

控制与决策

Control and Decision

融合结构化信息与时序演化信息的多变量间歇性时间序列预测

范黎林, 杨凯, 毛文涛, 罗铁军, 刘洋硕, 刘侠

引用本文:

范黎林, 杨凯, 毛文涛, 罗铁军, 刘洋硕, 刘侠. 融合结构化信息与时序演化信息的多变量间歇性时间序列预测[J]. *控制与决策*, 2024, 39(1): 263–270.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0768>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer
控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

一种基于深度学习的时间序列预测方法

A time series prediction method based on deep learning
控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于小波变换与差分变异BSO–BP算法的大坝变形预测

Dam deformation prediction based on wavelet transform and differential mutation BSO–BP algorithm
控制与决策. 2021, 36(7): 1611–1618 <https://doi.org/10.13195/j.kzyjc.2019.1431>

一种基于池计算的宽度学习系统

A broad learning system based on reservoir computing
控制与决策. 2021, 36(9): 2203–2210 <https://doi.org/10.13195/j.kzyjc.2019.1729>

基于云模型的煤矿安全大数据多粒度表示方法及应用

Multi-granularity representation method of big data in coal mine safety based on cloud model and its application
控制与决策. 2021, 36(10): 2359–2368 <https://doi.org/10.13195/j.kzyjc.2020.0325>

融合结构化信息与时序演化信息的 多变量间歇性时间序列预测

范黎林^{1,3}, 杨凯¹, 毛文涛^{1,3†}, 罗铁军², 刘洋硕¹, 刘侠¹

(1. 河南师范大学 计算机与信息工程学院, 河南 新乡 453007; 2. 株洲中车时代电气股份有限公司, 湖南 株洲 412000; 3. “智慧商务与物联网技术”河南省工程实验室, 河南 新乡 453007)

摘要: 复杂装备制造企业的售后配件需求不定时发生、需求波动大, 导致需求数据呈现典型的间歇性、小样本特点。当面对间歇性程度高、突发需求较大的序列时, 现有预测模型难以准确捕获其需求波动规律, 无法有效预测配件需求走势。为提高多组配件的预测精度和稳定性, 同时考虑序列间结构化信息和序列自身时序演化信息, 提出一种新的多变量间歇性时间序列预测方法。首先, 提出一种基于张量的轻型梯度提升机模型, 通过张量分解, 重构原始需求数据, 修正序列中的异常需求值, 并利用轻型梯度提升机对多组序列进行联合预测; 然后, 构建一种新的线性衰减修正模型, 将修正因子引入线性衰减指数平滑方法, 对每条序列分别预测需求量和间隔区间; 最后, 将 2 个预测模型进行加权融合, 得到最终预测结果。分别在 2 个复杂装备制造企业的售后配件需求数据集上进行实验验证, 实验结果表明, 与多个时间序列预测算法相比, 所提出方法能够有效预测需求波动趋势, 提升预测精度和数值稳定性。

关键词: 间歇性序列; 需求预测; 时间序列预测; 结构化信息; 时序信息; 配件管理

中图分类号: TP181

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0768

引用格式: 范黎林, 杨凯, 毛文涛, 等. 融合结构化信息与时序演化信息的多变量间歇性时间序列预测[J]. 控制与决策, 2024, 39(1): 263-270.

Multivariate intermittent time series forecasting with fusion of structured information and temporal evolution information

FAN Li-lin^{1,3†}, YANG Kai¹, MAO Wen-tao^{1,3†}, LUO Tie-jun², LIU Yang-shuo¹, LIU Xia¹

(1. School of Computer and Information Engineering, Henan Normal University, Xinxiang 453007, China; 2. Zhuzhou China Railway Rolling Stock Corporation Company Limited, Zhuzhou 412000, China; 3. Engineering Lab of Intelligence Business & Internet of Things, Henan Province, Xinxiang 453007, China)

Abstract: After-sale accessory demand of complex equipment manufacturing enterprises tends to occur irregularly and fluctuates greatly, which leads to typical intermittent and small sample characteristics of demand data. When facing the series with high intermittence and large sudden demand, the existing prediction models are difficult to accurately capture the demand fluctuation rule and can not effectively predict the trend of parts demand. In order to improve the prediction accuracy and stability of multi-group parts, this paper proposes a new multivariate intermittent time series forecasting method by considering both structured information between sequences and time series evolution information. Firstly, a tensor-based light gradient boosting machine model is proposed, the original demand data is reconstructed through tensor decomposition to correct abnormal demand values in the sequences, and use the light gradient boosting machine to jointly predict multiple sequences. Then, a new linear decay correction model is constructed, and a correction factor is introduced into the linear decay exponential smoothing method to predict the demand and interval respectively for each sequence. Finally, the two prediction models are weighted and fused to obtain the final prediction results. Experimental validation is conducted on two complex equipment manufacturing enterprises' aftermarket parts demand datasets respectively, and the results show that, compared with several time series forecasting algorithms, the proposed method can effectively predict the demand fluctuation trend and improve the prediction accuracy and numerical stability.

Keywords: intermittent demand; demand forecasting; time series forecasting; structured information; temporal information; accessory management

收稿日期: 2022-05-05; 录用日期: 2022-09-03.

基金项目: 国家重点研发计划专项项目(2018YFB1701400); 河南省科技攻关项目(212102210103).

责任编辑: 阳春华.

†通讯作者. E-mail: maowt@htu.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

0 引言

配件需求预测是实现配件准确备货和库存安全管理的重要手段,在汽车制造、航空航天和军事等复杂装备制造企业的生产活动中占据重要地位.准确的配件需求预测是制订备货策略、降低库存呆滞、提高现货满足率的必要前提.经过企业实地调研以及对真实应用场景下获取的需求数据进行分析发现,现有配件大多呈需求量少、需求分布稀疏且变化大的特点,导致对应的需求序列呈现明显的间歇性和小样本性,难以利用其波动规律进行有效预测.如何准确捕获此类配件需求演化规律,有效预测配件需求走势,是企业多级配件管理所面临的迫切问题,具有重要的研究价值.

目前的配件需求预测方法主要基于时间序列预测模型.常用的时间序列预测方法有指数平滑^[1]、移动平均^[2]等统计学方法和支持向量回归(support vector regression, SVR)^[3]、随机森林(random forests, RF)^[4]等浅层机器学习模型和长短时记忆网络(long short-term memory, LSTM)^[5]、深度自回归循环神经网络(deep auto-regressive recurrent network, DeepAR)^[6]等深度学习模型,但是上述方法对数据依赖性强,不适用于间歇性强、分布稀疏零散的小样本数据.不同于周期性时间序列或混沌时间序列,间歇性时间序列本身数据量小,且具有间歇性或块状分布特点,因此从有限数据中提取时序演化信息成为间歇性序列预测的关键.作为代表性算法之一, Croston^[1]通过将原始序列分为需求量序列和间隔区间序列,并使用指数平滑方法分别对上述两类序列进行预测,最后对结果进行组合得到最终预测需求量; Syntetos 等^[7]提出了 SBA (Syntetos-Boylan approximation)方法,通过在原 Croston 公式基础上添加修正因子,以纠正预测偏差.但是,上述两种方法只考虑到了需求为正时的需求量和需求区间的更新,忽略了需求过时问题对于预测结果造成的影响.为解决该问题, Teunter 等^[8]提出了 TSB (Teunter-Syntetos-Babai)方法,通过更新需求概率的方式解决过时需求; Prestwich 等^[9]提出了 ESLD (exponential smoothing with linear decay)方法,通过线性衰减需求量以解决过时需求; Tian 等^[10]提出了一种马尔可夫组合方法,该方法结合历史销售数据与库存状态,先计算需求和库存的状态转移概率,根据预测状态动态选择预测算法,实现对在线零售商品需求的预测.然而,上述方法的基础模型是指数平滑,受临近数值影响较大,无法利用配件序列的季节、同期值等周期规

律.对于多变量时间序列预测问题, Shi 等^[11]提出了一种多元时间序列预测方法(block hanker tensor-autoregressive integrated moving average, BHT-ARIMA),该方法通过张量分解提取多条配件需求序列间的结构化信息,进而使用张量化的 (autoregressive integrated moving average, ARIMA)算法实现对多条电脑配件需求序列的联合预测.尽管该方法利用了多配件间的演化信息,但是易受0值和异常需求点的干扰,并不完全适用于数据稀疏、波动大的间歇性序列.

考虑到制造企业往往实行整套备货计划,多组配件间往往具有内在相关性;而对于实际制造企业的间歇性需求序列而言,异常值常由人工经验不足或环境突变等产生,由于序列本身数据量有限,即使少量的异常值也易对演化信息的提取产生较大的负面影响.综上可知,提高间歇性序列预测效果的关键在于:1)如何综合利用多变量序列间的内在演化信息,提高模型预测的准确率和稳定性;2)如何有效处理序列中的异常需求和过时需求,减少其对模型的干扰.针对以上两点,本文同时考虑序列自身周期性特征和多序列间的结构化信息,提出一种新的多变量间歇性时间序列预测方法.首先,提出一种基于张量的轻型梯度提升机模型,利用张量分解对原始数据进行重构,实现对异常需求值的修正,并引入轻型梯度提升机(light gradient boosting machine, LightGBM)进行多配件联合预测;然后,构建一种新的线性衰减修正模型,将修正因子引入线性衰减指数平滑方法,在解决过时需求的基础上减少模型预测偏差;最后,为有效利用多维度序列信息,将上述2个模型加权融合.分别在具有间歇性特点的2个复杂装备制造企业的售后配件需求数据集上进行实验,实验结果验证了所提出方法的可行性和有效性.

本文在于构建一种鲁棒的间歇性序列联合预测方法,可同时提取并融合多序列间的结构化信息和序列自身的时序演化信息,有效挖掘序列中蕴含的演化机理信息,克服了传统单一预测模型无法准确捕获间歇性序列演化规律的局限,提高了模型预测的稳定性.同时从“纵向”和“横向”2个角度进行间歇性序列演化信息提取,这在现有研究中鲜有类似研究.

1 相关理论

1.1 Tucker分解

一维数组称为向量,二维数组称为矩阵,三维及以上数组称为张量. Tucker分解是一种高阶的主成分分析,其将一个张量表示为一个核心(core)张

量沿每个 mode 乘以一个矩阵. 分解时将 N 阶张量 $X \in R^{I_1 \times I_2 \times \dots \times I_n \times \dots \times I_N}$ 分解为一个核心张量 $G \in R^{J_1 \times J_2 \times \dots \times J_n \times \dots \times J_N}$ 与 N 个因子矩阵 $U^{(n)} \in R^{I_n \times J_n}$ 的 n -mode 乘积^[12], 如下式所示:

$$X = G \times_1 U^{(1)} \times_2 U^{(2)} \times \dots \times_N U^{(N)}. \quad (1)$$

1.2 Croston 系列模型

Croston 是处理间歇性需求的经典方法, 其将原始序列分解为需求量序列 y 和间隔区间序列 p , 使用指数平滑得到下一时间点的预测值, 计算公式如下式所示:

$$f_t = \frac{\hat{y}_t}{\hat{p}_t}; \quad (2)$$

$$\begin{cases} \hat{y}_t = \alpha y_{t-1} + (1 - \alpha)\hat{y}_{t-1}, \\ \hat{p}_t = \alpha p_{t-1} + (1 - \alpha)\hat{p}_{t-1}, \\ y_{t-1} > 0; \end{cases} \quad (3)$$

$$\begin{cases} \hat{y}_t = \hat{y}_{t-1}, \\ \hat{p}_t = \hat{p}_{t-1}, \\ y_{t-1} = 0. \end{cases} \quad (4)$$

其中: α 为平滑因子, f_t 为 t 时刻预测值, y_t 为在 t 时刻的需求量实际值, \hat{y}_t 为在 t 时刻的需求量预测值, p_t 为在 t 时刻的间隔区间实际值, \hat{p}_t 为在 t 时刻的间隔区间预测值.

Syntetos 和 Boylan 证明 Croston 方法在间歇性需求方面存在偏差, 将式(2)修改为下式, 将该变体称为 SBA:

$$f_t = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{y}_t}{\hat{p}_t}. \quad (5)$$

Croston 和 SBA 仅在需求发生时才会更新预测值, 不能应对过时需求问题. 因此, Prestwich 等^[9] 提出了 ESLD 模型, 将式(2)修改为下式, 通过线性衰减需求量以解决过时问题:

$$f_t = \begin{cases} \hat{y}_t / \hat{p}_t, & y_{t-1} > 0; \\ (\hat{y}_t / \hat{p}_t)(1 - \alpha p_{t-1} / 2\hat{p}_t)^+, & y_{t-1} = 0. \end{cases} \quad (6)$$

其中 x^+ 为取 $0 \sim x$ 间的最大值.

1.3 间歇性特征

平均需求间隔 (average demand interval, ADI) 和变异系数 (coefficient of variation, CV^2) 是目前常用的两种表示间歇性需求的特征指标^[13]. 计算公式如下式所示:

$$ADI = \frac{Per}{Occ}, \quad CV^2 = \left(\frac{\sigma}{\mu}\right)^2.$$

其中: Per 为总周期数, Occ 为需求发生次数, σ 为历史非 0 需求的标准差, μ 为历史非 0 需求的平均值.

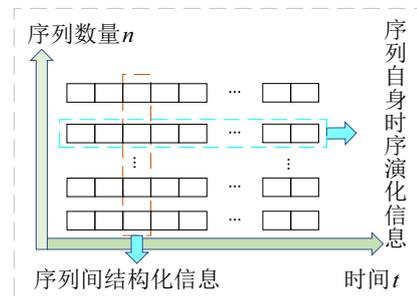
基于 ADI 和 CV^2 这 2 个指标, 可将需求概况分为

4 个不同的类型.

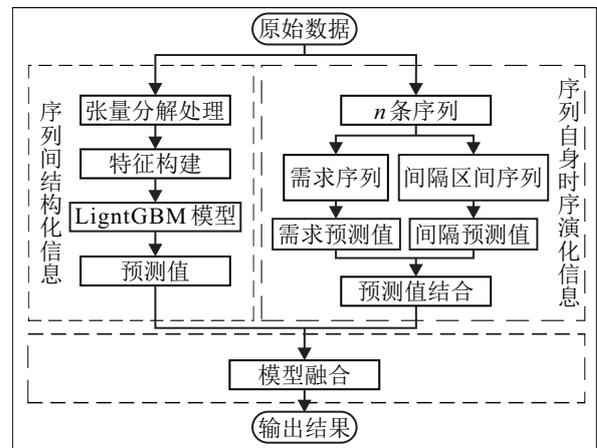
- 1) $ADI < 1.32, CV^2 < 0.49$ (平稳需求).
- 2) $ADI \geq 1.32, CV^2 < 0.49$ (间歇需求).
- 3) $ADI \geq 1.32, CV^2 \geq 0.49$ (块状需求).
- 4) $ADI < 1.32, CV^2 \geq 0.49$ (不稳定需求).

2 融合结构化信息的多变量间歇性时间序列预测方法

本文提出一种新的多变量间歇性时间序列预测方法, 综合考虑序列间结构化信息和序列自身时序演化信息, 主要分为基于张量的轻型梯度提升机模型的构建、线性衰减修正模型的构建和模型融合 3 部分. 该方法如图 1 所示.



(a) 序列信息示意图



(b) 流程

图 1 本文方法

2.1 基于张量的轻型梯度提升机模型

对于一个制造企业而言, 其配件需求间存在一定的内在联系. 因此, 可利用多序列之间的演化规律信息提升整体预测效果^[14]. 同时, 人工经验不足或环境突变等易导致配件需求数据发生异常变化. 因此, 本节首先使用张量分解对原始需求数据进行数据重构, 实现对异常数据的修正; 然后根据修正后的数据构建特征数据; 最后将特征数据代入 LightGBM 模型对多组序列进行联合预测.

本文先使用多路延时嵌入变换 (multi-way delay embedding transform, MDT) 将多条短小的需求序列

(A^T 为 T 时刻的所有序列值)沿着时间维度转换为三阶数据 X^T , 变换后的张量更平稳, 利于学习序列间的结构化信息^[11]. 其过程如下式所示:

$$H_t(X) = \text{fold}_{(l,t)}(X \times_1 S_1 \times \dots \times_l S_l). \quad (7)$$

使用 Tucker 分解对转换后的三阶张量进行信息重构, 其基本思想是通过不断逼近实际值从而实现信息重构, 即在给定核心张量 (G) 秩的情况下最小化原始张量 (X_H) 与重构张量 (\hat{X}_H) 误差的 F 范数, 相应的优化目标函数如下式所示:

$$\max \|X_H \times_1 U^{(1)T} \times_2 U^{(2)T} \times_3 U^{(3)T}\|. \quad (8)$$

Tucker 分解的过程需要一组共用的映射矩阵, 现有张量模型会对各维度方向的映射矩阵施加约束, 为了更好地捕捉序列间的演化规律, 本文不在时间维度加正交约束, 保持其他维度的正交约束^[11]. 使用 HOOI (higher order orthogonal iteration) 和 HOSVD (higher order singular value decomposition) 对式 (8) 进行求解, 求解过程见文献 [11], 并利用网格搜索在张量秩的集合寻找最优秩^[12].

使用 MDT 逆变换将重构后的三阶张量转换为原始数据空间的二维数据, 从而实现对异常需求数据的修正, MDT 逆变换如下式所示:

$$\begin{aligned} H_t^{-1}(\hat{X}) &= \text{unfold}_{(l,t)}(\hat{X}) \times_1 S_1^\dagger \times \dots \times_l S_l^\dagger, \\ \text{unfold}_{(l,t)} &= \text{fold}_{(l,t)}^{-1}. \end{aligned} \quad (9)$$

通过上述方法实现对异常需求值的修正, 减少其对预测模型的干扰. 同时, 考虑到小样本情况下间歇性序列信息量较少, 为提高预测效果, 有必要从原始序列中进一步提取特征工程数据. 需要说明的是, 所提出特征仅与原始序列特征有关, 与应用问题无关.

本节选用 LightGBM 作为训练模型, 该模型由微软亚洲研究院于 2017 年开发, 是一种基于决策树算法的分布式梯度提升框架. 其基本思想是通过 K 棵弱回归树线性组合为强回归树, 如下式所示:

$$\hat{y}_i = \sum_{t=1}^k f_t(x_i). \quad (10)$$

其中: f_k 为第 k 个弱回归树的预测值, \hat{y}_i 为第 i 个样本的预测值. 该模型具有训练速度快、准确率高等优点.

将特征工程得到的数据作为输入, 待预测月份的需求量作为输出. 通过利用多条序列间的结构化信息, 同时对多个需求序列进行联合预测.

2.2 线性衰减修正模型

在企业实际生产过程中, 当产品配件面临更新换代时, 其需求数量随着时间的推移而下降至 0, 这种现象称为需求过时, 且此类情况出现较多, 因此在预测

过程中须加以考虑^[15].

本节从序列自身时序演化信息入手, 提出一种新的 Croston 变体方法. 当需求不发生时, 使用 ESLD 的线性衰减公式对需求量进行更新, 以处理过时需求; 当需求发生时, 引入 SBA 的修正因子对需求量进行更新, 以减少预测偏差.

首先, 利用下式表示原始数据中的单条序列:

$$\begin{aligned} \text{ori} &= \{y_0, 0, \dots, 0, y_1, 0, \dots, 0, y_i, 0, \dots, 0, y_t\}, \\ y_i &\in \{1, 2, \dots, m\}. \end{aligned} \quad (11)$$

其中 y_i 为 i 时刻的需求量 ($y_i > 0$).

间隔区间定义为 2 个非 0 需求 y_i 与 y_{i+1} 间的周期数, 如 y_i 与 y_{i+1} 间有 a 个 0 值, 则相应的间隔区间为

$$p_{i+1} = a + 1, \quad i \in \{0, 1, \dots, n-1\}. \quad (12)$$

根据上述方法将原始数据分解为需求序列 y 和间隔区间序列 p , 有

$$y = \{y_0, y_1, \dots, y_n\}, \quad p = \{p_1, p_2, \dots, p_n\}. \quad (13)$$

使用一阶指数平滑 (SES) 分别对需求序列和间隔区间序列进行预测, 得到 $t+1$ 时刻的需求量预测值 \hat{y}_{t+1} 和间隔区间预测值 \hat{p}_{t+1} , 并根据下式进行组合得到最终预测值:

$$f_{t+1} = \begin{cases} (\hat{y}_{t+1}/\hat{p}_{t+1})(1 - \alpha/2), & y_t > 0; \\ (\hat{y}_{t+1}/\hat{p}_{t+1})(1 - \alpha p_t/2\hat{p}_{t+1})^+, & y_t = 0. \end{cases} \quad (14)$$

2.3 模型融合

为提高多组配件的预测精度和稳定性, 本文综合考虑序列间结构化信息 (m_1) 和序列自身时序演化信息 (m_2), 将这 2 个模型进行加权融合, 弥补单个模型的不足, 提升序列的整体预测效果^[16-17]. 过程如下: 首先通过数据训练和预测获取单个模型在历史数据上的预测值. 然后计算该段历史真实值与预测值间的平均绝对误差 (mean absolute error, MAE), 第 n 条序列中各模型的权重系数如下式所示:

$$\begin{cases} \text{Weight}_{m_1} = \frac{\text{MAE}_{m_2}^n}{\text{MAE}_{m_1}^n + \text{MAE}_{m_2}^n}, \\ \text{Weight}_{m_2} = \frac{\text{MAE}_{m_1}^n}{\text{MAE}_{m_1}^n + \text{MAE}_{m_2}^n}. \end{cases} \quad (15)$$

最后各模型预测结果与其对应模型权重相乘得到最终的预测结果, 如下式所示:

$$\widehat{y_final}_{t+1} = \hat{y}_{t+1}^{m_1} \times \text{Weight}_{m_1} + \hat{y}_{t+1}^{m_2} \times \text{Weight}_{m_2}. \quad (16)$$

其中: $\widehat{y_final}_{t+1}$ 为在 $t+1$ 时刻的最终预测值, $\hat{y}_{t+1}^{m_1}$ 为模型 1 在 $t+1$ 时刻的预测值, $\hat{y}_{t+1}^{m_2}$ 为模型 2 在 $t+1$ 时刻的预测值.

所提出方法的复杂度分析主要包括3部分:1)基于张量的LightGBM模型(子模块1)的复杂度;2)线性衰减修正模型(子模块2)的复杂度;3)模型融合的复杂度.其中:张量分解的时间复杂度为 $O(n^3)$,主要由序列数量 n 和迭代次数 k 决定,空间复杂度与核心张量秩的大小成正比,线性衰减修正模型的复杂度为 $O(n^2)$,模型融合是将前2个部分进行叠加,复杂度为 $O(n^3)$.综上,所提出方法的时间复杂度为 $O(n^3)$.

3 实验分析

本文除选取常见的回归评价指标:均方根误差(root mean square error, RMSE)、MAE,还使用了针对间歇性序列数据特点设计的评价指标:均方根标度误差(root mean squared scaled error, RMSSE)来评价方法的性能^[18-19].相关计算公式如下:

$$RMSSE = \sqrt{\frac{\frac{1}{h} \sum_{t=tn+1}^{tn+h} (y_t - \hat{y}_t)^2}{\frac{1}{tn-1} \sum_{t=2}^{tn} (y_t - y_{t-1})^2}} \quad (17)$$

其中: y_t 为 t 时刻的实际值, \hat{y}_t 为 t 时刻的预测值, tn 为训练样本长度, h 为预测范围长度.

3.1 数据集介绍

为验证所提出方法的可靠性,本文分别在“第五届全国工业互联网数据创新应用大赛”提供的某重型装备企业配件需求数据集(<https://www.industrial-bigdata.com/Competition>)和某大型车辆制造企业售后配件需求数据集中验证应用效果.2个数据集的需求量均是按月份进行统计的.

使用ADI和 CV^2 对数据进行分类(详细介绍请参见第1.3节),筛选出 $ADI \geq 1.32$ 的数据,经过处理后,2个数据集的剩余样本数分别为563条和999条,这些数据块状和间歇分布特点明显^[20],符合所提出方法的研究数据特点.

3.2 对比方法

本文对比方法包含Croston变体、时间序列预测模型、树模型、深度模型以及最新的多元时间序列预测方法BHT-ARIMA,相关方法已在文献调研部分介绍.如表1所示.

实验中,Croston变体模型中的 α 和 β 参数设置在0.05~0.3间^[9],步长为0.05,通过网格搜索得到最优;ARIMA参数、SVR参数和Prophet参数由网格搜索得到最优;LSTM网络设置隐藏层数为100,使用单层网络,学习率为0.01,时间步为5;LightGBM参数由贝叶斯搜索得到最优.

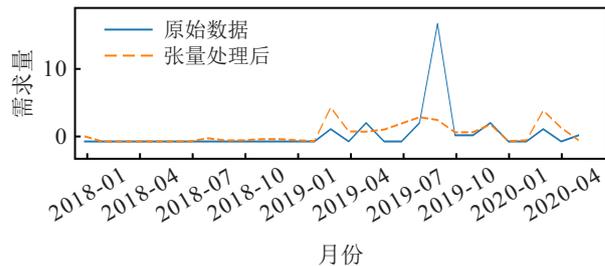
表1 对比方法

算法类型	对比方法
单维时间序列	SBA ^[7]
	TSB ^[8]
	ESLD ^[9]
	ARIMA ^[2]
	Prophet ^[11,21]
	SVR ^[3]
多元时间序列联合预测	LSTM ^[5]
	BHT_ARIMA ^[11]
	LightGBM ^[16-17]

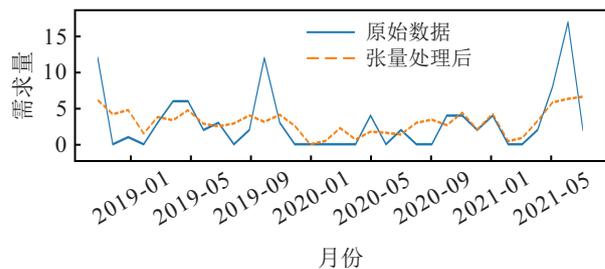
3.3 结果分析

3.3.1 张量处理

使用张量对2个数据集的原始数据进行处理,效果如图2所示.由图2可见,原始数据中的部分峰值点被修正,如数据集1中的759号配件和数据集2中的124号配件,其中759号配件原始数据中在2019年9月份有一次数量较大的需求,在未修正时该异常点会干扰预测模型的训练,而修正后避免了该异常点对模型训练的影响,有利于提高预测的准确度.



(a) 数据集1~759号配件



(b) 数据集2~124号配件

图2 张量处理效果

3.3.2 单月处理

与企业沟通后得知,在实际进行备件决策的过程中,预测值若在真实值的 $[-30\%, 30\%]$ 间,即可视为有效预测.在本节实验中将数据集1前29个时间点作训练,预测第30个时间点的需求;将数据集2中前33个时间点作训练,预测第34个时间点的需求.预测效果如图3所示.由图3可见,所提出方法预测结果虽然与真实值有些差异,但是均在有效预测范围内,能够为企业备货决策提供帮助.

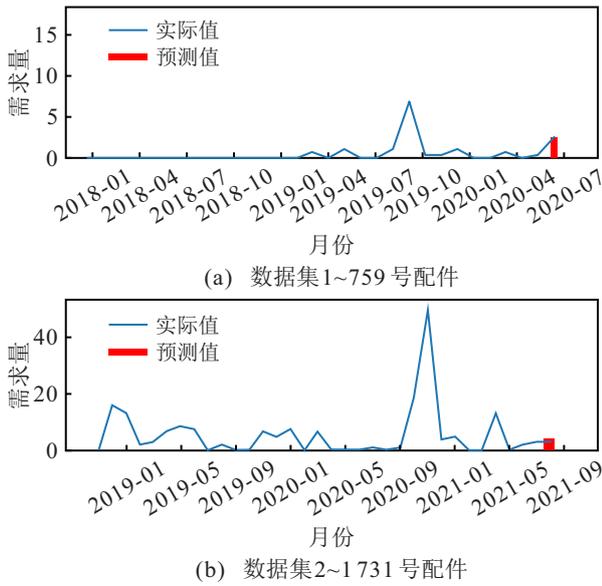


图3 单月预测效果

图4为不同算法的预测效果对比. 由图4可见,在绝大多数序列上,所提出方法相比于对比方法取得了更低的误差值. 以数据集1中的759号配件为例,此类需求次数较少,且存在部分极值,只使用序列“纵向”信息(图4中LSTM和LightGBM)比只使用“横向”信息(图4中SBA和TSB)的预测误差明显较小,表明此配件与其他配件有较强的联系,适合利用配件间的结构化信息提升预测效果. 同样,数据集2中的1731号配件在较长时间内未发生需求,只使用“横向”信息产生的预测误差更小,表明此配件与其他配件关联度较弱,建模时应侧重于“横向”信息的利用. 所提出方法同时考虑了序列的“横向”和“纵向”信息,可较

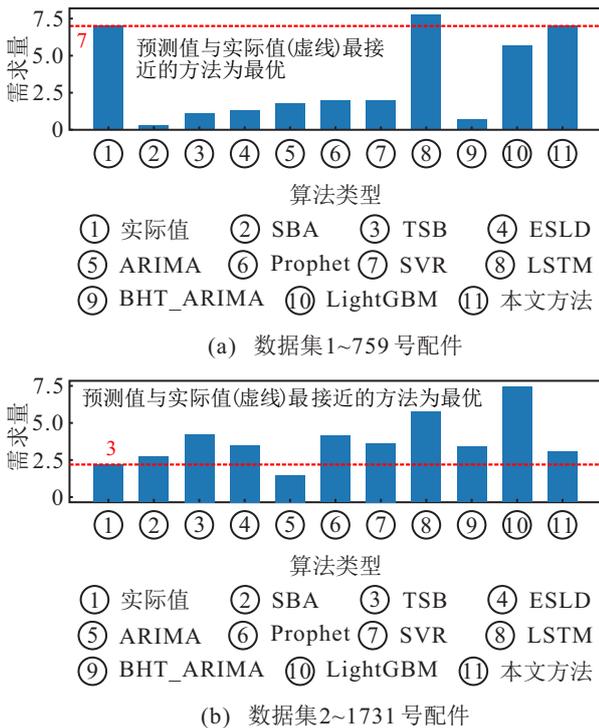


图4 不同方法预测结果对比

地提高整体序列的信息提取能力,因此其预测效果更佳. 此外,受间歇性数据数量波动大、小样本特点明显所致,对比方法的误差普遍高于所提出方法.

此外,本文对所提出方法的时间效率进行了验证. 算法环境为Python 3.7,采用的CPU为2.60 GHz Intel(R) E5-2 650 v2处理器,64 GB内存.

所提出方法运行用时相对较长(集中于特征数据提取),但是明显少于Prophet与LSTM两种方法的耗时. 需要说明的是,所提出方法更侧重于配件需求预测的准确度,预测周期通常为1个月,因此,虽然所提出方法的计算效率较低,但是预测准确度相比更高,更符合企业的实际生产需要.

3.3.3 多月连续预测

由于此类配件原始数据稀少,为进一步评估算法性能,本文将历史数据分别以最近若干个时间点为时间周期进行需求预测,依次实现对最近6个月配件需求的连续预测,结果如表2所示. 由表2可见,所提出方法的预测性能更好,各项指标均优于对比方法.

表2 不同算法性能对比

算法类型	数据集1			数据集2		
	RMSE	MAE	RMSSE	RMSE	MAE	RMSSE
SBA	14.7173	11.7372	1.2694	1.0052	0.8548	0.8776
TSB	14.9810	12.1177	1.3094	0.8261	0.6433	0.6078
ESLD	14.7841	11.8677	1.2800	0.7847	0.6154	0.6021
ARIMA	20.5937	15.9468	1.6623	0.9932	0.7186	0.7235
Prophet	15.3126	12.5038	1.3518	0.9945	0.7455	0.7519
SVR	14.8686	12.1633	1.2985	0.8422	0.6851	0.6233
LSTM	18.3890	14.7316	1.5610	0.9640	0.7095	0.6735
BHT_ARIMA	17.3729	13.7806	1.5117	1.0132	0.7184	0.7621
LightGBM	14.8601	11.4909	1.2680	0.8406	0.6198	0.6253
本文方法	14.2158	11.2434	1.1968	0.7692	0.5866	0.5856

为验证所提出方法各模块的必要性,此处给出了

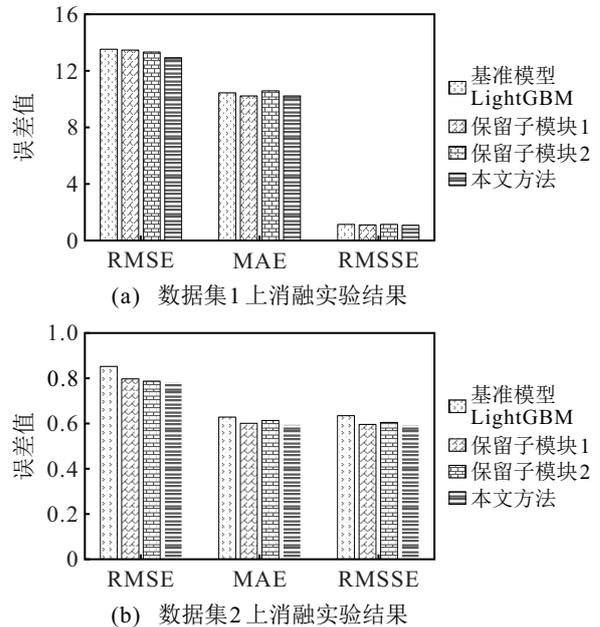


图5 不同数据集上消融实验结果

消融实验结果,即以LightGBM为基准,分别去除各子模块、计算对应误差,如图5所示.由图5可见,所提出方法去除各子模块后的性能均有一定程度下降,相反,相对于基准模型,使用了任一模块后误差值均有下降(尤其在数据集2更明显),由此表明分别从“纵向”和“横向”对序列信息进行提取和利用的合理性.

本文进一步考虑所提出方法在不同数据尺寸下的性能,如图6所示.其中:RMSE和MAE对应左侧Y轴刻度,RMSSE对应右侧Y轴刻度,横轴数字

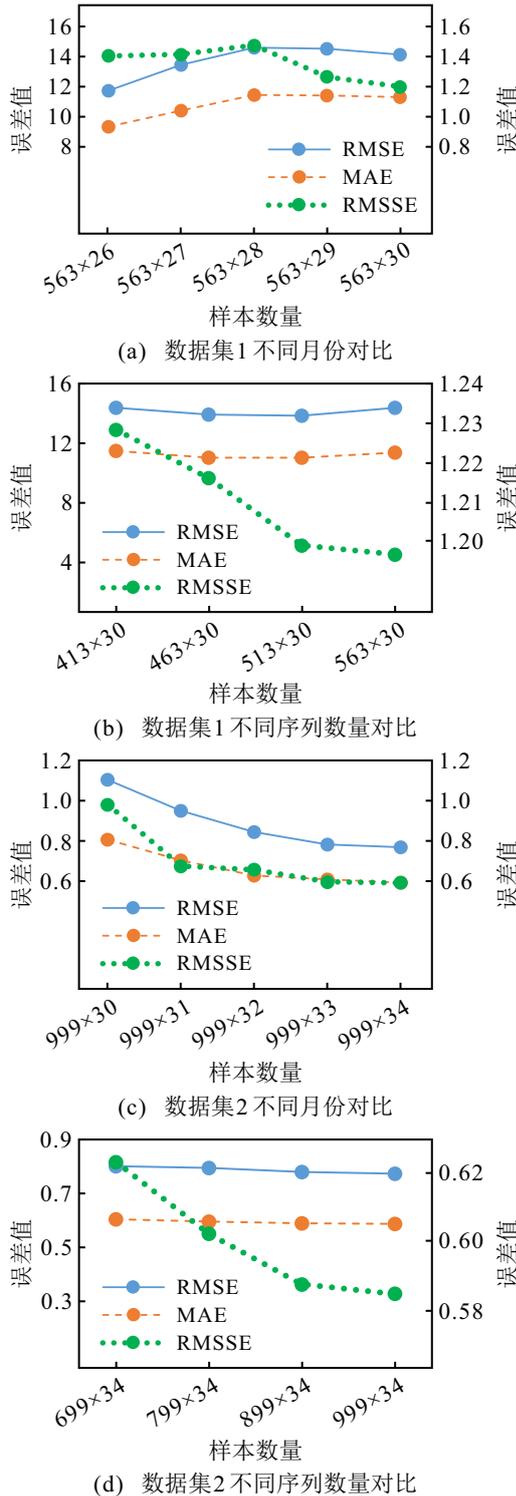


图6 不同数据集在不同尺寸下本文方法预测误差对比

为“序列数×月份数”.由图6可见,随着序列数和月份数的增加,所提出方法的预测误差整体呈下降趋势.需要注意的是,受春节和新冠疫情影响,图6(a)中的RMSE、MAE和RMSSE均呈现先上升后下降的趋势;图6(b)中RMSE、MAE整体呈现下降的趋势,中间略有波动,这是由原始数据的部分序列极差大且无法均匀抽取引起的.相比数据集1,数据集2的极差更小,在图6(c)和图6(d)中所提出方法的3个指标均整体呈现较规律的下降趋势.通过上述不同数据尺寸的性能对比,表明了所提出方法的模型与样本具有良好的一致性.

4 结论

从间歇性序列预测出发,本文提出了一种新的多变量间歇性时间序列预测方法.该方法综合考虑序列间结构化信息和序列自身时序演化信息,从“横向”和“纵向”2个角度充分挖掘序列中蕴含的演化机理信息,并减少了序列中异常值的负面影响,提高了对小样本情况下间歇性时间序列的预测效果.实验结果表明,所提出方法能有效预测需求波动趋势,在预测精度和数值稳定性方面均有明显提升,具有良好的实用性,为实际企业的弹性备件计划提供了一个有效的方案.

下一步工作,计划围绕间歇性序列可迁移性展开进一步研究,通过引入不同企业的需求数据,寻找间歇性序列的演化规律,提高对小样本需求数据的预测效果.此外,关注如何将间歇性序列预测与库存优化相结合,通过引入库存信息,建立库存优化模型,为企业作出合理库存决策作出信息支撑.

参考文献(References)

- [1] Croston J D. Forecasting and stock control for intermittent demands[J]. Journal of the Operational Research Society, 1972, 23(3): 289-303.
- [2] Chen Y, Zhao H, Yu L. Demand forecasting in automotive aftermarket based on ARMA model[C]. International Conference on Management and Service Science. Wuhan, 2010: 1-4.
- [3] Karmy J P, Maldonado S. Hierarchical time series forecasting via support vector regression in the European travel retail industry[J]. Expert Systems with Applications, 2019, 137: 59-73.
- [4] Steenbergen R M, Mes M R K. Forecasting demand profiles of new products[J]. Decision Support Systems, 2020, 139: 113401.
- [5] Abbasimehr H, Shabani M, Yousefi M. An optimized model using LSTM network for demand forecasting[J]. Computers & Industrial Engineering, 2020, 143: 106435.
- [6] Jeon Y, Seong S. Robust recurrent network model

- for intermittent time-series forecasting[J]. *International Journal of Forecasting*, 2022, 38(4):1415-1425.
- [7] Syntetos A A, Boylan J E. The accuracy of intermittent demand estimates[J]. *International Journal of Forecasting*, 2005, 21(2): 303-314.
- [8] Teunter R H, Syntetos A A, Babai M Z. Intermittent demand: Linking forecasting to inventory obsolescence[J]. *European Journal of Operational Research*, 2011, 214(3): 606-615.
- [9] Prestwich S D, Tarim S A, Rossi R. Intermittency and obsolescence: A Croston method with linear decay[J]. *International Journal of Forecasting*, 2021, 37(2): 708-715.
- [10] Tian X, Wang H Q, Erjiang E. Forecasting intermittent demand for inventory management by retailers: A new approach[J]. *Journal of Retailing and Consumer Services*, 2021, 62: 102662.
- [11] Shi Q, Yin J, Cai J, et al. Block Hankel tensor ARIMA for multiple short time series forecasting[C]. *Proceedings of the AAAI Conference on Artificial Intelligence*. New York: AAAI Press, 2020: 5758-5766.
- [12] 周晓艳, 唐涛, 张思乾, 等. 多角度SAR图像非目标遮挡缺失信息重构[J]. *信号处理*, 2021, 37(9): 1569-1580.
(Zhou X Y, Tang T, Zhang S Q, et al. Missing information reconstruction for multi-aspect SAR image occlusion[J]. *Journal of Signal Processing*, 2021, 37(9): 1569-1580.)
- [13] Syntetos A A, Boylan J E, Croston J D. On the categorization of demand patterns[J]. *Journal of the Operational Research Society*, 2005, 56(5): 495-503.
- [14] 郎祎平, 毛文涛, 罗铁军, 等. 间歇性时间序列的可预测性评估及联合预测方法[J]. *计算机应用*, 2022, 42(9): 2722-2731.
(Lang Y P, Mao W T, Luo T J, et al. Predictability evaluation and joint forecasting method for intermittent time series[J]. *Journal of Computer Applications*, 2022, 42(9): 2722-2731.)
- [15] Pinçe Ç, Turrini L, Meissner J. Intermittent demand forecasting for spare parts: A critical review[J]. *Omega*, 2021, 105: 102513.
- [16] 任春华, 孙林夫, 韩敏. 面向多价值链的汽车配件需求预测模型[J]. *计算机集成制造系统*, 2021, 27(10): 2786-2800.
(Ren C H, Sun L F, Han M. Demand forecasting model of auto parts for multi-value chains[J]. *Computer Integrated Manufacturing Systems*, 2021, 27(10): 2786-2800.)
- [17] Dodin P, Xiao J Y, Adulyasak Y, et al. Bombardier aftermarket demand forecast with machine learning[EB/OL]. (2021-11-08)[2022-05-04]. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3957452.
- [18] Hyndman R J, Koehler A B. Another look at measures of forecast accuracy[J]. *International Journal of Forecasting*, 2006, 22(4): 679-688.
- [19] Makridakis S, Petropoulos F, Spiliotis E. The M5 competition: Conclusions[J]. *International Journal of Forecasting*, 2022, 38(4): 1576-1582.
- [20] Rožanec J M, Mladenčić D. Reframing demand forecasting: A two-fold approach for lumpy and intermittent demand[J/OL]. 2021, arXiv: 2103.13812.
- [21] Kumar Jha B, Pande S. Time series forecasting model for supermarket sales using FB-prophet[C]. *The 5th International Conference on Computing Methodologies and Communication*. Erode, 2021: 547-554.

作者简介

范黎林(1970—), 男, 副教授, 博士, 从事工业大数据分析、时间序列预测、生产调度优化等研究, E-mail: flf@htu.edu.cn;

杨凯(1996—), 男, 硕士生, 从事时间序列预测的研究, E-mail: 18336200890@163.com;

毛文涛(1980—), 男, 教授, 博士, 从事机器学习、智能故障诊断等研究, E-mail: maowt@htu.edu.cn;

罗铁军(1970—), 男, 高级工程师, 从事工业工程的研究, E-mail: luotj@cszic.com;

刘洋硕(1998—), 男, 硕士生, 从事时间序列预测的研究, E-mail: 2468497418@qq.com;

刘侠(1996—), 男, 硕士生, 从事时间序列预测、库存优化等研究, E-mail: 1104009397@qq.com.