-3940.

[11] 董雪,赵宏伟,赵生校,等. 基于二次分解和多目标优化的超短期海上风电功率预测[J]. 高电压技术, 2022, 48(8): 3260-3270.

- [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]:IEEE,2022;5470-5479.
- [8] LIU L, GU J, ZAW L K, et al. Neural spars voxel fields[J]. Advances in Neural Information Processing Systems, 2020, 33:15651-15663.
- [9] WANG P, LIU L, LIU Y, et al. Neus: learning neural implicit surfaces by volume rendering for multi-view reconstruction[J]. Advances in Neural Information Processing Systems, 2021, 34:27171-27183.
- [10] FRIDOVICH S, YU A, TANCIK M, et al. Plenoxels: radiance fields without neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]:IEEE,2022;5501-5510.
- [11] SUN C, SUN M, CHEN T, et al. Improved direct voxel grid optimization for radiance fields reconstruction[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]:IEEE,2022;5449-5459.
- [12] GUI P, LI B, TANG T, et al. An improved tri-linear interpolation method for hybrid overset grids and its application [C]//The Proceedings of the 2018 Asia-Pacific International Symposium on Aerospace Technology. Singapore: Springer,2019;601-613.
- [13] MÜLLER T, EVANS A, SCHIED C, et al. Instant neural graphics primitives with a multiresolution hash encoding [J]. ACM Transactions on Graphics, 2022, 41(4):1-15.
- [14] WEGHORST H, HOOPER G, GREENBERG D P. Improved computational methods for ray tracing[J]. ACM Transactions on Graphics (TOG), 1984, 3(1):52-69.
- [15] LIN M, JI R, WANG Y, et al. Hrank: filter pruning using high-rank feature map[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]:IEEE,2020;1529-1538.
- [16] FISHER A, CANNIZZARO R, COCHRANE M, et al. Colmap: a memory-efficient occupancy grid mapping framework[J]. Robotics and Autonomous Systems, 2021, 142:103755.

(责任编辑 胡亚敏)

(上接第 455 页)

- [12] PROIETTI T, PEDREGAL D J. Seasonality in high frequency time series[J]. Econometrics and Statistics, 2023, 27:62-82.
- [13] BANDARA K, HYNDMAN R J, BERGMEIR C. MSTL: a seasonal-trend decomposition algorithm for time series with multiple seasonal patterns[PP/OL]. arXiv (2021-07-28). <https://doi.org/10.48550/arXiv.2107.13462>.
- [14] WU Q, LIN H. Daily urban air quality index forecasting based on variational mode decomposition, sample entropy and LSTM neural network[J]. Sustainable Cities and Society, 2019, 50:101657.
- [15] GUO Z, YU B, HAO M, et al. A novel hybrid method for flight departure delay prediction using random forest regression and maximal information coefficient [J]. Aerospace Science and Technology, 2021, 116:106822.
- [16] 杨贵军, 李晓霞, 孙玲莉. Prophet-X-12-ARIMA 组合模型及交通运输量预测[J]. 统计与决策, 2023, 39(4):29-34.
- [17] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). [S. l.]:IEEE,2011;4144-4147.
- [18] 汤俊, 李垠健, 高鑫. 基于 CEEMDAN 的 GNSS 变形监测去噪方法 [J]. 大地测量与地球动力学, 2021, 41(4):408-412.
- [19] YU Y, SI X, HU C, et al. A review of recurrent neural networks; LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7):1235-1270.
- [20] 刘晴晴, 陈华友. 基于赋权 KNN-LSTM 模型的 PM_{2.5} 质量浓度预测 [J]. 合肥工业大学学报(自然科学版), 2021, 44(12):1690-1698.
- [21] ABDOLLAHZADEH B, GHAREHCHOPOGH F S, MIRJALILI S. African vultures optimization algorithm; a new nature-inspired metaheuristic algorithm for global optimization problems[J]. Computers & Industrial Engineering, 2021, 158:107408.
- [22] SIDDIQUI R, AZMAT M, AHMED S, et al. A hybrid demand forecasting model for greater forecasting accuracy: the case of the pharmaceutical industry[J]. Supply Chain Forum; An International Journal, 2022, 23(2):124-134.

(责任编辑 胡亚敏)