

## 基于多维度综合决策的猪肉价格时间序列预测模型

李蓊涛<sup>1</sup>,姚瑶<sup>2</sup>,李颖<sup>2</sup>,陈晓<sup>3</sup>,张国锋<sup>1\*</sup>

1. 泰山学院信息科学技术学院, 山东 泰安 271000
2. 山东农业大学经济管理学院, 山东 泰安 271018
3. 泰山学院数字经济学院, 山东 泰安 271000

**摘要:** 山东省是畜牧业大省,猪肉价格波动对居民生活质量有着重大影响,目前,关于山东省生猪价格波动的预测研究较少,且存在预测时间较短,时间窗口狭窄和预测结果不准确等问题。针对传统预测模型存在长时序预测准确率不足的问题,本文提出了一种基于综合决策机制的时间序列预测模型。首先,将时间序列信息进行分解,通过可逆归一化将数据特征进行放大,以提取更多的价格波动信息;在信息分解的基础上,通过上采样扩充先验知识,并采用多维度综合决策的方式,增强多层感知机的数据特征挖掘能力和决策能力;最后,将先验知识与预测结果进行直接映射,解决了窗口狭窄和滑动窗口迭代预测导致的误差累积问题。试验结果表明,相较于 ARIMA、Prophet-BP、GA-BP、VMD-LSTM 和 STL-Informer 模型,本文算法在 RMSE (Root mean square error) 和 MAE (Mean absolute error) 指标上平均提升了 50.2% 和 30.9%,在  $R^2$  (Coefficient of Determination) 指标上的稳定性优于上述对比算法,平均提升了 60.2%。本文所提出的算法对于山东省生猪市场的预测性能更优,有助于相关部门对生猪价格波动做出科学决策。

**关键词:** 猪肉价格; 时间序列预测; 趋势分解; 上采样; 多维度决策

中图分类号: F323.7

文献标识码: A

文章编号: 1000-2324(2026)01-0117-14

## Time Series Prediction Model for Pork Prices Based on Multi-dimensional Comprehensive Decision-making

LI Ji-tao<sup>1</sup>, YAO Yao<sup>2</sup>, LI Ying<sup>2</sup>, CHEN Xiao<sup>3</sup>, ZHANG Guo-feng<sup>1\*</sup>

1. College of Information Science and Technology/Taishan University, Tai'an, 271000, China

2. School of Economics and Management/Shandong Agricultural University, Tai'an 271018, China

3. College of Digital Economy/Taishan University, Tai'an, 271000, China

**Abstract:** Shandong Province is a major hub for animal husbandry, and pork price fluctuations have a significant impact on residents' quality of life. Currently, there is limited research on predicting hog price fluctuations in Shandong Province, and issues such as short prediction horizons, narrow time windows, and inaccurate forecasting results persist. To address the insufficient accuracy of traditional prediction models in long-term time series prediction, this paper proposes a time series prediction model based on a comprehensive decision-making mechanism. Firstly, this study decomposes time series information and amplifies data features through reversible normalization to extract more price fluctuation information. Based on the information decomposition, it expands prior knowledge via upsampling and enhances the data feature mining and decision-making capabilities of the multi-layer perceptron through multi-dimensional comprehensive decision-making. Finally, it directly maps prior knowledge to prediction results, thereby addressing the issues of narrow windows and error accumulation caused by sliding window iterative prediction. The experimental results show that compared with models such as ARIMA, Prophet-BP, GA-BP, VMD-LSTM, and STL-Informer, the algorithm in this paper achieves an average improvement of 50.2% and 30.9% in RMSE and MAE indicators, respectively. Furthermore, it exhibits superior stability in the  $R^2$  indicators, with an average improvement of 60.2% over the aforementioned comparative models. The proposed algorithm exhibits better forecasting performance for the hog market in Shandong Province, which can assist relevant departments in making scientific decisions regarding hog price fluctuations.

**Keywords:** Pork price; time series prediction; trend decomposition; up-sampling; multi-dimensional decision

收稿日期: 2025-03-22

修回日期: 2025-12-26

基金项目: 山东省自然科学基金项目(ZR2024MF120); 泰安市科技创新发展项目(政策引导类)(2023NS135、2023NS106、2023ZC485)

第1作者简介: 李蓊涛(1990-),男,博士,讲师,研究方向:深度学习算法。E-mail:ljt@tsu.edu.cn

\*通讯作者: Author for correspondence. E-mail:zhangguofeng@tsu.edu.cn

中国是全球猪肉生产和消费大国,其生产和消费总量均位列世界第一,根据《中国统计年鉴》、美国农业部和经济合作与发展组织数据库的数据,2024年中国猪肉产量为5 706万t,占全球猪肉总产量超过一半。现如今,生猪产品在畜产品消费中保持优势地位,是居民最主要的肉食来源,猪肉价格的波动会直接影响居民的日常开销。例如2018年的非洲猪瘟爆发,导致中国各省猪肉价格在短时间内快速上涨,直接扰乱了市场猪肉价格的稳定,引发百姓恐慌,也让监管部门意识到建立一套有效的预警机制可以有效避免市场在突发疫情情况下受到冲击,这对维护市场价格稳定具有非常重要的实际意义<sup>[1,2]</sup>。

现如今各种类型的时间序列预测方法也广泛地用于畜禽养殖业数据分析和预警工作中,不仅可以提供行业决策支持,还可以有效地预知风险和抵御风险<sup>[3]</sup>。基于此,石庆兰等提出了BiLSTM-GRU融合神经网络预测模型,用于预测稻虾养殖中的溶解氧含量,降低养殖风险<sup>[4]</sup>;杨亮等为提高猪舍氨气浓度预测精度和效率,提出基于经验模态分解和长短时记忆神经网络相结合的预测模型EMD-LSTM,降低氨气排放对生态环境的污染<sup>[5]</sup>;刘春红等提出了基于ARIMA-BP神经网络的猪舍氨气浓度组合预测方法,同样为猪舍环境精准调控管理提供依据<sup>[6]</sup>;王润周等提出一种农产品价格预测模型CT-BiSeq2seq,对北京丰台区批发市场的白条猪肉价格进行实证分析<sup>[7]</sup>。

猪肉作为居民重要的肉食来源,其价格的稳定具有重要意义。在猪肉价格预测与预警方面,任青山等提出基于BP神经网络与多元回归分析的组合预测模型,从供给、需求、市场外因素等方面综合分析生猪价格,试验表明其预测精度高于单一模型<sup>[8]</sup>;吴培等分别使用ARIMA模型、GM模型和组合模型ARIMA-GM-RBF对猪肉价格进行了分析和预测,结果显示ARIMA模型适合进行短期预测,GM模型适合中长期预测<sup>[9]</sup>;魏嘉妮使用基于GA-BP的神经网络模型对猪肉价格进行预测分析,并分析了后疫情时代中国生猪价格的趋势<sup>[10]</sup>;刘合兵等使用LSTM混合模型对猪肉价格进行预测研究,其算法经过特征学习后,CEEMDAN-PCA-CNN-LSTM模型可以拟合价格的走势<sup>[11]</sup>;胡春安等提出了基于VMD-BO-

BiLSTM的猪肉价格预测模型,将原序列划分为若干个有效子序列,减小了序列非线性、上下波动的特性对预测模型精度的影响<sup>[12]</sup>;叶勇使用了Prophet-BP模型对猪肉价格进行了预测研究,实现了猪肉价格波动的可视化预测<sup>[13]</sup>;Guo等使用STL模型的季节性和趋势分解对猪肉价格进行分解,使用LSTM和SARIMA模型对猪肉价格进行预测<sup>[14]</sup>;Sun等使用了VMD-EEMD-LSTM方法分解原始序列,通过EEMD平滑价格波动曲线,借助强化学习方法提高模型预测能力,并以此对猪肉价格进行了短期预测<sup>[15]</sup>;Fu等使用EEMD与LSTM结合的方法对猪肉价格进行了预测<sup>[16]</sup>;Ye等通过将Heterogeneous Graph与LSTM相结合的方法对生猪价格进行了短期预测<sup>[17]</sup>。

现有的猪肉价格预测多数基于传统的记忆单元,而传统时间序列算法只能应对短期预测,存在不足<sup>[18]</sup>,针对上述问题,Zhou等提出了基于注意力机制的时间序列预测方法Informer,其在长时间序列预测方面大幅度超越了LSTM和GRU方法,成为时间预测方法的主流<sup>[19]</sup>。王杰等基于Informer模型提出了一种新的价格预测组合模型STL-Informer-ARIMA,用季节性和趋势分解法对猪肉(白条猪)价格进行分解,采用ARIMA模型对季节项进行预测<sup>[20]</sup>。线性预测模型Dlinear以简单的线性映射在长序列时间预测任务中取得了优于其他时间序列预测模型的预测效果,作为一种最简单的多层感知器模型,其计算复杂度低、运行效率高,相较于自注意力算法具有很大的优势<sup>[21]</sup>。Li等基于RevIN+Linear的线性预测模型进行了多角度的分析试验,讨论并验证了基于多层感知机的时间序列模型对时间序列特征提取的有效性<sup>[22]</sup>。

然而,综合分析现有相关文献的具体实现细节可知,现有猪肉价格预测模型主要聚焦于月平均价格的短期预测,但月度数据因数值平均,会使数日或数周的不稳定波动在统计学上被掩盖;且月度数据量较小,先验数据不足导致问题分析维度受限。此外,部分论文指出,受限于算法性能,现有基于记忆单元的深度学习方法在长时间序列预测中会无限放大预测差值,致使预测结果与实际价格偏差较大,无法满足实际市场对精准预测的需求。为解决上述问题,同时为市场提供

更加精确的评价与预警标准,本文构建了一种生猪价格日度预测模型 RMLP (the RevIN-Based Multi-layer Decision Process Pork Price Daily Prediction Model)。该模型以数据驱动为核心,运用可逆归一化和趋势分解精准提取时间序列中的关键特征;通过上采样和多维度综合决策,避免单一决策单元在时间序列特征提取过程中出现的局部误差,充分挖掘了时间序列中的特征信息;最终,将先验知识与预测信息进行了有效映射,降低了模型在长时间预测问题中的波动,提高了预测结果的准确性和稳定性。

## 1 数据来源与处理方法

### 1.1 数据来源

为了保证本次预测结果的准确性和有效性,本文数据均来源于中国养猪网(zhuwang.com.cn),该网站通过折线图的形式展示过去月、季、年的价格走势。本次试验选取2015年11月25日至2024年9月2日的日度生猪价格数据,共3 187条数据,按照传统的有监督学习方式将数据集按

6:2:2的比例划分为训练集、测试集和验证集,并选取多种算法在验证集上进行了对比验证。

其中本文试验将数据集分为了两个部分,数据集一为2018年11月12日到2023年11月12日,数据集数量为1 808条。在子数据集中,由于经历了2018年的猪瘟,猪肉价格迅速上涨,并在高位持续两年时间(见图1)。

从图1可以看出,训练集均为高价位状态下的数据,而验证集和测试集均为猪肉价格回落出现小幅波动的时间段的数据,本数据集可以验证本文算法在训练集与验证集数据分布不同情况下的特征提取能力。

数据集二包含全部数据集,其时间跨度为2015年11月25日至2024年9月2日(见图2),数据集涵盖的时间范围为9年,其中2015-2018年猪肉价格较为平稳,大致浮动于10~25元区间内,2018-2021年猪瘟暴发时猪肉价格出现了大幅上涨,直到2022-2024年间的价格区间再次趋于稳定。该数据集包含1 912条数据,该数据集可用于验证算法在面对不同价格波动区间时的信息提取能力。




图1 数据集一2018-2023猪肉价格走势

Fig. 1 Pork price trend chart from 2018 to 2023 for dataset 1




图2 数据集二2015-2024猪肉价格走势

Fig. 2 Pork price trend chart from 2015 to 2024 for dataset 2

## 1.2 处理方法

由于影响生猪价格的外界因素复杂且难以预知,文献[21]和文献[22]讨论了多元时间序列预测中多元素间的影响问题,如果单纯增添变量和属性,模型就需要对这些变量和属性的时间序列进行综合预测,由于时间序列预测长度较长,多元属性的联合预测反而会增加模型的不确定性。而上述两种算法均采用各属性分别建立模型、以通道独立的策略进行独立预测的方式,现有的时间序列模型设计过程中也大多遵循通道独立策略<sup>[23]</sup>。本文算法设计同样遵循通道独立策略,只选择猪肉价格这一单一属性进行验证试验,简化了模型训练的同时,降低了多属性分析之间的干扰。

传统的生猪价格预测方法大多基于月度数据进行分析,但月度数据因精度问题无法为市场提供更精确的评价与预警标准。以日度数据为基础、针对山东省生猪价格波动的研究总体偏少,且日度生猪市场价格波动较大,对算法性能要求更高,传统的基于记忆单元的神经网络方法已无法满足现实需求。基于上述分析,生猪价格预测模型设计仍面临两大问题:一是本文算法所用数据集为单一属性数据集,受我国猪肉价格市场信息化起步较晚的影响,数据量较小,不利于深度学习模型训练;二是价格波动信息量少,回溯窗口过短无法为模型提供足够先验知识,过长则会导致特征提取困难和过拟合问题。

为解决上述问题,本文提出了RMLP方法。具体而言,首先通过可逆归一化和趋势分解模块,解决数据漂移和价格频繁波动所造成的时序特征提取困难的问题;继而,借助上采样的方式丰富时序信息、放大波动特征,在有限的窗口内提供更多的先验知识,增强对价格波动的细节提取能力;最终,采用多感知机综合决策的方法,避免了单决策系统因决策维度单一而在特征提取过程中陷入过拟合的问题,同时增强了时序信息的提取能力。

**1.2.1 可逆归一化(RevIN)** 猪肉价格波动十分频繁,这导致其在时间窗口内的统计属性经常发生变化,即数据分布随时间窗口推移而变化。同时,由于不同回溯窗口内的数据波动范围存在差异,从中所提取到的特征也出现大范围漂移,使得这些数据在统计学上无法进行统一处理,这种

时间分布变化是阻碍对时间序列信息精确建模的主要挑战之一。针对上述问题,本文采用RevIN模块来解决数据漂移问题。

RevIN作为一种预处理方法,现已广泛用于时间序列预测建模中。其由两个不同的模块构成,分别是窗口数据归一化和逆归一化过程,前者对输入进行归一化,根据均值和方差来固定其分布,而后者将输出返回到原始分布。其公式如下:

$$E_t[x_{kt}^i] = \frac{1}{T_x} \sum_{j=1}^{T_x} x_{kj}^i \quad (1)$$

$$\text{Var}[x_{kt}^i] = \frac{1}{T_x} \sum_{j=1}^{T_x} (x_{kj}^i - E_t[x_{kt}^i])^2 \quad (2)$$

$$\hat{x}_{kt}^i = \gamma_k \frac{x_{kt}^i - E_t[x_{kt}^i]}{\sqrt{\text{Var}[x_{kt}^i] + \varepsilon}} + \beta_k \quad (3)$$

$x_{kj}^i$ 表示的是时间窗口内的猪肉价格数据,其平均值与方差的算法与传统算法无异,其中均值和方差的计算已由公式(1)和公式(2)给出。而具体的归一化如公式(3),其中 $\varepsilon$ 、 $\gamma$ 和 $\beta$ 为可学习参数,其在归一化训练过程中可以随时变化,用于应对不同窗口间的。 $\hat{x}_{kt}^i$ 为原始价格数据归一化后的数据,将窗口内数据减去均值除标准差就将数据分布转化为典型的高斯分布,再乘以 $\gamma$ 后加上 $\beta$ ,其中 $\gamma$ 值的大小决定了高斯峰值, $\beta$ 决定了偏移方向,避免归一化过程结果出现漂移。而其逆归一化过程如公式(4)所示。

$$\hat{y}_{kt}^i = \sqrt{\text{Var}[x_{kt}^i] + \varepsilon} \cdot \left( \frac{\hat{y}_{kt}^i - \beta_k}{\gamma_k} \right) + E_t[x_{kt}^i] \quad (4)$$

其中 $\hat{y}_{kt}^i$ 为模型的预测数据,根据公式(4),使用相同的缩放与移动数值将模型训练结果进行还原,让每个样本的过去窗口重新做一次归一化,然后记录归一化系数,并将归一化后的过去窗口输入模型中预测未来窗口,并将未来窗口逆归一化,得到逆归一化后还原的数据 $\hat{y}_{kt}^i$ 。通过上述方法可以有效避免数据的漂移问题,提高时间序列预测的准确性。

**1.2.2 趋势分解** 本文算法所使用的趋势分解步骤主体思路借鉴了ARIMA的信号分解方法(见图3),

本文主要基于山东省生猪价格波动日度数据展开研究,由于日度价格波动幅度较大,频繁的价格波动导致模型在提取趋势特征和周期性特征时面临困难,因此本研究采用趋势分解的方




图3 趋势分解过程

Fig. 3 Trend decomposition process

法来剔除外部因素的影响。本文算法的趋势分解模块将原先的时序数据分解为趋势项和残差项,其中趋势项使用是对原始数据做平均池化所得,残差项是原始数据和池化所得数据的差值,通过上述方法,可以剔除周期性波动对模型特征提取的干扰,提高模型预测的准确率。

趋势分解计算方法如公式(5)和公式(6)。

$$X_t = AvgConv(x) \quad (5)$$

$$X_s = X - X_t \quad (6)$$

其中该类算法存在如下优势:(1)路径短,捕获的长短期关系效果好;(2)更少的内存、参数和更快的推理速度;(3)结构简单,可解释性探索相对容易;(4)超参数少,不需要过多地针对参数进行调优。

1.2.3 维度扩展及多维度决策 时间序列数据处理过程中,普遍存在因输入长度不足而导致时间序列特征提取不完整的问题。猪肉价格的波动

受到复杂周期性因素和外部趋势的影响,增加了特征提取的难度;同时,采用现有较短的回溯窗口输入,模型提取到的信息特征会过于单一,会由于缺少多维度的综合决策的依据,进而容易引发过拟合问题。因此,本文算法在模型输入方面应用了维度扩展块,以增强模型的特征提取能力。具体来说,输入回溯窗口  $X_t \in R^N$  权重向量  $d \in R^{L \times d}$ ,通过  $H_t = X_t \times d$  以获得更具表现力的隐藏表示  $H_t \in R^{N \times L \times d}$  从而带来更多语义信息,其中  $N$  为批大小, $L$  为回溯窗口的长度, $d$  为权重向量的维度。通过此种上采样可以在不改变原有时间序列骨架的同时,保留时间序列变化特点。多维度决策模块是在上采样模块的基础上,对应回溯窗口生成一个多维权重向量  $d \in R^{c \times L \times d}$ ,其中  $c$  为多维决策的维度,在输入模块将得到的信息进行重排列后,变为  $H_t \in R^{N \times c \times (L \times d)}$ ,并将输入后续的 MLP 单元进行映射并融合(见图4)。

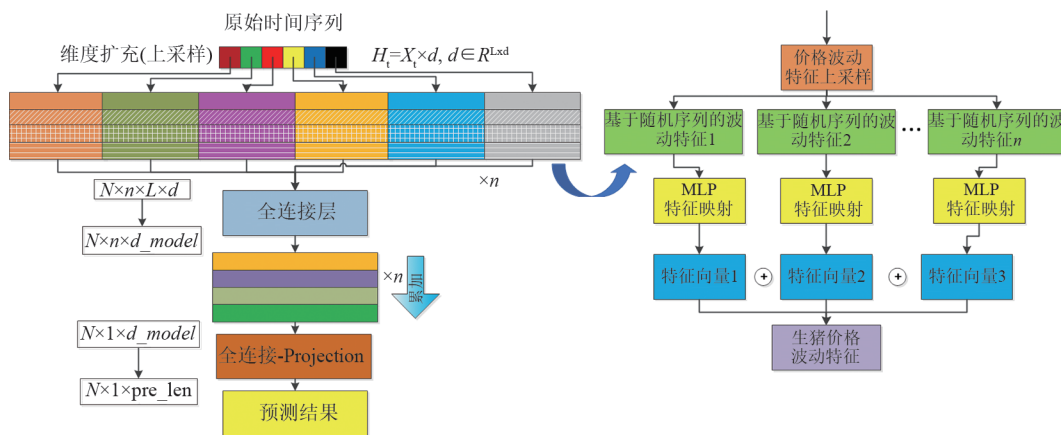


图4 时间序列预测模块构成

Fig. 4 Composition of the time series prediction module

为了提取时间序列波动特征,本文算法使用 MLP 单元将扩展后的数据通过映射-累加-映射的方式提取有效特征。每个 MLP 模块都包含 2 个全连接层,其中包括一个特征提取层用于将时

间序列映射成为特定长度的特征向量,随后多种映射后的特征向量会再进行融合,其思路类似于集成学习机制,避免单一特征提取单元造成的特征提取不足的问题。特征提取后加入 1 个非线

性激活函数RELU(Linear rectification function), 最后一个时间序列预测层将融合后的特征向量映射为时间序列预测结果。

MLP是一种全连接前馈神经网络,输入数据通过隐藏层计算后,由输出层神经元进行输出。本文算法特征提取模块作用过程如公式(7)。

$$pred = \omega_2 \left( \Phi \left( \sum_{i=1}^n (\omega_1(H_i)) \right) \right) \quad (7)$$

其中,  $\Phi$  表示作用于输入元素的非线性激活函数RELU,  $\omega_1$  和  $\omega_2$  表示 MLP 模块中的全连接层,其作用相当于分阶段的下采样过程。  $H_i$  表示的是上采样后的时间特征向量,对趋势分解完的趋势项和周期项进行分别处理,本文算法中其输入层的输入变量为猪肉在一个时间序列内的价格,输出为预测价格波动,算法复杂度低。

本文算法流程见图 5:

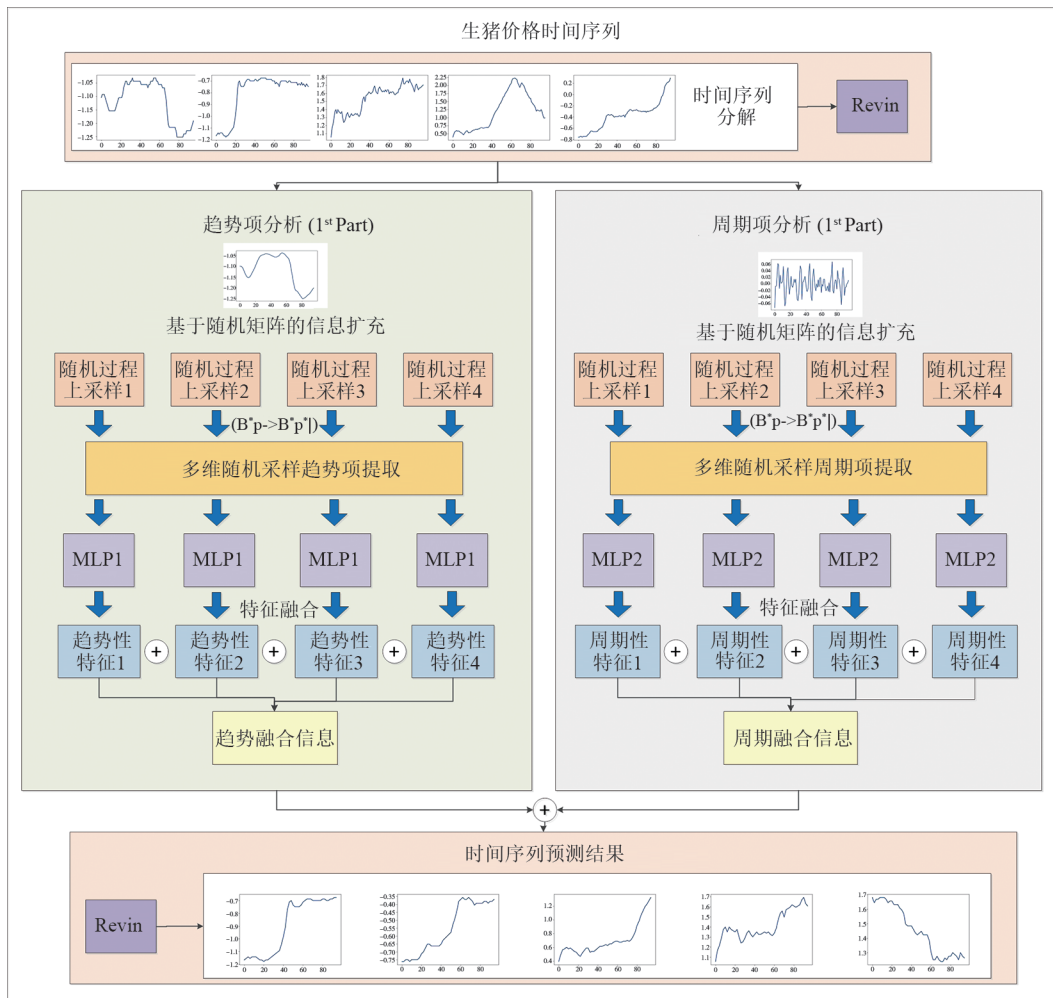


图 5 算法流程图

Fig. 5 Flow diagram of the algorithm

## 2 评价指标和模型评估

### 2.1 本文试验环境

本文算法的仿真试验在 win10 操作系统下的 python 3.11.4 的环境下实现,所使用的深度学习框架为 pytorch 2.2.2+cuda 11.8 的版本,其中支持深度学习模型训练硬件为 CPU Intel(R) Core

(TM) i7-1260P (16G), 以及 GeForce RTX 3090, 在数据读取和预处理阶段所使用的框架为 pandas 2.0.3, numpy 1.25.2 以及 scikit-learn 1.3.0。

### 2.2 评价指标介绍

本文试验中所有的价格数据都经过标准化处理,其核心目的是将不同量纲、不同范围的数据调整到统一的尺度,消除量纲的影响,提升数

据的稳定性,以便后续分析和建模,可表示为公式(8):

$$x' = \frac{x - \bar{x}}{\text{var}(x)} \quad (8)$$

本文算法的核心目标是所得到与实际情况高度契合的模型预测结果,为系统性评估所提方法的性能,本文选用的评价指标包括均方根误差(Root mean square error, RMSE)、平均绝对误差(Mean absolute error, MAE)作为关键评价指标。上述两个指标均用于衡量模型预测值与真实值之间的差异程度,通过不同的计算方式反映误差特性,为模型优化和性能比较提供依据。RMSE通过平方运算放大较大误差的影响,适用于对极端偏差敏感的场景;而MAE以绝对值形式平等对待所有误差,更能体现预测结果的平均偏离水平。在模型评估中,当RMSE、MAE越小时,模型的精度与可靠性就越高。均方根误差为公式(9):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

平均绝对误差为公式(10):

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

其中  $n$  为测试集的数量;  $y_i$  为第  $i$  个样本点的真实值;  $\hat{y}_i$  为第  $i$  个样本点的预测值,其得到的数值越小,表明所得预测结果与真实值差距越小。

为全面评估模型的拟合性能,本研究进一步引入决定系数(Coefficient of Determination,  $R^2$ )作为补充指标,  $R^2$  指标可以有效衡量模型对因变量的解释能力,即衡量模型能否提取到猪肉价格波动的内在关联关系和波动趋势,其取值范围为  $(-\infty, 1]$ 。具体而言,其取值越接近 1 表示模型对数据的拟合程度越优,  $R^2$  的定义为公式(11):

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

其中,  $\bar{y}$  为所有真实值的平均数,  $\hat{y}_i$  为第  $i$  个样本点的预测值。

### 2.3 模型定量评估

长期预测任务需要强大的算法性能作为支撑,为了证明本文算法在长时间序列预测问题中的性能,本文选取了 SARIMA、文献[10]所使用的 Prophet-BP、文献[12]所使用的 GA-BP 神经网络、文献[13]所使用的 VMD-LSTM 网络和文献[20]所提出的 STL-Informer-ARIMA 算法用作对比试验对象。其中, SARIMA 是 ARIMA 模型的改进方法,具备更强的时序特征提取能力;文献[20]所提出的 STL-Informer-ARIMA 模型是一种短期预测模型,不具有长周期预测能力,因此本文保留了该模型中的周期项和方差项的数据处理部分,将 ARIMA 模型在季节项的处理方式替换为 Informer 模型的线性映射,从而构建本章节的 STL-Informer 模型。

传统时间序列预测方法都是通过窗口滚动的方式进行预测,即使用  $1 \sim t$  时刻的数据预测  $t+1$  时刻的数据,再使用  $2 \sim t+1$  时刻的数据预测  $t+2$  时刻的数据并以此类推(见图 6(a))。SARIMA、Prophet-BP、GA-BP 和 VMD-LSTM 模型在本质上都是短期预测方法,都需要借助窗口滚动的方式进行预测。而本文算法所使用的方法为使用多层感知机直接将历史信息与预测信息进行映射(见图 6(b)),不同于传统的迭代多步预测,本文将时序信息看作一个整体信号,通过时间序列的整体分析,挖掘历史与未来之间的关联关系并整体预测,避免了传统算法因多次滚动而导致的误差放大问题。




图 6 长时间序列预测滚动预测与直接映射

Fig. 6 Rolling prediction vs. direct mapping for long-term time series prediction

本文选取了长度为[32, 64, 96, 128]的回溯窗口(Look-back Window, LW),并根据先验知识得到长度为[16, 32, 48, 64]的时间序列预测结果,其中 RMLP、GA-BP、VMD-LSTM 和 STL-Informer 算法需要使用训练集进行预训练,而 SARIMA 和 Prophe-BP 算法属于基于统计学传统算法,无须训练直接使用验证集进行验证。本文算法的超参数(见表1)。

在数据集一上,本文所提出的生猪价格预测的算法在各个指标上相较于其他传统算法均展现出显著优势,根据 RMSE 和 MAE 的试验结果(见表2),在回溯窗口取值从[32, 64, 96, 128]不

**表 1 超参数设置**  
**Table 1 Hyperparameters setting**

超参数 Hyper-parameters	超参数功能说明 Clarifications	数值 Values
train_epoch	训练轮数	20
batch_size	输入数据批处理数量	64
hidden_size	特征维度大小	512
Embedding_size	随机映射维度大小	128
learning_rate	学习率	0.000 1
Decision_size	上采样个数	8

断拉长的情况下,意味着模型所需处理的先验知识数量增多,这对模型的信息提取能力提出了更高要求。

**表 2 基于数据集一的猪肉价格预测 RMSE 和 MAE 指标对比**  
**Table 2 Comparison of RMSE and MAE indicators for pork price prediction based on dataset 1**

		RMLP		SARIMA		Prophe-BP		GA-BP		VMD-LSTM		STL-Informer	
		RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
32	16	<b>0.012 9</b>	<b>0.069 8</b>	0.022 1	0.088 8	0.022 5	0.098 8	<u>0.013 1</u>	<u>0.073 5</u>	0.020 5	0.107 1	0.013 8	0.075 7
	32	<b>0.031 4</b>	<b>0.110 1</b>	0.078 5	0.161 0	0.064 4	0.166 0	0.075 6	0.163 2	0.058 2	0.173 0	<u>0.038 2</u>	<u>0.122 8</u>
	48	<b>0.060 3</b>	<b>0.150 9</b>	0.193 0	0.239 3	0.141 5	0.240 0	0.084 3	0.180 7	<u>0.072 4</u>	0.177 0	0.083 9	<u>0.175 4</u>
	64	<b>0.091 8</b>	<b>0.184 4</b>	0.404 1	0.319 9	0.263 7	0.320 3	0.133 4	0.227 5	<u>0.114 2</u>	0.242 6	0.137 8	<u>0.224 8</u>
64	16	<b>0.013 9</b>	<b>0.074 3</b>	<u>0.018 1</u>	<u>0.082 9</u>	0.039 0	0.132 0	0.045 0	0.113 1	0.025 2	0.110 4	0.026 2	0.107 7
	32	<b>0.034 7</b>	<b>0.117 0</b>	<u>0.055 1</u>	<u>0.149 0</u>	0.101 6	0.219 5	0.197 8	0.214 5	0.058 1	0.166 4	0.069 6	0.173 6
	48	<b>0.063 7</b>	<b>0.157 8</b>	0.120 2	0.218 2	0.206 5	0.309 8	0.283 1	0.291 2	<u>0.101 6</u>	<u>0.228 0</u>	0.133 7	0.228 0
	64	<b>0.095 0</b>	<b>0.157 8</b>	0.216 5	0.286 7	0.350 3	0.402 0	0.358 5	0.288 1	<u>0.141 3</u>	<u>0.268 1</u>	0.189 4	0.266 5
96	16	<b>0.012 7</b>	<b>0.074 4</b>	<u>0.019 6</u>	<u>0.083 5</u>	0.063 9	0.161 8	0.063 6	0.137 5	0.034 7	0.126 6	0.056 8	0.169 5
	32	<b>0.032 0</b>	<b>0.116 2</b>	<u>0.062 4</u>	<u>0.149 4</u>	0.143 1	0.252 7	0.225 4	0.230 2	0.079 2	0.199 5	0.120 3	0.233 7
	48	<b>0.059 6</b>	<b>0.156 5</b>	0.150 4	0.227 2	0.260 6	0.348 1	0.266 4	0.289 8	<u>0.114 3</u>	<u>0.231 2</u>	0.194 2	0.286 0
	64	<b>0.089 0</b>	<b>0.189 0</b>	0.299 6	0.309 0	0.399 8	0.432 1	0.265 4	0.310 6	<u>0.168 6</u>	<u>0.284 5</u>	0.294 4	0.338 9
128	16	<b>0.014 5</b>	<b>0.077 5</b>	<u>0.017 3</u>	<u>0.077 5</u>	0.072 2	0.172 1	0.098 1	0.211 5	0.021 0	0.090 5	0.128 4	0.271 0
	32	<b>0.036 7</b>	<b>0.122 7</b>	<u>0.057 8</u>	<u>0.147 9</u>	0.152 9	0.258 9	0.305 1	0.349 9	0.076 2	0.204 3	0.209 0	0.324 4
	48	<b>0.065 2</b>	<b>0.164 8</b>	0.134 2	0.223 9	0.266 1	0.352 3	0.253 2	0.281 8	<u>0.124 8</u>	<u>0.238 6</u>	0.233 7	0.323 1
	64	<b>0.099 5</b>	<b>0.200 7</b>	0.252 6	0.298 9	0.385 9	0.422 7	0.273 0	0.350 5	<u>0.192 0</u>	<u>0.297 4</u>	0.335 9	0.396 9

注:最优结果使用红色加粗方式标注,次优结果使用绿色下划线标出。

Note: The optimal results are annotated in the bold way of red, the sub-optimal results are underlined in green.

从 RMSE 和 MAE 指标增长幅度来看,在预测长度越长的情况下,本文算法的预测结果没有出现大的波动,同时从整体结果可以看出,基于深度学习的时间序列预测算法的稳定性更强,原因在于,传统算法由于无法在历史数据中获取先验知识,其知识窗口认知狭窄继而导致了在中长期时间序列预测工作中精度不足的问题。

$R^2$  指标作为一个有监督学习的分类指标,其用于衡量数据模型的适应度(见表3),然而,在长时间序列预测中,由于其标签长度较长,会

导致  $R^2$  指标波动会很大,不过这反倒能更好地展示算法的性能细节。各类算法在数据集一上试验结果显示,随着预测长度的增加, $R^2$  指标都出现了快速的下降,在后续预测长度到达 64,其预测复杂度同时呈指数级上升时,SARIMA、Prophe-BP、GA-BP、VMD-LSTM 和 STL-Informer 算法结果都出现了很大的波动,只有本文算法的  $R^2$  值下降幅度较为平缓。综上所述,本文算法相较于其他对比算法在 RMSE、MAE 和  $R^2$  指标上具有较大优势,并展现了较好的长时间序

表 3 基于数据集一猪肉价格预测  $R^2$  指标对比  
Table 3 Comparison of  $R^2$  indicators for pork price prediction based on dataset 1

		RMLP	SARIMA	Prophe-BP	GA-BP	VMD-LSTM	STL-Informer
32	16	<b>0.882 7</b>	0.820 0	0.816 8	<u>0.880 2</u>	0.832 8	0.871 9
	32	<b>0.648 8</b>	0.224 7	0.363 9	0.155 1	0.425 8	<u>0.571 0</u>
	48	<b>0.182 1</b>	-1.289 4	-0.679 1	-0.142 3	<u>0.140 9</u>	-0.174 0
	64	<b>-0.463 6</b>	-4.646 9	-2.685 1	-0.922 1	-0.595 6	<u>-0.499 2</u>
64	16	<b>0.873 2</b>	<u>0.852 3</u>	0.682 3	0.590 3	0.794 9	0.561 0
	32	<b>0.642 4</b>	0.455 6	-0.030 0	-1.210 4	<u>0.426 3</u>	0.227 4
	48	<b>0.136 3</b>	-0.426 5	-1.449 5	-2.835 0	-0.205 3	<u>-0.141 1</u>
	64	<b>-0.513 5</b>	-2.025 9	-3.895 0	-4.713 3	-0.974 6	<u>-0.688 9</u>
96	16	<b>0.883 8</b>	<u>0.840 7</u>	0.480 0	0.420 2	0.717 7	0.307 0
	32	<b>0.642 7</b>	<u>0.384 2</u>	-0.412 6	-1.519 5	0.218 6	-0.239 8
	48	<b>0.191 9</b>	-0.784 9	-2.091 5	-2.611 5	<u>-0.355 9</u>	-0.540 4
	64	<b>-0.418 6</b>	-3.186 2	-4.587 3	-3.229 8	<u>-1.356 0</u>	-2.304 7
128	16	<b>0.868 1</b>	0.820 0	0.412 2	0.105 8	<u>0.828 9</u>	-0.842 9
	32	<b>0.590 3</b>	0.224 7	-0.509 4	-2.409 4	<u>0.248 2</u>	-2.477 4
	48	<b>0.116 3</b>	-1.289 4	-2.157 4	-2.432 7	<u>-0.480 9</u>	-2.967 3
	64	<b>-0.586 2</b>	-4.646 9	-4.392 3	-3.350 8	<u>-1.682 5</u>	-2.899 6

注:最优结果使用红色加粗方式标注,次优结果使用绿色下划线标出。

Note: The optimal results are annotated in the bold way of red, the sub-optimal results are underlined in green.

列预测性能。

在数据集二上,本文提出的生猪价格预测算法在各个指标上相较于其他传统算法都具有很大优势,根据 RMSE 和 MAE 的对比分析(见表

4),同样在回溯窗口取值[32,64,96,128]不断拉长的情况下,本文算法的性能基本可以保持稳定,其 MAE 和 RMSE 指标的变化相对较小,而其余算法结果均出现较大波动。

表 4 基于数据集二的猪肉价格预测 RMSE 和 MAE 指标对比  
Table 4 Comparison of RMSE and MAE indicators for pork price prediction based on dataset 2

		RMLP		SARIMA		Prophe-BP		GA-BP		VMD-LSTM		STL-Informer	
		RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
32	16	<b>0.012 4</b>	<b>0.073 4</b>	0.017 9	0.084 3	0.024 4	0.113 3	0.026 6	0.105 4	0.017 0	<u>0.086 1</u>	<u>0.014 1</u>	0.082 0
	32	<b>0.025 6</b>	<b>0.107 0</b>	0.054 8	0.135 1	0.062 3	0.176 3	0.045 0	0.129 9	0.035 1	0.118 7	<u>0.026 1</u>	<u>0.110 9</u>
	48	<b>0.033 0</b>	<b>0.127 0</b>	0.118 0	0.181 8	0.113 7	0.234 9	0.083 5	0.196 1	0.058 0	0.186 2	<u>0.041 3</u>	<u>0.143 9</u>
	64	<b>0.043 5</b>	<b>0.145 2</b>	0.204 8	0.205 4	0.189 2	0.294 8	0.085 1	0.196 4	0.179 9	0.387 2	<u>0.049 4</u>	<u>0.159 2</u>
64	16	<b>0.013 3</b>	<b>0.077 9</b>	<u>0.015 5</u>	<u>0.080 1</u>	0.026 9	0.121 0	0.019 7	0.098 0	0.038 6	0.157 8	0.019 8	0.100 3
	32	<b>0.026 9</b>	<b>0.112 0</b>	0.040 2	0.131 0	0.060 7	0.181 5	0.038 3	0.124 7	0.032 2	0.141 0	<u>0.029 5</u>	<u>0.122 4</u>
	48	<b>0.038 0</b>	<b>0.135 9</b>	0.072 4	0.173 9	0.107 4	0.233 3	0.052 7	0.150 6	0.051 7	0.166 8	<u>0.040 9</u>	<u>0.146 0</u>
	64	<b>0.043 5</b>	<b>0.150 2</b>	0.099 6	0.196 2	0.164 9	0.277 3	0.066 0	0.165 0	0.085 2	0.246 1	<u>0.055 7</u>	<u>0.168 7</u>
96	16	<b>0.013 9</b>	<b>0.082 6</b>	<u>0.015 9</u>	<u>0.083 4</u>	0.027 0	0.120 2	0.022 3	0.098 5	0.014 8	0.082 4	0.030 4	0.130 4
	32	<b>0.027 0</b>	<b>0.114 6</b>	<u>0.044 4</u>	<u>0.136 2</u>	0.056 1	0.172 3	0.058 0	0.152 6	0.049 5	0.165 4	0.047 9	0.152 1
	48	<b>0.038 7</b>	<b>0.139 8</b>	0.091 1	0.185 0	0.094 9	0.219 1	0.061 8	0.162 0	0.044 7	0.149 1	<u>0.054 4</u>	<u>0.156 0</u>
	64	<b>0.045 4</b>	<b>0.154 8</b>	0.167 6	0.226 6	0.143 5	0.259 3	0.075 5	0.171 1	<u>0.108 4</u>	<u>0.270 3</u>	0.109 0	0.228 5
128	16	<b>0.015 8</b>	<b>0.088 6</b>	<u>0.018 0</u>	<u>0.086 2</u>	0.028 6	0.125 8	0.027 1	0.112 9	0.029 5	0.114 3	0.081 1	0.201 8
	32	<b>0.028 6</b>	<b>0.120 3</b>	0.045 6	0.140 0	0.054 1	0.170 4	0.053 0	0.148 4	<u>0.034 3</u>	<u>0.144 1</u>	0.135 1	0.262 5
	48	<b>0.040 7</b>	<b>0.145 1</b>	0.088 8	0.189 0	0.088 0	0.211 9	0.077 2	0.182 6	<u>0.042 6</u>	<u>0.143 0</u>	0.139 7	0.261 1
	64	<b>0.044 6</b>	<b>0.154 9</b>	<u>0.116 5</u>	<u>0.199 7</u>	0.136 2	0.252 4	0.130 6	0.231 4	0.217 6	0.437 3	0.128 3	0.247 0

注:最优结果使用红色加粗方式标注,次优结果使用绿色下划线标出。

Note: The optimal results are annotated in the bold way of red, the sub-optimal results are underlined in green.

具体而言,从RMSE和MAE指标的表现来看,本文算法预测效果最优,其中STL-Informer在短期预测上排名第二,且该算法只适用于短期预测,随着回溯窗口的增长,其预测效果下降,SARIMA和VMD-LSTM在长期预测上效果较好。在将数据集数量增长一倍时,GA-BP和Prophet-BP算法的预测性能不足,原因是2015-2019年期间猪肉价格波动较小,而2019-2021年猪肉价格出现大范围的波动,验证集(2023-2024年)的样本同样波动较小,在训练集和验证集在数据分布相似的情况下,深度学习算法均可以得到较好的训练结果,其可以在短、中、长期预测上超越传统机器学习算法。

在长期时间序列结果中,本文算法相较于其他已有算法,其波动幅度在RMSE和MAE指标上变化较小,SARIMA和Prophe-BP这类传统算法在预测长度增长时会出现较大的波动。在试验中,预测长度从16增长为64,随着预测长度的增长,本文算法的预测效果变化不大,相对而言,SARIMA模型的稳定性差于Prophet-BP算法,

VMD-LSTM算法在长期预测上的表现和SARIMA算法相似,其预测性能不稳定,在RMSE和MAE上都出现了较大的波动。其大致原因是受2019-2021猪肉价格波动影响较大,导致了在长周期预测过程中出现了误差累积问题,进而导致了在评价指标上表现出不稳定性,STL-Informer算法在长时间序列预测任务上的RMSE和MAE指标也不稳定。

在 $R^2$ 指标的对比上(见表5),随着预测长度的增加,本文试验所选取算法的 $R^2$ 指标都出现了快速的下降。当预测长度为16时,各个模型所得结果仍较为理想,均能保持在0以上;在后续预测长度到达64,其预测复杂度同时呈指数级上升时,SARIMA、Prophe-BP、GA-BP网络、VMD-LSTM和STL-Informer算法结果都出现了很大的波动,只有本文算法的 $R^2$ 值仍保持在-2左右,其余算法的 $R^2$ 值都下降到-4以下。综上所述,本文算法相较于其他算法,在RMSE、MAE和 $R^2$ 指标上具有较大优势,并展现了较好的长时间序列预测性能。

表 5 基于数据集二猪肉价格预测  $R^2$  指标对比  
Table 5 Comparison of  $R^2$  indicators for pork price prediction based on dataset 2

		RMLP	SARIMA	Prophe-BP	GA-BP	VMD-LSTM	STL-Informer
32	16	<b>0.540 6</b>	0.354 6	0.155 8	0.016 7	0.371 5	<u>0.470 2</u>
	32	<b>0.088 2</b>	-0.987 0	-1.230 9	-0.636 9	-0.151 7	<u>0.057 0</u>
	48	<b>-0.097 6</b>	-2.959 6	-2.837 4	-1.780 5	-0.931 1	<u>-0.144 4</u>
	64	<b>-1.572 8</b>	-10.808 2	-9.745 2	-3.941 2	-4.988 5	<u>-1.210 2</u>
64	16	<b>0.505 8</b>	<u>0.441 0</u>	0.069 2	0.271 4	-0.431 0	0.359 8
	32	<b>-0.021 7</b>	-0.456 2	-1.172 3	-0.393 8	-0.194 2	<u>0.216 5</u>
	48	<b>-0.266 1</b>	-1.427 7	-2.625 2	-0.755 7	<u>-0.721 6</u>	-0.854 4
	64	<b>-1.732 0</b>	-4.742 0	-8.364 2	-2.833 5	-3.944 7	<u>-2.036 4</u>
96	16	<b>0.485 1</b>	0.426 2	0.065 3	0.172 8	<u>0.451 1</u>	0.280 8
	32	<b>-0.017 9</b>	<u>-0.608 5</u>	-1.009 2	-1.109 0	-0.799 7	-0.576 3
	48	<b>-0.288 7</b>	-2.058 1	-2.203 0	-1.058 5	<u>-0.487 4</u>	-1.059 2
	64	<b>-1.636 1</b>	-8.660 7	-7.152 9	<u>-3.382 0</u>	-5.294 0	-3.719 6
128	16	<b>0.416 2</b>	<u>0.378 4</u>	0.012 3	-0.001 7	-0.073 7	-0.176 2
	32	<b>-0.040 4</b>	-0.633 2	-0.935 1	-0.927 1	<u>-0.269 9</u>	-1.350 5
	48	<b>-0.355 2</b>	-1.997 7	-1.971 4	-1.568 9	<u>-0.419 7</u>	-2.188 3
	64	<b>-1.589 0</b>	-5.713 0	-6.736 6	-6.581 7	-11.631 6	<u>-4.384 3</u>

注:最优结果使用红色加粗方式标注,次优结果使用绿色下划线标出。

Note: The optimal results are annotated in the bold way of red, the sub-optimal results are underlined in green.

传统的长时间序列预测需要采用滚动窗口的方式逐步预测,虽然在短期预测上可以很大程度上与现实拟合,但随着时间线的拉长,预测

失误也被不断放大,准确率也就逐渐降低。本文算法通过RevIN模块解决了数据漂移问题,并通过趋势分解和多维决策方法学习价格的趋势

变化规律而非已有的价格变化经验,避免了训练集、测试集和验证集之间的数据分布不同的问题,从而获得了较好的指标结果。相比其他算法,本文算法无须使用滚动方式逐天迭代进行预测,其通过映射的方式直接将回溯窗口和预测数据建立线性关联,在理论上可以无视已预测的数据,而是将时间序列数据看作一个整体的信号,将过去与未来进行点对点的映射,避免了因为某天预测错误而导致的连锁反应。通过多维度的试验,较于 ARIMA、Prophet-BP、GA-BP、VMD-LSTM 和 STL-Informer 模型,本文算法在 RMSE 和 MAE 指标上平均提升了 50.2% 和 30.9%;在  $R^2$  指标上的稳定性优于对比算法,平均提升了 60.2%。

综上所述,本文算法可以取一个月到四个月的历史数据作为先验知识,进行 2 周到 9 周的价格预测,从各个指标的对比来看,相较于现有的猪肉价格预测算法,本文算法都可以保证效果最优且性能稳定。

## 2.4 模型定性评估

本章节展示了本文算法和 ARIMA、Prophet-BP、GA-BP、VMD-LSTM 和 STL-Informer 模型在回溯窗口均为 96(更长的历史知识),并根据先验知识预测长度为 64 的时间序列预测结果(见图 7),生猪价格的日度数据在整体上波动明显,在回溯窗口内也出现不规则性和大量的突变点,可以很好地测试各模型的特征挖掘能力和突变问题应变能力。

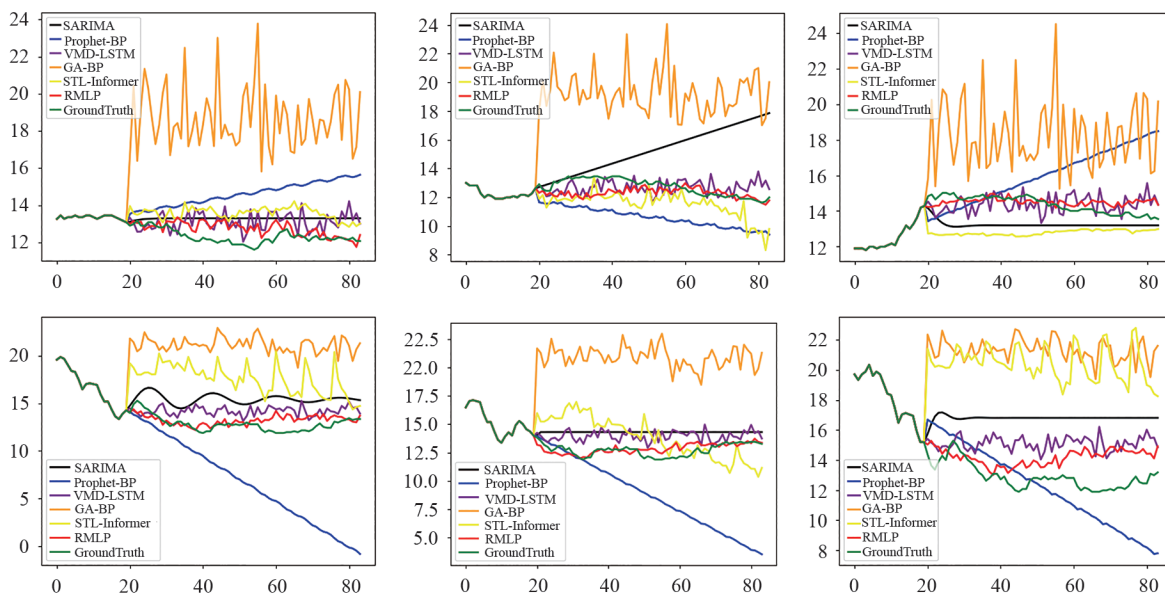


图 7 回溯窗口 96 预测 64 各算法结果对比

Fig. 7 Result comparison of each algorithm with look-back window 96 and prediction window 64

图中绿色曲线作为原始价格曲线,本文算法结果对应红色曲线,其他各类算法的预测结果由不同颜色的线标出,本章节则对预测结果的合理性进行论证。SARIMA 模型的结果主要是根据回溯窗口对算法的时间序列发展趋势进行了预测,而没有对每日猪肉的波动特征进行拟合,因此其预测结果更贴近于一条直线;Prophe-BP 算法结果与 SARIMA 模型相似,Prophe-BP 算法中虽对猪肉价格波动有一定的拟合,但其由于缺少先验知识,在结果中经常出现类似于直线的预测结果,而且其算法的拟合结果过于激进;GA-BP 神经网络作为一种初级的深度学习预测模型,其

可以拟合复杂的函数过程,但由于日度数据价格波动较大,阻碍了其特征学习的提取能力,从而导致其结果不稳定的问题;VMD-LSTM 是一种在线性网络上叠加记忆单元的方法,其预测结果较 GA-BP 神经网络有一定的提升,且结果较 GA-BP 神经网络更加稳定,但其在应对时间序列突变问题上能力较弱;STL-Informer 算法在长时序预测下的结果与实际有较大差别;只有本文算法在整体上则与原始曲线拟合程度较高,且在应对突变时能够快速反应,相较于上述对比算法,其长时间序列预测结果最好。

## 2.5 模型有效性分析

2.5.1 消融试验及参数有效性分析 为了验证本文所提出的生猪价格时间序列预测工作改进的有效性,本章节设计了消融试验。本文算法的设计框架是基于 DLinear 的深度学习框架,因此本章节选取了 DLinear、结合 RevIN 与多层 MLP 学习的 DLinear 微调算法,用于验证 RevIN 算法和更多层次的深度学习算法对猪肉价格波动信息的提取能力。本文算法的主要改进是添加了基

于多维度综合决策的改进算法,因此本章节验证了在 1 维度、4 维度和 8 维度综合决策情况下的 RMSE 和 MAE 指标下的时间序列预测结果,其中,维度代表随机上采样的维度,这一维度与多维决策中参数  $c$  的取值相对应,从理论上讲,参数  $c$  的值越大,模型决策维度越高,进而模型在应对短输入窗口情况下的特征提取能力也就越强。本章内容用于验证在加入了多维度决策机制的情况下,本文算法可以获得更强的时间序列信息挖掘能力(见表 6)。

表 6 基于数据集二的猪肉价格预测 RMSE 和 MAE 指标对比(消融试验)

Table 6 Comparison of RMSE and MAE indicators for pork price prediction based on dataset 2 (ablation experiment)

		DLinear		RevIN+MLPs		1D decision		4D decision		8D decision	
		RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
32	16	0.026 8	0.110 8	0.012 6	0.074 4	0.012 7	0.074 6	<u>0.012 5</u>	<u>0.073 8</u>	<b>0.012 4</b>	<b>0.073 4</b>
	32	0.039 8	0.135 3	<b>0.023 3</b>	<b>0.106 7</b>	0.028 6	0.118 3	0.025 8	0.108 0	<u>0.025 6</u>	<u>0.107 0</u>
	48	0.047 7	0.151 6	0.036 6	0.131 2	<u>0.034 4</u>	<u>0.128 8</u>	0.035 1	0.129 1	<b>0.033 0</b>	<b>0.127 0</b>
	64	0.056 3	0.165 8	0.045 5	0.145 8	<u>0.043 6</u>	<u>0.145 4</u>	0.044 3	0.145 3	0.043 5	<b>0.145 2</b>
64	16	0.021 8	0.100 9	<b>0.013 2</b>	<b>0.077 3</b>	0.016 5	0.089 6	<b>0.013 2</b>	<u>0.077 7</u>	<u>0.013 3</u>	0.077 9
	32	0.035 4	0.128 5	0.028 2	0.113 8	0.028 6	0.118 3	<u>0.027 6</u>	<u>0.113 4</u>	<b>0.026 9</b>	<b>0.112 0</b>
	48	0.044 1	0.149 8	0.041 5	0.138 9	0.039 0	0.138 5	<u>0.039 0</u>	<u>0.137 3</u>	<b>0.038 0</b>	<b>0.135 9</b>
	64	0.054 0	0.163 3	0.052 6	0.157 4	0.052 0	0.162 8	<u>0.047 1</u>	<u>0.154 1</u>	<b>0.043 5</b>	<b>0.150 2</b>
96	16	0.020 5	0.099 7	<u>0.014 5</u>	0.081 7	0.023 3	0.111 4	<u>0.014 5</u>	<u>0.085 1</u>	<b>0.013 9</b>	<b>0.082 6</b>
	32	0.035 0	0.129 4	<u>0.027 7</u>	<u>0.115 8</u>	0.041 1	0.146 0	0.028 3	0.118 5	<b>0.027 0</b>	<b>0.114 6</b>
	48	0.044 1	0.149 8	<u>0.039 8</u>	<u>0.143 2</u>	0.045 6	0.156 2	0.044 8	0.148 2	<b>0.038 7</b>	<b>0.139 8</b>
	64	0.052 6	0.163 6	0.052 1	0.164 8	0.055 4	0.175 2	<u>0.045 6</u>	<u>0.154 9</u>	<b>0.045 4</b>	<b>0.154 8</b>
128	16	0.022 1	0.106 7	<u>0.014 5</u>	<u>0.081 8</u>	0.040 6	0.150 5	<b>0.013 7</b>	<b>0.081 4</b>	0.015 8	0.088 6
	32	0.032 4	0.125 9	0.028 7	<u>0.119 5</u>	0.047 1	0.162 6	<b>0.028 4</b>	<b>0.117 1</b>	<u>0.028 6</u>	0.120 3
	48	0.045 5	0.155 5	0.042 2	0.149 6	0.054 6	0.175 3	<u>0.041 6</u>	<u>0.146 9</u>	<b>0.040 7</b>	<b>0.145 1</b>
	64	0.053 4	0.162 7	0.051 9	0.163 5	0.067 9	0.196 2	<u>0.049 1</u>	<u>0.161 1</u>	<b>0.044 6</b>	<b>0.154 9</b>

注:最优结果使用红色加粗方式标注,次优结果使用绿色下划线标出。

Note: The optimal results are annotated in the bold way of red, the sub-optimal results are underlined in green.

由表 6 可知,在预测长度固定,先验长度增长的情况下(从 32 增长到 128),所有算法的 RMSE 和 MAE 指标都出现了小幅的上涨,其原因是随着先验长度的增加,其干扰数据数量也随之增加,先验知识的增加反而加大了模型的有效信息提取难度,导致了预测结果的 RMSE 和 MAE 指标出现了波动,其也更加考验模型的信息提取能力。

在使用 RevIN 和更深层的 MLP 模型的情况下,在数据集二上, RMSE 和 MAE 指标都有了明显的下降,证明了可逆归一化和更深层次的 MLP 模型可以更好地提取时间序列信息。如果将单一的 MLP 单元换成上采样与综合决策单元

的情况下,4 维度上采样下的综合决策算法就已经可以在 68% 的概率上获得最优或者次优结果,8 维度上采样的情况下,其可以 93% 的概率得到最优或次优结果,其中最优结果的占比达到了 80%,次优结果占比 20%。虽然 RevIN+MLPs 的组合也有 37% 的概率可以达到最优或者次优结果,但其在长时间序列预测上(预测长度为 48 和 64)与多维度决策算法均存在较大差距,4 维度上采样决策和 8 维度上采样决策基本占据了最优和次优位置,其相较于单纯的 MLP 的模型平均提高了 20%,证明了本文提出的多维度决策机制可以更好地提取时间序列的信息,并在长时间序列预测中得到更好的效果。

2.5.2 模型信息提取能力验证 为了验证本文算法在时间序列信息提取的有效性,本章节将使用不同长度的先验知识对数据的训练过程进行分析。从图 8 可以看出,训练集、验证集和测试集在数据分布上都存在的差异,在训练过程中,验证集的损失函数较大,这表明其数据分布与训练集和测试集的差异明显。从结果来看,本文算法

在各不同先验数据集上都可以实现快速收敛,虽然训练集、验证集和测试集的数据分布存在差异,但损失函数在进入平稳状态后波动很小,且各数据集损失函数差距很小,这表明模型可以充分挖掘训练集中的时间序列信息,提取价格波动的趋势特征,并成功将其应用于验证集和测试集的预测工作。

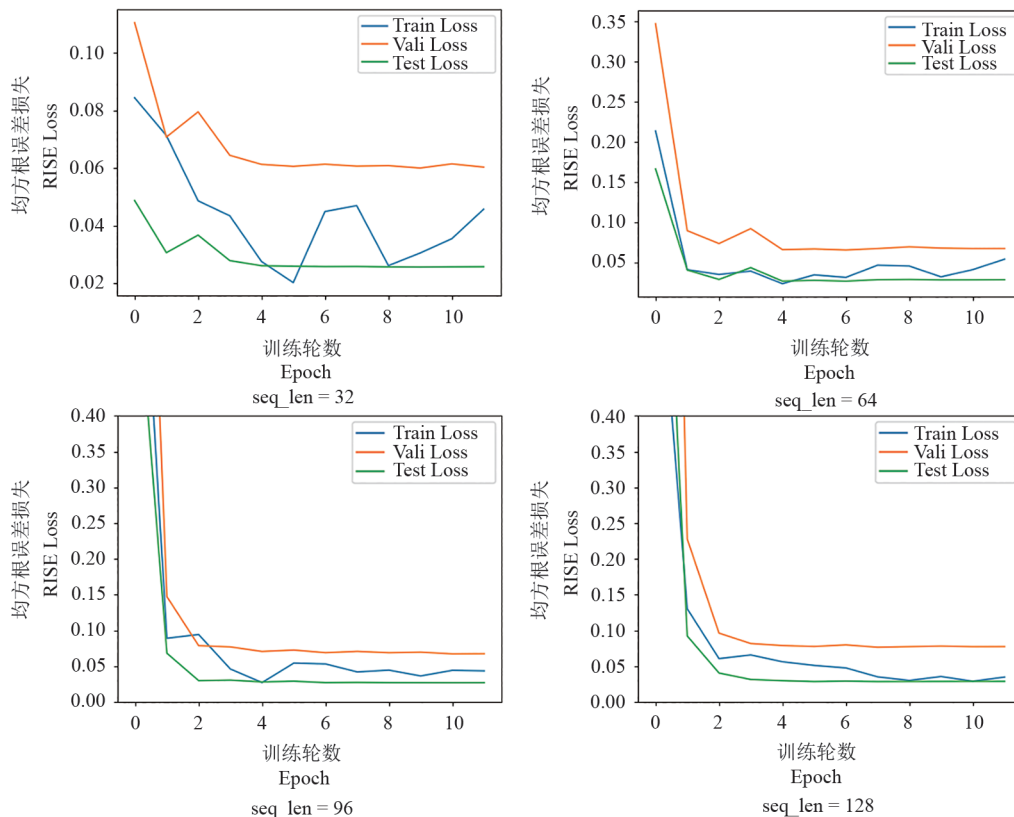


图 8 不同时间序列预测 Loss 值变化曲线(pred\_len=32)

Fig. 8 Loss value change curves for different time series prediction models (pred\_len = 32)

### 3 结论

本文构建了基于多维综合决策的 RMLP 时间序列预测模型,用于猪肉价格长时间序列预测。该模型通过 RevIN、趋势分解和多维度决策方法,有效避免数据漂移并增强局部特征提取,采用直接映射替代滑动窗口预测,减少差值累计,同时通过多维度决策拓展特征空间,提升模型的特征提取能力,避免出现过拟合现象。实验结果表明,相比多种现有的猪肉价格预测算法,本文算法在多项指标上均有显著提升,预测时间越长,结果与实际价格波动越吻合,算法稳定性更优。该深度学习模型可为市场监督机构和投

资者提供科学预测与调控依据,助力生猪市场稳定,预测信息有助于提前识别价格波动风险,为企业生产决策和政府政策制定提供支持,推动生猪产业结构优化。

### 参考文献

- [1] 李俊茹,石自忠,胡向东. 中国生猪市场价格波动的双疫情冲击效应[J]. 统计与决策,2023,39(17):79-83.
- [2] 李霞,陶建平,涂涛涛. 突发动物疫情信息与猪肉价格波动——基于消费者网络关注视角[J]. 农业技术经济,2024(02):73-95.
- [3] 陈怡然,熊竹青,周脚根,等. 畜禽养殖业数据应用展望和问题分析[J]. 中国科学院院刊,2024,39(11):1982-1993.
- [4] 石庆兰,束金阳,李道亮,等. 基于 BiLSTM-GRU 融合

- 网络的稻虾养殖溶解氧含量预测[J]. 农业机械学报,2023,54(10):364-370.
- [5] 杨亮,刘春红,郭显辰,等. 基于 EMD-LSTM 的猪舍氨气浓度预测研究[J]. 农业机械学报,2019,50(S1): 353-360.
- [6] 刘春红,杨亮,邓河,等. 基于 ARIMA 和 BP 神经网络的猪舍氨气浓度预测[J]. 中国环境科学,2019, 39(06):2320-2327.
- [7] 王润周,张新生,王明虎. 基于信号分解和深度学习的农产品价格预测[J]. 农业工程学报,2022,38(24): 256-267.
- [8] 任青山,方逵,朱幸辉. 基于多元回归的 BP 神经网络生猪价格预测模型[J]. 江苏农业科学,2019, 47(14):277-281.
- [9] 吴培,李哲敏. 中国猪肉价格预测研究-基于 ARIMA-GM-RBF 组合模型的分析[J]. 价格理论与实践,2019(01):75-78.
- [10] 魏嘉妮. 基于 GA-BP 神经网络模型的猪肉价格预测分析[D]. 大连:东北财经大学,2023.
- [11] 刘合兵,华梦迪,席磊,等. 白条猪价格预测模型构建[J]. 河南农业大学学报,2024,58(01):123-131.
- [12] 胡春安,江维. 基于 VMD-BO-BiLSTM 的猪肉价格预测模型[J]. 应用科学学报,2023,41(04):692-704.
- [13] 叶勇,许潘,辜丽川,等. 基于 Prophet-BP 模型的猪肉价格预测研究[J]. 黄山学院学报,2021,23(05): 75-80.
- [14] Guo Y, Tang D, Cai Q, et al. Agricultural price prediction based on data mining and attention-based gated recurrent unit: a case study on China's hog[J]. Journal of Intelligent & Fuzzy Systems, 2024, 46(4): 9923-9943.
- [15] Sun C, Pei M, Cao B, et al. A study on agricultural commodity price prediction model based on secondary decomposition and long short-term memory network[J]. Agriculture, 2023, 14(1):60-72.
- [16] Fu L, Ding X, Ding Y. Ensemble empirical mode decomposition-based preprocessing method with Multi-LSTM for time series forecasting: a case study for hog prices[J]. Connection Science, 2022, 34(1): 2177-2200.
- [17] Ye K, Piao Y, Zhao K, et al. A heterogeneous graph enhanced LSTM network for hog price prediction using online discussion[J]. Agriculture, 2021, 11(4): 359-359.
- [18] Sun F, Meng X, Zhang Y, et al. Agricultural product price forecasting methods: A review[J]. Agriculture, 2023, 13(9):1671.
- [19] Zhou H, Zhang S, Peng J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]. AAAI, 2020, 35(12):11106-11115.
- [20] 王杰,董国奥,李俊清. 基于 STL-Informer-ARIMA 组合模型的猪肉价格预测方法研究[J]. 山东农业大学学报(自然科学版),2024,55(03):367-375.
- [21] Zeng A, Chen M, Zhang L, et al. Are Transformers effective for time series forecasting? [C]. AAAI, 2023.37(9):11121-11128.
- [22] Li Z, Qi S, Li Y, et al. Revisiting long-term time series forecasting: An investigation on linear mapping[J]. arXiv:2305.10721, 2023.
- [23] Liu Y, Hu T, Zhang H, et al. iTransformer: Inverted transformers are effective for time series forecasting [C]. ICLR, 2024, pp 1-25.