

基于时间序列高效卷积神经网络的农机备件需求预测方法

张智刚^{1,2} 张嘉锐¹ 张闻宇^{1,2} 何维胜¹ 潘健坤¹ 吴思进¹

(1. 华南农业大学南方农业机械与装备关键技术教育部重点实验室, 广州 510642;

2. 广东省农业人工智能重点实验室, 广州 510642)

摘要: 农机备件是农机维修的重要基础,是农机故障及时维修和农业生产正常开展的必要保障,因此,对农机备件需求量的精准预测至关重要。然而,农机备件的需求量具有非平稳性、非线性、多零值、波动大等特点,使得预测任务变得困难。本文提出了一种基于卷积神经网络的时间序列高效卷积网络(Time series efficient convolution network, TECNet),用于农机备件需求量的预测。该模型首先利用快速傅里叶变换对原始一维序列进行周期性提取,然后根据周期性构建二维时间序列卷积模块进行特征提取,最后将二维特征重塑回一维特征,并通过线性变换得到预测值。利用某农机备件供应商4种不同备件类型的销售数据进行了评估验证,并引入均方根缩放误差作为衡量指标,以统一不同序列间的预测效果。试验结果表明,提出的模型预测效果显著优于其他参考模型,4种不同备件需求量预测的均方根缩放误差分别为0.775、1.349、0.822、0.205,均表现出良好的预测效果。该模型能有效考虑时间序列中的时间依赖关系,具有捕捉时间序列数据中非线性模式的能力,对不同农机备件类型的预测任务均能取得良好的效果,可为预测农机备件需求量提供参考。

关键词: 农机备件; 需求预测; 时序预测; 高效卷积神经网络

中图分类号: S24

文献标识码: A

文章编号: 1000-1298(2026)01-0300-11

OSID:



Method for Agricultural Machinery Spare Parts Demand Forecasting Based on Time Series Efficient Convolutional Neural Networks

ZHANG Zhigang^{1,2} ZHANG Jiarui¹ ZHANG Wenyu^{1,2} HE Weisheng¹ PAN Jiankun¹ WU Sijin¹

(1. Key Laboratory of Key Technology on Agricultural Machine and Equipment, Ministry of Education, South China Agricultural University, Guangzhou 510642, China

2. Guangdong Provincial Key Laboratory of Agricultural Artificial Intelligence, Guangzhou 510642, China)

Abstract: Agricultural machinery spare parts are the foundation for the repair of agricultural machinery and are essential for timely maintenance of machinery failures and the normal operation of agricultural production. Therefore, accurate forecasting of the demand for agricultural machinery spare parts is crucial. However, the demand for agricultural machinery spare parts is characterized by non-stationarity, non-linearity, multiple zero values, and large fluctuations, making the prediction task challenging. A time series efficient convolution network (TECNet) was proposed based on convolutional neural networks for predicting the demand of agricultural machinery spare parts. The model firstly extracted the periodicity of the original one-dimensional sequence by using fast Fourier transform, then a two-dimensional time series convolution module for feature extraction was constructed based on the periodicity, and finally the two-dimensional features back was reshaped to one-dimensional features and the predicted values were obtained by linear transformation. The sales data of four different spare part types from an agricultural machinery spare part supplier were used to evaluate and validate the model, and the root mean square scaling error was introduced as a measure to unify the prediction effect among different sequences. The findings from the experiment indicated that the predictive performance of the

收稿日期: 2024-10-06 修回日期: 2024-12-17

基金项目: 国家重点研发计划项目(2020YFB1709604)

作者简介: 张智刚(1977—),男,副教授,博士,主要从事精准农业和无人农场关键技术研究,E-mail: zzg208@scau.edu.cn

通信作者: 张闻宇(1985—),男,助理研究员,博士,主要从事精准农业和无人农场关键技术研究,E-mail: zhangwenyu@scau.edu.cn

new model surpassed that of other comparative models. The root mean square errors for the projections of the four distinct spare parts' demand were 0.775, 1.349, 0.822, and 0.205, respectively, demonstrating a high degree of accuracy in predicting. The model was capable of analyzing the time-dependent relationships within time series data, effectively identifying nonlinear patterns. It performed well in predicting the demand for various agricultural machinery spare parts, offering valuable insights for the demand of predicting agricultural machinery spare parts.

Key words: agricultural machinery spare parts; demand prediction; time series prediction; efficient convolutional neural network

0 引言

近年来,我国农业机械化水平不断提高,农作物耕种管收综合机械化率达到 70% 以上。农业机械的广泛应用对农机备件的需求也随之增大。在田间作业时,农机若发生故障而不能得到及时维修,将导致经济损失,特别是在农忙时期,这种经济损失更为巨大。农机主机厂和经销商通常会在农忙开始前进行备件储备,从而保障农机在发生故障能及时得到维修,使农业生产减少经济损失。农机备件储备量应与市场需求量相适应,储备量少将导致农机维修不及时,储备量多将导致库存积压。因此,根据农机备件的历史统计数据,构建农机备件需求预测模型非常重要。农机备件需求预测指通过分析历史数据、当前市场环境等多方面因素来预测未来一段时间内农机备件的需求情况、备件的类型及数量等相关信息。目前常见的备件需求预测多采用基于时间序列的预测方法,可以分为两大类:一类是基于时序回归的预测方法,另一类是基于时序分解的预测方法^[1]。

基于时序回归的方法通常将时序数据看作自变量和因变量之间的关系,通过建立回归模型来进行预测^[2]。高龙^[3]提出了一种基于自回归积分滑动平均模型(ARIMA)的需求预测方法,旨在提高制造企业中具有不稳定供需特性的物料生产需求预测准确性。但 ARIMA 的主要局限性在于它假设给定的时间序列是线性的,可能无法有效捕捉具有周期性变化、趋势变化的非线性模式,导致预测精度不足^[4]。张舜等^[5]结合主成分分析(PCA)和支持向量回归(SVR)构建了 PCA-SVR 预测模型对农机备件需求量进行预测,相较于线性回归和随机森林方法表现出较好的预测性能。但该方法中 SVR 的性能很大程度上依赖于核函数和惩罚参数的选择,不当的参数设置可能导致预测效果不佳。

基于时序分解的方法通常将时序数据分解为趋势性、季节性和残差等组成部分,然后分别对这些分项进行建模和预测,最后进行汇总^[6]。对于时间序列的分解,常见的方法包括季节与趋势分解(Seasonal and trend decomposition using loess, STL)、变分模态分

解(Variational mode decomposition, VMD)和经验模态分解(Empirical mode decomposition, EMD)等。秦海峰等^[7]基于变分模态分解的方法,结合径向基神经网络对典型的非稳态备件需求历史数据进行处理和预测,结果表明 VMD-模糊熵-RBF 神经网络预测模型具有较高的预测精度和适用性。然而,该方法依赖于 VMD 分解过程,该过程将原始数据拆分为 K 个模态分量,再对这 K 个模态分量进行建模,这无疑增加了模型的计算量。随着数据量的增加,计算复杂度也显著增长,这在一定程度上限制了模型对长周期时间序列的预测能力。温彦博等^[8]提出了一种基于改进的 LightGBM 算法的农机服务备件需求预测方法,能够以较高的精度预测服务站对于农业机械服务配件的需求情况。但 LightGBM 的超参数众多,尽管该方法使用了 PSO 算法进行超参数优化,但找到最优参数组合仍然具有一定的挑战性。

备件需求预测的方法多种多样,但都存在各自的优缺点^[9-10]。农机备件的需求量具有非平稳性、非线性、多零值、波动大等特点,尤其是农闲时期造成的备件需求量多零值的特点,使得趋势分析和季节性分解变得困难。特别是在模型训练过程,数据被切分为较短的数据长度,数据中的零值还会掩盖或削弱数据的真实趋势和季节性模式,使得模型难以有效训练。同时,由于目前尚无公开的农机备件需求数据集,对于农机备件需求预测少有研究,这也给农机备件需求预测的相关研究带来了困难。农机备件种类繁多,不同类型的备件会呈现出不同的时间模式和周期性,使得备件需求预测任务具有挑战性^[11-14]。因此本文采用一种新型的时间序列高效卷积网络(Time series efficient convolution network, TECNet)对农机备件需求预测加以研究,以期解决农机备件需求预测准确性不高的问题。

1 模型与方法

该模型的核心思想是,利用快速傅里叶变换将原始的一维时序数据转换为具有周期性和跨周期特征的二维时序数据,再构建高效卷积神经网络模型

进行特征学习,最后通过一个全连接神经网络实现备件需求预测输出。模型总体结构包括数据嵌入模块、特征提取模块、时间序列高效卷积模块。具体的处理流程如图 1 所示,包括如下步骤:

(1)对原始备件需求的时间序列数据进行分割,按照回望窗口(Lookback window)大小和预测长度,划分固定长度的需求序列样本,并按比例划分训练集和测试集。

(2)将原始历史需求序列经过由序列归一化、位置编码和通道线性变换组成的数据嵌入模块(Data embedding)操作,得到初步的时序特征。

(3)经过若干个特征提取模块(Feature extraction module),获取需求序列数据中的变化规律和趋势。

(4)通过层归一化、通道特征线性投影和反归一化操作得到预测值。




图 1 TECNet 模型结构图
Fig.1 TECNet model structure

1.1 数据嵌入模块

现实世界中,备件需求序列多为非平稳时间序列。非平稳时间序列会使深度模型的预测任务变得困难,因为很难很好地概括推理过程中统计数据发生的变化。因此,本文在数据嵌入模块引入了序列平稳化操作,用于处理由均值和标准差变化引起的非平稳序列,以增强输入数据的平稳性。通过随时间推移的滑动窗口对时间维度进行归一化,减少每个输入时间序列之间的分布差异,使模型输入的分布更加稳定。对于每一个输入序列 $X = (x_1, x_2, \dots, x_t)$,通过放缩变换得到 $X' = (x'_1, x'_2, \dots, x'_t)$,其过程可表示为

$$\mu_x = \frac{1}{t} \sum_{i=1}^t x_i \tag{1}$$

$$\sigma_x^2 = \frac{1}{t} \sum_{i=1}^t (x_i - \mu_x)^2 \tag{2}$$

$$x'_i = \frac{1}{\sigma_x} (x_i - \mu_x) \tag{3}$$

式中 μ_x ——输入序列的均值

t ——输入序列数据个数

σ_x ——输入序列方差

对 X' 进行预测得到预测值 $Y' = (y'_1, y'_2, \dots, y'_o)$,也可以通过反归一化得到正确的预测值 $\hat{Y} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_o)$ 。具体的变换过程可表示为

$$\hat{y}_i = \sigma_x (y'_i + \mu_x) \tag{4}$$

序列归一化操作后是值嵌入(Value embedding)和位置嵌入(Position embedding)操作。值嵌入由 1 个一维卷积实现,通过将低维时序数据映射到高维空间,可以提供更多的特征信息,提高模型对数据的表征能力和泛化能力。而位置嵌入层用于为输入序列中的每个位置添加特定的位置信息,可以有效帮助模型学习到序列中不同位置的信息,更好地理解序列中各个位置的先后顺序,提高对序列的理解能力。最后将 2 个嵌入操作得到的序列进行相加并对通道维度进行线性变换,得到初步的时序特征。图 2 展示了数据嵌入层中数据的转换过程以及变量的空间依赖关系。




图 2 数据嵌入层结构图

Fig. 2 Data embedding structure

1.2 特征提取模块

在时间序列数据中,每个时间点与其相邻的区域同时涉及两种类型的时间变化,即周期内变化和跨周期变化。然而,原始的一维时间序列结构只能反映相邻时间点之间的变化。为了克服这一局限性,将原始一维时间序列结构变换为二维结构,这种二维结构可以显式地表示时段内和时段间的变化,从而在表示能力上更具优势,有利于后续的学习。

如图 1 右侧描述,在特征提取模块中,首先利用快速傅里叶变换对时序特征进行频域分析,提取输入序列的周期,并通过 Softmax 函数计算每个周期的权重,选用的求和权重即为傅里叶变换后得到的振幅,具体计算方法为

$$Amp = \text{FFT}(X) \quad (X \in \mathbf{R}^{T \times d}) \quad (5)$$

$$f_i = \text{Topk}(Amp) \quad (6)$$

$$p_i = \left\lceil \frac{T}{f_i} \right\rceil \quad (i \in 1, 2, \dots, k) \quad (7)$$

$$Weight = \text{Softmax}(\text{Avg}(Amp_{\text{Topk}})) \quad (8)$$

其中 T 为输入序列长度, $\text{FFT}(\cdot)$ 表示快速傅里叶变换,计算每个频率的振幅, $\text{Topk}(\cdot)$ 表示选取 k 个最大值, Amp_{Topk} 表示选出的 k 个最大振幅, $\text{Avg}(\cdot)$ 表示在通道维度上计算均值。考虑到频域的稀疏性,避免无意义的高频带来的噪声^[15],本文只选取幅值最大的 k 个频率 $f_1, f_2, \dots, f_k$, 对应了 k 个周期长度 $p_1, p_2, \dots, p_k$ 。

原始的一维序列 $X_{1d} = (X_1, X_2, \dots, X_d)$, ($X_{1d} \in \mathbf{R}^{T \times d}$), 按照周期长度进行二维变换得到 k 个二维时序结构 $X_{2d}^1, X_{2d}^2, \dots, X_{2d}^k$ ($X_{2d}^i \in \mathbf{R}^{p_i \times f_i \times d}$), 接着利用时间序列高效卷积模块提取二维时序结构的空问特征, 再将二维特征结构重构回一维序列 $\{\hat{X}_{1d}^1, \hat{X}_{1d}^2, \dots, \hat{X}_{1d}^k\}$ ($\hat{X}_{1d}^i \in \mathbf{R}^{T \times d}$), 并乘以每个周期的权重得到 k 个一维序列特征。最后对得到的 k 个一维序列特征进行聚合, 得到具有不同周期变化的时间序列特征。

1.3 时间序列高效卷积模块

一维的时间序列信息被转换成二维的数据结构

之后,就可以使用当前先进的视觉主干网络来直接对这些二维信息进行特征提取, 比如 Swin Transformer^[16]、GoogLeNet^[17]、ResNeXt^[18] 等。本文针对备件需求时序数据的特性, 设计了基于图 3b 高效卷积块 (Efficient convolutional block, EConv Block) 的时间序列高效卷积模块 (Time series efficient conv module, TEC Module), 通过卷积神经网络的局部性归纳偏置能力提取需求时间序列二维结构的空问特征, 更好地将卷积应用于时间序列分析中。




图 3 时间序列高效卷积模块结构图

Fig. 3 TEC module structure

所提出的时间序列高效卷积模块 (TEC Module) 分为 3 个阶段, 每个阶段先由 1 个一维卷积 (Conv1d) 和层归一化 (Layer Norm) 操作组成, 实现时序二维结构的通道变换, 随后紧跟着堆叠的高效卷积块, 每个高效卷积块堆叠的数量都为 3, 如图 3a 所示。高效卷积块 (EConv Block) 主要由 1 个卷积核为 3×3 的深度可分离卷积层 (Depthwise convolutional layer, dw Conv)、2 个一维卷积、1 个层

归一化、1 个 GELU 激活函数和 1 个 Drop Path 正则化组成,并且在最后使用了残差结构,避免在构建深层神经网络时发生梯度消失和梯度爆炸的问题,具体结构如图 3b 所示。为了在不降低执行效率的情况下提升模型性能,在高效卷积块中,仅在深度可分离卷积层后使用层归一化,并在下一个卷积层后使用 GELU 激活函数^[19]。

在残差网络 ResNet^[20] 中,设计了带 bottleneck 结构的残差单元,其通道变化类似于一个瓶口。这样的残差单元由 3 部分组成:1×1 卷积、3×3 卷积和 1×1 卷积,依次对输入进行降维、卷积和升维。这种结构有效节省了计算资源,然而先降维再卷积的操作会导致信息丢失,从而降低模型拟合能力和准确度。采用逆瓶颈结构,先对输入进行升维,再进行特征提取,最后降维。通过激活函数处理后,能够保留较多高维信息,减少信息丢失。该思想被 SANDLER 等^[21] 在 MobileNetV2 中推广,随后在多个先进的卷积架构^[22-23] 中使用。同时,为了降低计算复杂度,将高效卷积模块中的深度可分离卷积模块上移,使其具有更少的通道数,让高效、密集的 1×1 卷积模块承担复杂的计算工作。通过这种顺序的改变,能够在有效降低模型计算量的同时保持良好性能。改进后的逆瓶颈结构如图 4c 所示。




图 4 改进的高效卷积逆瓶颈结构图
Fig.4 Improved inverse bottleneck structure for EConv block

2 数据集制备与时序分析

采用某农机装备供应商客户关系管理系统、进销存系统以及售后系统导出的真实备件月销售数据作为基础数据集。数据涵盖 2020 年至 2022 年大疆植保无人机的 T 系列桨叶(备件 A)、大疆测绘无人机的正桨(备件 B)、洋马秧爪 1C731C(备件 C)以及洋马发动机油(备件 D)共 4 种农机备件的月销售数据,每种备件的时间序列共有 36 个月。本文以月为时间单位,对农机备件进行需求预测。

在时间序列分析中,趋势性和季节性是导致数据非平稳性的主要因素。通过观察时间序列的均值和标准差的变化,可以判断序列的平稳性。图 5 展示了各备件需求序列原始值、12 个月滑动平均值和 12 个月滑动标准差。同时,为了更精确地衡量时间序列的平稳程度,对各需求序列进行了 ADF (Augmented dickey-fuller) 检验^[24]。4 种备件需求序列的 ADF 检验结果包括 P 和 ADF 统计量,如表 1 所示。




图 5 备件需求序列趋势图

Fig.5 Trend graphs of spare parts demand series

表 1 备件需求序列的 ADF 检验结果

参数	备件 A	备件 B	备件 C	备件 D
ADF 统计量	-3.315 10	-2.579 66	-5.275 59	-5.057 48
P	0.014 217	0.097 275	6×10^{-6}	1.7×10^{-5}
1% 临界点	-3.639 22	-3.632 74	-3.632 74	-3.632 74
5% 临界点	-2.951 23	-2.948 51	-2.948 51	-2.948 51
10% 临界点	-2.614 45	-2.613 02	-2.613 02	-2.613 02

备件 A 需求序列呈现总体上的上升趋势,根据表 1 中 ADF 检验的数据, P 低于 0.05 的显著性阈值,且 ADF 统计值低于 5% 置信水平的临界值,因此可以排除该序列含有单位根的假设,即该序列具有趋势平稳性。

备件 B 的需求序列没有表现出明显的周期性或趋势性波动。依据 ADF 检验的数据, P 高于 0.05 的显著性标准,同时 ADF 统计量也超过了 10% 置信水平的临界值,因此不能排除序列中有单位根的可能,这表明备件 B 需求序列是一个非平稳的序列。

备件 C 需求序列的滑动平均值与标准差趋于稳定,经过 ADF 检验, P 远小于 0.05 显著性水平,ADF 检验统计量小于置信度 10% 临界值,可以判断备件 C 需求序列为平稳性序列。

备件 D 需求序列呈现先上升后下降的趋势,这种趋势的突然变化会使得预测任务变得困难。一阶差分后,序列的趋势逐渐趋于平稳(图 6),表明该序列为差分平稳性序列。




图 6 备件 D 需求序列一阶差分趋势图

Fig.6 Trend graph of the first difference of demand series for spare part D

3 试验验证

3.1 试验设置

本文设计一系列试验来验证所提出的模型的预测性能。试验平台采用 AMD Ryzen 7 5700X8 核心处理器,以及 24 GB 的 NVIDIA GeForce RTX 3090 显卡,使用 CUDA 11.8、Python 3.9 和 Pytorch 1.13 搭建深度学习环境。模型的训练通过指数衰

减策略动态调节学习率,初始学习率设置为 0.001。选用 Adam 算法作为优化器,迭代训练 10 个周期。

提出的模型涉及的超参数有 Topk、数据嵌入模块变换后的通道数 d_{model} 、特征提取模块的堆叠数 e_{layer} 、EConvBlock 的深度和通道数以及滞后时间 (Lag),对于每个超参数,确定一个值列表,用于模型配置和训练。利用网格搜索对每个超参数组合进行模型训练和评估,从而找到性能最佳的超参数组合。每个超参数的搜索空间如表 2 所示。

表 2 超参数搜索列表

超参数	值列表
Top_k	(1,2,3,4,5)
d_{model}	(96,192,384)
EConvBlock depths	({3,3,3} , {3,3,9} , {3,9,3})
EConvBlock dims	({96,192,384} , {128,256,512})
e_{layer}	(1,2,3)
Lag	(3,4,6,7,12)

对于各超参数组合,利用平均绝对误差 (Mean absolute error, MAE) 评估所得模型,从而选择最优的模型,最优模型的超参数如表 3 所示。

表 3 最优模型的超参数

超参数	数值
Top_k	4
d_{model}	384
EConvBlock depths	{3,3,3}
EConvBlock dims	{96,192,384}
e_{layer}	1
Lag	12

3.2 数据集划分

将各需求序列数据按照时间顺序划分为训练集和测试集,其中前 80% 为训练集、其余 20% 为测试集。由于时间序列预测涉及滞后阶数的选取,本文参考文献[25],设计了滞后阶数为 4、6、7、12 的对比试验,最终确定滞后阶数为 12 时具有最好的预测效果。创建的数据样本示例如表 4 所示(以备件 A 需求序列为例)。

3.3 评价指标

采用均方根误差 (Root mean square error, RMSE)、平均绝对误差 (Mean absolute error, MAE)、均方根缩放误差 (Root mean squared scaled error, RMSSE) 3 项指标,用以评估模型在预测不同序列时的准确性。RMSSE 是平均绝对缩放误差 (Mean absolute scaled error, MASE)^[26] 的变体,不受时间序列绝对大小影响,适用于不同规模和幅度的时间序

表 4 备件 A 需求序列样本部分数据

Tab.4 Spare part A demand series sample data

样本序号	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12	输出
1	4	2	10	20	50	44	70	82	127	77	54	22	25
2	2	10	20	50	44	70	82	127	77	54	22	25	6
3	10	20	50	44	70	82	127	77	54	22	25	6	46

列数据,对正负误差都有对称惩罚。此外,RMSSE不依赖于实际值为零的除法,解决了备件需求序列多零值所带来的问题。最后,通过计算所有备件需求序列的总体 RMSSE 均值,作为方法模型的综合指标。上述 3 种指标越小,表明模型预测的效果越好。当 RMSSE 小于 1 时,意味着预测误差的波动比实际数据的波动还要小,能够达到较好的预测效果。

3.4 对比试验

为了比较本文模型的预测性能,将其与一些传统模型进行比较,包括基于回归的自回归移动平均模型 (Autoregressive integrated moving average, ARIMA) 和贝叶斯岭回归模型 (Bayesian ridge regression, BRR),基于分解的 DLinear 模型^[27]和基于 Transformer 架构的 Informer 模型^[28],所选的传统模型分别是统计学习方法、机器学习方法和深度学习方法在时序预测任务中具有代表性的模型。其中 ARIMA 和 BRR 模型使用 Python 中的 scikit-learn 工具包实现和优化,DLinear 和 Informer 参考原论文用 pytorch 实现。

对于每个传统模型,本文都搜索了最优参数,使

其表现最好。传统模型的最优参数如表 5 所示。

表 5 传统模型的最优超参数

Tab.5 Optimal hyperparameters of benchmark model

方法	最优超参数
ARIMA	$p = 1, q = 1, d = 0$
	滞后窗口长度 (Lag): 12
	正则化参数 (alpha1): 0.01
BRR	正则化参数 (alpha2): 0.01
	滞后窗口长度 (Lag): 12
	滑动均值窗口大小 (window size of moving average): 3
DLinear	滞后窗口长度 (Lag): 4
	编码器层数 (num of encoder layers): 2
Informer	解码器层数 (num of decoder layers): 1
	模型编码维度 (dimension of model): 512
	滞后窗口长度 (Lag): 12

将上述模型应用于农机备件需求数据,各模型的预测结果如图 7 所示,预测误差结果如表 6 所示。

ARIMA 对平稳性序列有较精准的预测,但当序列具有趋势性时会导致性能损失。针对备件 B (非平稳性序列),从 RMSE、MAE、RMSSE 来看,其表现并不适合本文的备件数据。与本文方法模型相比,




图 7 各模型在备件数据集上的预测结果

Fig.7 Prediction results of each model on spare parts dataset

表 6 各模型对备件需求数据的误差结果
Tab.6 Error results of each model on spare parts demand data

序列	参数	ARIMA	BRR	DLinear	Informer	TECNet
A	RMSE/件	95.64	62.986	108.889	252.492	38.776
	MAE/件	77.4	57.6	91.2	235.2	30.8
	RMSSE	1.922	1.268	2.193	5.073	0.776
B	RMSE/件	195.236	232.018	114.635	22.685	63.073
	MAE/件	194.4	219	100.4	15	42.6
	RMSSE	4.178	4.968	2.452	0.485	1.349
C	RMSE/件	32.367	25.108	27.404	33.024	29.1
	MAE/件	23.6	20	19.8	24.6	24
	RMSSE	0.94	0.733	0.804	0.965	0.823
D	RMSE/件	18.308	24.936	12.313	14.112	8.185
	MAE/件	17.6	23.8	11.2	13.5	5.8
	RMSSE	0.459	0.634	0.311	0.356	0.205
总体平均 RMSSE		1.875	1.900	1.440	1.720	0.788

提出的 TECNet 预测模型在 4 种备件上的预测性能指标都优于 ARIMA。

贝叶斯岭回归在平稳性需求序列(备件 A、C、D)的预测中都取得了较好的效果,并且在备件 C 的预测中取得了最好的预测性能,但对于非平稳性序列,由于其趋势变化和周期变化的不规则性,使得预测任务变得困难,导致性能的下降。

DLinear 是基于序列分解中具有代表性的模型,不同于其它基于回归的预测方法,它通过将时间序列分解为趋势序列和剩余序列,然后对这两个序列进行建模,以完成预测任务。尽管 DLinear 在对 4 种备件需求序列的预测中未展现出显著优越的表现,但与其他方法不同的是,它并未表现出对某一序列类型的严重欠拟合问题。这使得在综合指标平均 RMSSE 方面,DLinear 的预测效果排名第 2 位。

基于 Transformer 架构的 Informer 预测模型在备件 B 和备件 D 中取得了最佳预测效果,但对备件 A 需求序列存在严重的欠拟合问题,表明了 Informer 模型的不稳定性。

本文方法在 4 种不同备件需求序列上均展现出了卓越的预测性能。在备件 A 和备件 D 的需求预测中,该方法在所有性能指标上均超越了其他模型,表 7 给出了模型对备件 A 的预测效果。RMSSE 指标方面除了备件 B 的 RMSSE 值为 1.349,仅次于 Informer 模型外,其他备件 RMSSE 值均低于 1,显示出较高的准确性。此外,该方法的综合性能指标总体平均 RMSSE 值达到 0.788,取得了最佳的综合性能指标,显著优于其他参考模型,证明了其在精准预测不同类型备件需求序列方面的有效性。

表 7 各模型对备件 A 需求数据的预测结果对比
Tab.7 Comparison of prediction results of each model on spare parts A demand data

实际值	TECNet	ARIMA	BRR	DLinear	Informer
277	299	259	372	230	6
343	270	262	408	252	6
304	266	264	373	280	6
198	204	265	234	295	6
84	69	265	107	281	6
RMSE/件	38.776	95.64	62.986	108.889	252.492
MAE/件	30.8	77.4	57.6	91.2	235.2
RMSSE	0.776	1.922	1.268	2.193	5.073

总的来说,对于上述 4 种不同备件需求序列类型的预测,备件 C 和备件 D 需求序列由于序列平稳性的特点,上述 5 种方法都取得了较好的预测效果。理论上,备件 C(平稳性序列)应该是最简单、最容易预测的序列,但由于其需求序列中存在较多离散的零值,导致各模型预测效果略有下降,这也是农机备件需求序列中常见的问题。除本文的方法模型外,其他参考模型在某些序列类型上存在较明显的性能损失。

3.5 模型分析

3.5.1 二维空间特征

从表征学习的角度来解释模型的性能。本文提出的 TECNet 模型能够发挥高效稳定的性能,其中一个重要操作就是对一维时间序列进行二维变换。由 1.2 节可知,本文通过快速傅里叶变换对一维时间序列的周期性进行提取,随后按照周期长度将一维时序数据重塑为二维空间数据。这种设计也使得时序预测任务可以直接受益于蓬勃发展的计算机视觉技术。

图 8 提供了备件数据集备件 A 需求序列从原始一维数据变换为二维数据后的可视化案例。从图中可以发现,对于小样本数据,TECNet 能够准确地捕捉到原始一维数据的多周期现象,并且变换后的二维数据具有高度的结构化特性,相邻的行和列可以反映该时间点周期内和跨周期期间的局部特征。这种结构化的数据表示有助于模型在有限的条件下进行有效的特征提取,并避免无关噪声对学习过程的干扰。通过这种捕获 2D 时间变化建模的方式,可以很好地借助高效卷积模块进行二维表征学习。

3.5.2 超参数敏感性分析

本文在公式(6)中引入了一个超参数 k_{Top} 来选择最有效的频率。在图 9 中给出了该超参数的敏感性分析。可以发现,本文提出的 TECNet 模型对不同序列的预测都能在不同的 k 值选择下表现出稳定




图 8 备件数据集备件 A 需求序列二维表征

Fig. 8 2D representation of spare parts A series for spare parts dataset




图 9 超参数 k_{Top} 敏感性分析

Fig. 9 Hyperparameter k_{Top} sensitivity analysis




图 10 各序列的滞后时间试验变化曲线

Fig. 10 Test on lag time of different agricultural products

的性能。

3.5.3 滞后时间试验

时间序列预测问题需要确定滞后时间,即用前几天的序列值来预测后一天的序列值。为验证TECNet模型滞后时间设置为多少时预测效果才能达到最优,设置了不同滞后时间的预测试验。其他参数与网格搜索后得到的最优参数保持一致,试验结果如图10所示。当滞后时间为12个月时,预测误差达到最小。在滞后时间为4个月、7个月和12个月时,预测误差较小,当滞后时间为12个月时,预测精度最高。滞后时间在3~6个月时,预测误差先降低后增加,说明一味地增加滞后时间并不一定能带来性能的提升。在对滞后时间进行设置时,需要充分考虑历史数据对未来走势的影响,同时也要避免过度依赖过去数据而导致的预测误差增加的情况。

4 结束语

本研究针对农机备件需求量非线性、多零值、波动大等特点,提出了一种新型的时间序列高效卷积网络用于农机备件需求预测。该方法通过快速傅里叶变换提取周期,将一维数据转换为二维空间表征,利用高效卷积模块提取特征,最后通过线性变换得到预测值。评估与验证过程使用了不同序列类型的农机备件需求数据。提出的方法与统计学习、机器学习、深度学习方法中具有代表性的模型进行比较,结果显示,本文的方法在备件A和备件D需求序列的预测中, RMSE、MAE、RMSSE 值分别为 38.776 件、30.8 件、0.776 和 8.185 件、5.8 件、0.205,所有指标均优于其他方法模型。在备件B需求序列的预测中, RMSE、MAE、RMSSE 值为 63.073 件、42.6 件、

1.349,仅次于 Informer 方法。在备件 C 需求序列的预测中, RMSE、MAE、RMSSE 值为 29.1 件、24 件、0.823,表现出色。除了本文方法,其他方法在某些序列类型上存在较严重的性能下降问题。本文方法在不同备件类型的预测任务上均展现出高效稳定的性能,综合性能指标总体平均 RMSSE 值达到 0.788,取得了最佳的综合性能指标,显著优于其他参考模型,证明了其在精准预测不同类型备件需求序列方面的有效性,对于农机备件的需求预测具有应用价值。

参 考 文 献

[1] CASOLARO A, CAPONE V, IANNUZZO G, et al. Deep learning for time series forecasting: advances and open problems[J]. Information, 2023, 14(11): 598.

[2] ABBASIMEHR H, SHABANI M, YOUSEFI M. An optimized model using LSTM network for demand forecasting [J]. Computers & Industrial Engineering, 2020, 143: 106435.

[3] 高龙. 基于 ARIMA 的小批量物料生产需求预测模型研究[J]. 现代信息科技, 2023, 7(15): 97 – 101.
GAO Long. Research on the small batch material production demand prediction model based on ARIMA [J]. Modern Information Technology, 2023, 7(15): 97 – 101. (in Chinese)

[4] ADHIKARI R, AGRAWAL R K. An introductory study on time series modeling and forecasting[J]. arXiv Preprint, arXiv: 1302.6613, 2013.

[5] 张舜, 杨欣, 魏津瑜. 基于预防性维修的农机备件需求预测问题研究[J]. 中国农机化学报, 2020, 41(6): 225 – 230.
ZHANG Shun, YANG Xin, WEI Jinyu. Research on forecasting of agricultural machinery spare parts demand based on preventive maintenance[J]. Journal of Chinese Agricultural Mechanization, 2020, 41(6): 225 – 230. (in Chinese)

[6] ZHANG T, ZHANG Y, CAO W, et al. Less is more: fast multivariate time series forecasting with light sampling-oriented MLP structures[J]. arXiv Preprint, arXiv:2207.01186, 2022.

[7] 秦海峰, 杨超, 侯兴明, 等. 基于变分模态分解的非稳态备件需求预测方法[J]. 火力与指挥控制, 2021, 46(11): 99 – 105.
QIN Haifeng, YANG Chao, HOU Xingming, et al. A prediction method of non-steady state spare parts demand based on variational modal decomposition[J]. Fire Control & Command Control, 2021, 46(11): 99 – 105. (in Chinese)

[8] 温彦博, 王卓, 白晓平. 基于改进 LightGBM 的农机服务备件配置预测方法[J]. 农机化研究, 2024, 46(4): 7 – 14.
WEN Yanbo, WANG Zhuo, BAI Xiaoping. Based on the pre-measurement method of agricultural service spare parts allocation modified to LightGBM[J]. Agricultural Mechanization Research, 2024, 46(4): 7 – 14. (in Chinese)

[9] HONGTAO L, SHUO L I U, JUNWEI D U, et al. Review of deep learning applied to time series prediction[J]. Journal of Frontiers of Computer Science & Technology, 2023, 17(6): 1285.

[10] 王小巍, 陈视桥, 金家善, 等. 备件需求预测中的不确定性问题研究综述[J]. 科学技术与工程, 2024, 24(4): 1338 – 1346.
WANG Xiaowei, CHEN Yanqiao, JIN Jiashan, et al. Spare parts demand forecasting: a review on uncertainty problems[J]. Science Technology and Engineering, 2024, 24(4): 1338 – 1346. (in Chinese)

[11] LIU Y, LI C, WANG J, et al. Koopa: learning non-stationary time series dynamics with koopman predictors[J]. Advances in Neural Information Processing Systems, 2023, 36: 12271 – 12290.

[12] MARTÍNEZ F, FRÍAS M P, PÉREZ M D, et al. A methodology for applying k-nearest neighbor to time series forecasting[J]. Artificial Intelligence Review, 2019, 52(3): 2019 – 2037.

[13] 梁宏涛, 刘硕, 杜军威, 等. 深度学习应用于时序预测研究综述[J]. 计算机科学与探索, 2023, 17(6): 1285 – 1300.
LIANG Hongtao, LIU Shuo, DU Junwei, et al. Review of deep learning applied to time series prediction [J]. Journal of Frontiers of Computer Science and Technology, 2023, 17(6): 1285 – 1300. (in Chinese)

[14] WU H, HU T, LIU Y, et al. Timesnet: temporal 2d-variation modeling for general time series analysis[J]. arXiv Preprint, arXiv:2210.02186, 2022.

[15] MA S, ZHANG T, ZHAO Y B, et al. TCLN: a transformer-based conv – LSTM network for multivariate time series forecasting [J]. Applied Intelligence, 2023, 53(23): 28401 – 28417.

[16] LIU Z, LIN Y, CAO Y, et al. Swin Transformer: hierarchical vision transformer using shifted windows[C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012 – 10022.

[17] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C] //2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015: 1 – 9.

[18] XIE S, GIRSHICK R, DOLLÁR P, et al. Aggregated residual transformations for deep neural networks[C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 5987 – 5995.

[19] 祁宣豪, 智敏. 图像处理中注意力机制综述[J]. 计算机科学与探索, 2024, 18(2): 345 – 362.
QI Xuanhao, ZHI Min. Review of attention mechanisms in image processing[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(2): 345 – 362. (in Chinese)

[20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770 – 778.

[21] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510 – 4520.

[22] TAN M, LE Q. EfficientNet: rethinking model scaling for convolutional neural networks[C] // Proceedings of the 36th International Conference on Machine Learning. PMLR, 2019: 6105 – 6114.

[23] TAN M, CHEN B, PANG R, et al. MnasNet: platform-aware neural architecture search for mobile[C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 2815 – 2823.

[24] ENGLE R, YOO B S. Forecasting and testing in co-integrated systems[J]. Journal of Econometrics, 1987, 35(1): 143 – 159.

[25] 方雪清, 吴春胤, 俞守华, 等. 基于 EEMD – LSTM 的农产品价格短期预测模型研究[J]. 中国管理科学, 2021, 29(11): 68 – 77.
FANG Xueqing, WU Chunyin, YU Shouhua, et al. Research on short-term forecast model of agricultural product price based on EEMD – LSTM[J]. Chinese Journal of Management Science, 2021, 29(11): 68 – 77. (in Chinese)

[26] HYNDMAN R J, KOEHLER A B. Another look at measures of forecast accuracy[J]. International Journal of Forecasting, 2006, 22(4): 679 – 688.

[27] ZENG A, CHEN M, ZHANG L, et al. Are transformers effective for time series forecasting? [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2023: 11121 – 11128.

[28] ZHOU H, ZHANG S, PENG J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 11106 – 11115.

~~~~~

( 上接第 261 页 )

[22] 靳伟, 张学军, 丁幼春, 等. 基于 EDEM – Fluent 的残膜与杂质悬浮分离仿真与试验[ J ]. 农业机械学报, 2022, 53( 4 ): 89 – 98.  
JIN Wei, ZHANG Xuejun, DING Youchun, et al. Experiment on suspension separation of residual film and impurity based on EDEM – Fluent coupling[ J ]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53( 4 ): 89 – 98. ( in Chinese )

[23] 王昭宇, 陈学庚, 颜利民, 等. 随动式残膜回收机起膜拾拾机构设计与试验[ J ]. 农业机械学报, 2021, 52( 4 ): 80 – 90.  
WANG Zhaoyu, CHEN Xuegeng, YAN Limin, et al. Design and experiment on collecting and removing device for profile modeling residual plastic film collector[ J ]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52( 4 ): 80 – 90. ( in Chinese )

[24] 杨松梅, 陈学庚, 颜利民, 等. 残膜回收机带式卷膜装置设计与试验[ J ]. 农业机械学报, 2021, 52( 2 ): 135 – 144.  
YANG Songmei, CHEN Xuegeng, YAN Limin, et al. Design and experiment on belt-type curl-up film device for residual plastic film recycling machine[ J ]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52( 2 ): 135 – 144. ( in Chinese )

[25] 蒋德莉, 颜利民, 陈学庚, 等. 纵向型钉齿链式地膜拾拾装置设计与试验[ J ]. 农业机械学报, 2025, 56( 1 ): 267 – 281.  
JIANG Deli, YAN Limin, CHEN Xuegeng, et al. Improved design and test of longitudinal nail-tooth-chain plastic film pickup device[ J ]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56( 1 ): 267 – 281. ( in Chinese )

[26] 营雨琨, 霍尚, 王敏, 等. 1. MSF – 2.0 残膜回收打捆与秸秆粉碎联合作业机设计与试验[ J ]. 干旱地区农业研究, 2025, 43( 2 ): 281 – 293.  
YING Yukun, HUO Shang, WANG Min, et al. Design and experiment of 1. MSF – 2.0 plastic film recycling bundling and straw crushing joint operation machine[ J ]. Arid Region Agricultural Research, 2025, 43( 2 ): 281 – 293. ( in Chinese )