

基于 TiDE - PatchTST 模型的柑橘冷藏效率时序预测模型优化

杨信廷^{1,2} 郭向阳¹ 韩佳伟^{2,3} 刘彤¹ 杨霖⁴

(1. 上海海洋大学信息学院, 上海 201306; 2. 北京市农林科学院信息技术研究中心, 北京 100097;

3. 农产品质量安全追溯技术及应用国家工程研究中心, 北京 100097;

4. 仲恺农业工程学院信息科学与技术学院, 广州 510225)

摘要: 柑橘低温贮藏过程中果实温度波动是引发果品品质安全风险与增加制冷能耗的关键因素,同时果品品质与制冷能耗也是评判柑橘冷藏效率的重要评价指标,实现两者动态预测可为科学预知与精准优化柑橘冷藏效率提供可靠支持。本文提出一种基于 PatchTST 的柑橘冷藏效率时序预测模型。首先,基于自注意力机制和独立预测方法(Channel independent, CI)构建基础 PatchTST 模型;其次,通过融合基础 PatchTST 模型与 TiDE 模型中的协变量特征提取模块,实现对多元时序数据集中全部序列的特征提取,并有效改进模型预测精度;最后,基于皮尔森相关性分析方法定量分析冷库制冷参数与能耗、柑橘温度的相关性,确定 TiDE - PatchTST 模型输入参数,并基于 5 000 组实验数据实现多种模型训练与测试,对比验证 TiDE - PatchTST 模型的准确性与优越性。结果表明,基于 TiDE - PatchTST 模型的冷库能耗预测值与实验值平均绝对误差(MAE)和均方根误差(RMSE)分别为 3.645 W·h 和 10.421 W·h,柑橘温度预测值与实验值的 MAE 和 RMSE 分别为 0.034℃ 和 0.042℃,相比 Transformer 模型,能耗预测的 MAE 和 RMSE 最高分别下降 41.43% 和 39.27%,柑橘温度预测的 MAE 和 RMSE 最高分别下降 46.03% 和 28.81%。本研究可为柑橘冷藏过程温度波动与能耗动态感知与优化调控等提供可靠方法支持与参考。

关键词: 柑橘; 冷藏效率; 时序预测模型优化; PatchTST; TiDE

中图分类号: TP391

文献标识码: A

文章编号: 1000-1298(2024)07-0396-09

OSID:



Optimization of Citrus Cold Storage Efficiency Time-series Prediction Model Based on TiDE - PatchTST

YANG Xinting^{1,2} GUO Xiangyang¹ HAN Jiawei^{2,3} LIU Tong¹ YANG Lin⁴

(1. Department of Information, Shanghai Ocean University, Shanghai 201306, China

2. Research Center of Information Technology, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

3. National Engineering Laboratory for Agri-product Quality Traceability, Beijing 100097, China

4. Department of Information Science and Technology, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China)

Abstract: The temperature fluctuation during the low-temperature storage process of citrus is a key factor that triggers quality and safety risks for the fruit and increases refrigeration energy consumption. Simultaneously, quality and energy consumption are crucial evaluation indicators for assessing the efficiency of citrus cold storage. Achieving dynamic predictions for both aspects can provide reliable support for scientifically anticipating and precisely optimizing citrus cold storage efficiency. In light of this, a citrus cold storage efficiency time-series prediction model was proposed based on PatchTST. Firstly, a basic PatchTST model was constructed based on the self-attention mechanism and the channel independent (CI) prediction method. Secondly, by integrating the basic PatchTST model with the covariate feature extraction module from the TiDE model, feature extraction for all sequences in the multivariate time series dataset was achieved, effectively improving the model's prediction accuracy. Finally, quantitative analysis of the correlation between cold storage refrigeration parameters, energy

收稿日期: 2023-11-29 修回日期: 2024-04-19

基金项目: 国家重点研发计划项目(2022YFD2001804, 2023YFD2001302)和北京市农林科学院科研创新平台建设项目(PT2024-24)

作者简介: 杨信廷(1974—),男,研究员,博士生导师,主要从事冷链物流信息化关键技术研究, E-mail: yangxt@nercita.org.cn

通信作者: 韩佳伟(1989—),男,高级农艺师,博士,主要从事智慧冷链物流关键技术研究, E-mail: hanjw@nercita.org.cn

consumption, and citrus temperature was conducted by using the Pearson correlation analysis method. This analysis helped determine the input parameters for the TiDE - PatchTST model. The model was then trained and tested with 5 000 sets of experimental data, and its accuracy and superiority were compared and validated against other models like basic PatchTST and Informer. The results showed that the predicted cold storage energy consumption values of the TiDE - PatchTST model had average absolute errors (MAE) and root mean square errors (RMSE) of 3.645 W·h and 10.421 W·h, respectively. The MAE and RMSE for citrus temperature predictions were 0.034℃ and 0.042℃, respectively. Compared with Transformer model, the MAE and RMSE in energy consumption predictions were decreased by up to 41.43% and 39.27%, and in citrus temperature predictions, they were decreased by up to 46.03% and 28.81%. The research result can provide strong support for the dynamic perception and optimization control of temperature fluctuations and energy consumption during the citrus cold storage process.

Key words: citrus; cold storage efficiency; time-series prediction model optimization; PatchTST; TiDE

0 引言

柑橘采后品质易受温度影响,温度过高或过低都易引发果实病变,营养流失甚至失去其商品价值。低温贮藏可为柑橘提供适宜的储藏温度,抑制柑橘呼吸,延缓柑橘品质劣变速率,进而延长柑橘货架期与销售周期等^[1-2]。然而,在仓储保鲜设施的日常作业与管理过程,外界高温环境与作业人员等热源会随库门开关被引入库内,加之壁面材质的非绝热特性,成为引发贮藏过程中柑橘温度波动与增大柑橘品质风险的关键因素之一^[3-4]。冷库制冷参数的动态与精准控制可有效降低外界热源对库内环境温度稳定性的影响,近年来相关学者在冷库制冷参数优化控制方面已展开了大量研究,为有效降低果品温度波动风险与提升果品品质安全保障等提供了关键理论基础与有益借鉴^[5-8]。然而,低温贮藏下柑橘温度波动具有动态时变性特征,精准预判温度波动趋势是实现相关制冷参数动态优化控制的关键基础,否则不仅不能有效解决果品温度波动问题,也易增加无效电力消耗,经济损失严重。因此,近年来冷库环境参数预测与动态感知成为研究热点之一,为精准预判与动态维持库内果品温度的稳定性与适宜性,减少果品品质损失以及实现制冷系统节能增效等奠定关键理论基础。

冷库环境温度与能耗等相关参数的时序性预测研究常采用统计学模型开展,黄芳等^[9]利用时序指数平滑法构建了冷库能耗预测模型,可实现未来 1 h 内冷库能耗的准确预测。HUANG 等^[10]结合粒子群算法与具有外生变量的自回归移动平均模型构建了冷库能耗预测模型,模型相比随机时间序列(STS)方法具有优越的收敛特性和更短的计算时间。上述研究为冷藏效率的时序预测研究提供了重要参考。然而,统计学模型在处理大规模数据集时难以捕捉复杂的非线性关系,在对参数过多的动态系统进行

时序预测时预测精度较低^[11]。随着近年来计算机软硬件技术的飞速发展,深度学习模型借助计算能力的提升及算法的改进,已被广泛应用于不同领域时序性数据预测研究^[12-15],其模型预测精度与泛化能力相比统计学模型有显著提升^[16-17]。ONOUFRIOU 等^[18]分别采用循环神经网络(RNN)、长短期记忆网络(LSTM)及序列生成对抗网络(seqGAN)3 种模型对解冻过程中不同食品的温度进行时序预测;FURKAN 等^[19]基于卷积长短期记忆网络模型(CNN-LSTM)构建了室内环境温度时序预测模型,并通过解决循环神经网络模型缺乏长期记忆的问题,使模型在温度预测上的 MAE 达到 0.045℃。然而,深度学习模型如 RNN^[20]、LSTM^[21]等难以提取数据的长距离依赖关系且需要进行顺序计算,因而在长序列预测问题上预测精度较低且计算速度较慢。鉴于此,NIE 等^[22]基于 Transformer 模型^[23]结合独立预测方法构建了 PatchTST,实现完全依赖自注意力机制对数据进行特征提取,既可有效捕捉长距离数据间的依赖关系,也可完全消除递归和卷积,实现了模型准确性、并行性与处理速度的多重提升。此外,PatchTST 模型属多段式数据输入模型,使模型在处理长序列时能够保持时间序列的局部特征,进而有效保障了长序列时序预测模型的准确性。然而,PatchTST 模型拟合能力较弱^[24],并且无法实现多元时间序列数据特征的特征提取,导致模型缺少多元特征信息,面向耦合性较强的柑橘冷藏效率预测,难以实现柑橘温度与能耗的精准预测。DAS 等^[25]提出了具备多元数据特征提取优势的 TiDE 模型,通过融合 TiDE 与 PatchTST 模型,可有效弥补上述 PatchTST 模型的不足。

本文以柑橘低温贮藏为例,通过在基础 PatchTST 模型中引入 TiDE 模型,强化时序数据多元参数特征提取能力,降低噪声数据对柑橘冷藏效率时序预测模型训练精度的负面影响,进而构建一

种基于优化 PatchTST 的低温贮藏柑橘冷藏效率(温度与能耗)时序预测模型,并与其他模型展开对比分析,以验证优化后 PatchTST 模型的准确性与可靠性。

1 材料与方法

1.1 数据采集

本文数据来源于柑橘冷藏实验。冷库尺寸(长×宽×高)为 5.8 m×2.4 m×2.6 m,最大功率 12 kW,电源 380 V/460 V 三相电,额定电流 17 A,冷藏室温度范围 -5~30℃,温控精度±1℃。冷库安装了基于物联网系统的冷库数据监测系统,能够对冷库环境温度、回风温度、出风温度、冷机电压、冷机电流进行监测。数据采集间隔为 1 min。冷库能耗使用冷机电流和冷机电压计算得出。冷链能耗计算公式为

$$J=UIT\cos\varphi \tag{1}$$

式中 J——总能耗 U——电压
I——电流 φ——相位差
T——时长

冷库内安装了以 STM32G070RBT6 芯片为核心的冷库环境监测系统。在冷库内部安装了 15 个无线温湿度监测仪(温度测量精度为±0.2℃,相对湿度测量精度为±1%),将无线温湿度监测仪探针插入柑橘内,测量柑橘温度。无线温湿度监测仪能够对柑橘温度和环境温度与环境相对湿度进行监测并通过 LORA 模块与芯片通信。柑橘温度与环境温湿度数据采样时间间隔为 1 min,并通过 4G 模块上传至物联网云平台。柑橘温度为 4 个温度传感器采集数据的均值,冷库内温度和冷库内相对湿度为 15 个温湿度传感器的采集数据。

1.2 数据预处理

选取从 2023 年 9 月 4—8 日共计 5 d 的监测数据(柑橘温度、设定温度、出风温度、回风温度、冷机电流、冷机电压、蒸发器盘管温度、冷库内温度和冷库内相对湿度)作为实验数据。在模型训练前,需对数据进行预处理。首先,对冷库数据与冷库内环境数据进行合并,由于冷库环境监测系统的采集频率更高,因而将与冷库数据时间最接近的冷库内环境数据进行合并。其次,将冷库数据进行时间序列重采样,使得时间序列数据集间隔为 1 min。最后,由于数据采集过程易因网络波动等问题产生异常数据,故需对采集数据进行数据清洗。对数值过大异常点使用拉依达准则筛选出极端值后,对去除极端值后的每一维数据再次依据拉依达准则筛选异常点,将数据集中的异常点替换为缺失值。缺失值采

用前向填充方法补全,共计得到 5 000 组有效数据。

为提升模型泛化能力与稳定性,需对数据进行归一化处理。归一化公式为

$$z'_i=\frac{z_i-z_{\min}}{z_{\max}-z_{\min}} \tag{2}$$

式中 z_i ——输入冷库数据
 z'_i ——归一化后冷库数据
 $z_{\max}$ ——输入数据中最大值
 $z_{\min}$ ——输入数据中最小值

数据预处理完成后,需将数据集划分为训练集、验证集和测试集。首先将最后 500 组数据作为测试集,然后将剩下的 4 500 组数据作为训练数据,其中 4 000 组数据为训练集,500 组数据为验证集。通过皮尔森相关性分析方法,确定各参数与冷库能耗和柑橘温度相关系数,并依据相关系数对参数进行筛选。

1.3 模型构建与优化

本文构建了一种改进的 PatchTST 模型用于时序数据预测,使用基本 PatchTST 模型对预测序列的历史序列进行特征提取,对时序数据集的序列进行划分,使用以残差块为基本单元的协变量特征提取模块对时序数据集进行特征提取,并与基本 PatchTST 模型的输出进行残差连接,使得基本 PatchTST 模型能够提取多元时序特征。将柑橘温度、能耗、设定温度、出风温度、回风温度、冷机电流、冷机电压、蒸发器盘管温度、冷库内温度和冷库内相对湿度的数据序列作为模型输入,模型输出为未来 96 min 的能耗与温度。

1.3.1 PatchTST 模型

PatchTST 模型属于独立预测方法,仅对时序数据集的单个序列提取特征并预测,主要由数据处理层、Transformer 层和预测头组成。传统的以 Transformer 为基础的模型将每个时间点视作一个单元,PatchTST 将输入的序列归一化处理后,划分为若干个时间段,每个时间段可有重叠部分,每个时间段都视为一个单元。对每个时间段进行位置编码之后,即可直接输入到 Transformer 层中。最后将 Transformer 的输出向量展平后输入一个预测头,得到单变量的输出序列。

给定一个多变量时间序列数据集,将长度为 L 的序列($x_1,x_2,\cdots,x_L$)输入模型,数据处理层接收到数据后将序列划分为 N 个切片(patch)。 N 的计算式为

$$N=\frac{L-P}{S}+2 \tag{3}$$

式中 L ——输入序列长度

P ——patch 长度

S ——步长

Transformer 层将 patch 通过与 $W_p \in \mathbf{R}^{D \times P}$ 相乘映射到维度为 D 的空间,得到特征投影并与位置编码 $W_{pos} \in \mathbf{R}^{D \times N}$ 相加得到包含 patch 的时间顺序的序列 $\mathbf{x}_d^{(i)}$,即

$$\mathbf{x}_d^{(i)} = W_p \mathbf{x}_p^{(i)} + W_{pos} \quad (4)$$

式中 W_{pos} ——位置编码矩阵

W_p ——映射矩阵

$\mathbf{x}_p^{(i)}$ ——第 i 个 patch

$\mathbf{x}_d^{(i)}$ ——第 i 个 patch 的特征投影结果

使用多头注意力中的每个头部 $h = 1, 2, \dots, H$ 将其转换为 Query 向量 $\mathbf{Q}$ 、Key 向量 $\mathbf{K}$ 和 Value 向量 $\mathbf{V}$,计算式为

$$\mathbf{Q}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^Q \quad (5)$$

$$\mathbf{K}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^K \quad (6)$$

$$\mathbf{V}_h^{(i)} = (\mathbf{x}_d^{(i)})^T \mathbf{W}_h^V \quad (7)$$

式中 W_h^Q ——第 h 个 $\mathbf{Q}$ 变换矩阵

W_h^K ——第 h 个 $\mathbf{K}$ 变换矩阵

W_h^V ——第 h 个 $\mathbf{V}$ 变换矩阵

进行 Softmax 归一化,得到权重矩阵,矩阵的每

个值都大于 0 且小于 1,并且总和为 1。将权重矩阵与 $\mathbf{V}$ 相乘,计算加权求和得到输出结果 $\mathbf{O}_h^{(i)}$ 。

$$(\mathbf{O}_h^{(i)})^T = \text{Softmax} \left(\frac{\mathbf{Q}_h^{(i)} (\mathbf{K}_h^{(i)})^T}{\sqrt{d_k}} \right) \mathbf{V}_h^{(i)} \quad (8)$$

式中 d_k ——缩放因子

最后将 $\mathbf{O}_h^{(i)}$ 展平后输入由一个全连接层组成的预测头,得到最终预测结果。

1.3.2 TiDE - PatchTST 模型

TiDE - PatchTST 模型多元时序特征提取模块主要由残差块组成的编码器模块与解码器模块组成。模型首先对数据归一化处理,并将不同信道划分成过去序列、静态协变量、未来可知动态协变量和未来不可知动态协变量 4 部分。过去序列输入基础 PatchTST 模型进行预测,将未来可知动态协变量和未来不可知动态协变量分别经过一个残差块进行特征投影后与过去序列和静态协变量拼接成一个长序列,然后输入到由多个残差块堆叠而成的编码器中,编码器输出到多个残差块堆叠而成的解码器,将解码器输出的结果重构,并与未来可知动态协变量拼接,拼接后的结果再输入一个残差块。最后将输出与基本 PatchTST 模型输出结果进行残差连接,得到最终预测结果。图 1 为模型结构图。




图 1 TiDE - PatchTST 模型结构

Fig. 1 Structure of TiDE - PatchTST model

过去序列即模型需要预测时间序列的历史序列,如温度、冷机电流等。静态协变量即在训练和预

测过程中不变的序列,如冷库的设定温度等。未来可知动态协变量即在训练和预测过程中都已知的序

列,如时间等。未来不可知动态协变量即在预测过程中未来状态未知序列,如冷库回风温度、出风温度、环境温度等。

将数据集划分后得到 4 个输入数据:过去序列 $y_{1:L}^{(i)}$,静态协变量 $a^{(i)}$,未来不可知动态协变量 $U_{1:L}^{(i)}$,未来可知动态协变量 $X_{1:L+H}^{(i)}$ 。 H 为预测序列长度。

残差块由 Dense 层、ReLU 非线性层、Layer Norm 层组成,使用残差连接,如图 2 所示。




图 2 残差块结构
Fig. 2 Residual block structure

未来不可知动态协变量 $U_{1:L}^{(i)}$ 和未来可知动态协变量 $X_{1:L+H}^{(i)}$ 分别经过一个残差块后特征投影到 $\hat{r}$ 维空间得到 $\tilde{U}_{1:L}^{(i)}$ 和 $\tilde{X}_{1:L+H}^{(i)}$ 。

图 3 显示编码器由多个残差块堆叠而成,将未来不可知动态协变量和未来可知动态协变量的特征





图 3 编码器模块
Fig. 3 Encoder module



投影 $\tilde{U}_{1:L}^{(i)}$ 和 $\tilde{X}_{1:L+H}^{(i)}$ 与过去序列 $y_{1:L}^{(i)}$ 和静态协变量 $a^{(i)}$ 拼接成长序列后输入编码器,得到输出序列 $e^{(i)}$ 。

图 4 显示解码器也由多个残差块堆叠而成,将编码器输出序列 $e^{(i)}$ 输入解码器得到长序列 $g^{(i)}$,将长序列 $g^{(i)}$ 重塑后与剩余部分未来可知动态协变量 $\tilde{X}_{L+1:L+H}^{(i)}$ 拼接。拼接后的数据输入一个残差块后即可得到协变量特征提取模块的输出。




图 4 解码器模块
Fig. 4 Decoder module

1.4 模型验证

为了验证模型预测精度,采用平均绝对误差 (MAE) 和均方根误差 (RMSE) 对模型性能进行评估。

1.5 模型开发环境

本模型硬件开发环境为 AMD Ryzen 7 6800H 处理器,Nvidia RTX 3060 显卡,Windows 11 64 位操作系统。模型开发采用 Python 3.7 编程语言结合 Pytorch 框架开发,编程平台为 Pycharm,所有对比模型均在相同环境下运行。

2 结果与分析

2.1 模型输入参数确定

选取 2023 年 9 月 4—8 日共计 5 d 经过预处理的数据作为实验数据,图 5 显示了能耗变化与柑橘温度变化曲线。观察图 5 可发现,冷库能耗波动较大,高值在 $50 \sim 70 \text{ W} \cdot \text{h}$ 之间变化,低值在




图 5 冷库能耗与温度变化曲线
Fig. 5 Variation curves of energy consumption and temperature in cold storage

5 ~ 8 W · h 之间变化,和制冷机组状态一致,柑橘温度变化较为平稳,在设定温度附近波动。

时序数据集包含冷库的多样参数,通过对参数的筛选,确定影响能耗与柑橘温度的因素,能使模型更加充分地提取数据特征。使用皮尔森相关系数分析法对各种参数进行相关性分析,表 1 为冷库能耗和柑橘温度冷库各参数的相关系数。

表 1 皮尔森相关系数

Tab. 1 Pearson coefficient factor correlation analysis		
参数	冷库能耗	柑橘温度
环境温度	0. 682	0. 343
出风温度	0. 359	0. 018
回风温度	0. 101	0. 542
冷机电压	0. 102	0. 112
冷机电流	0. 998	0. 355
蒸发器盘管温度	0. 332	0. 421
柑橘温度	0. 171	1
冷库内环境温度	0. 527	0. 716
冷库内环境相对湿度	-0. 427	-0. 697
冷库能耗	1	0. 317

冷库能耗与环境温度具有较强的正相关性,相关系数为 0. 682,与出风温度、蒸发器盘管温度、冷库内环境温度呈正相关,相关系数分别为 0. 359、0. 332 和 0. 527,与冷库内环境相对湿度呈负相关,相关系数为 -0. 427,与冷机电压、回风温度的相关性较低。柑橘温度与冷库内环境温度具有较强的正相关性,相关系数为 0. 716,与环境温度、回风温度、冷机电流、蒸发器盘管温度和冷库能耗呈正相关,相关系数分别为 0. 343、0. 542、0. 355、0. 421 和 0. 317,与冷库内环境相对湿度呈负相关,相关系数为 -0. 697,与出风温度、冷机电压相关性较低。

冷机电压与冷库能耗和柑橘温度相关性均较低,分析数据发现冷机电压在 405 ~ 415 V 之间波动,且大部分情况下维持在 410 V 左右,数据波动较小。因此不将冷机电压作为影响因素。

相关性分析选取与冷库能耗和柑橘温度具有较高相关性的影响因素作为数据集。选取环境温度、出风温度、冷机电流、蒸发器盘管温度、柑橘温度、冷库内环境相对湿度和冷库内环境相对湿度作为冷库能耗影响因素;选取环境温度、回风温度、冷机电流、蒸发器盘管温度、冷库内环境温度、冷库内环境相对湿度和冷库能耗作为柑橘温度影响因素。

2.2 TiDE - PatchTST 模型训练

本文有效数据共计 5 000 组,为验证数据是否充足,模型训练过程将保持验证集与测试集不变,逐步增加训练集的数据量,以观察模型的 MAE 与

RMSE 随数据量增加的变化趋势。图 6 为冷库能耗 MAE 与 RMSE 随数据量增加的变化趋势,在数据量 1 000 组增加至 3 100 组过程中,MAE 与 RMSE 下降趋势较为明显,在数据量 3 100 ~ 4 000 组之间,MAE 与 RMSE 变化较小。图 7 为柑橘温度 MAE 与 RMSE 随数据量增加的变化趋势,在数据量 1 000 组增加至 2 800 组过程中,MAE 与 RMSE 下降趋势较为明显,在数据量 2 800 ~ 4 000 组之间,MAE 与 RMSE 变化较小。观察冷库能耗和柑橘温度的 MAE 与 RMSE 的变化趋势,可知增加数据量对提升预测精度作用已经较小。




图 6 冷库能耗 MAE 和 RMSE 变化曲线

Fig. 6 Variation of MAE and RMSE in energy consumption of cold storage




图 7 柑橘温度 MAE 和 RMSE 变化曲线

Fig. 7 Variation of MAE and RMSE in citrus temperature

2.3 TiDE - PatchTST 模型验证

使用测试集对 TiDE - PatchTST 模型的预测精度进行验证,图 8 分别显示冷库能耗与柑橘温度的预测值和实际值,TiDE - PatchTST 模型对冷库能耗预测和柑橘温度预测结果与实际值变化趋势接近,呈现出周期性变化,两者变化趋势的速度与范围存在较大差异。冷库能耗变化范围为 1.2 ~ 76.2 W · h,模型预测值变化范围为 1.2 ~ 74.4 W · h,最小误差为 0.2 W · h,最大误差 60.4 W · h,平均误差为 3.64 W · h,数据变化趋势较为迅速,在高值与低值之间呈周期性变化,且无中间值存在。柑橘温度实际值变化范围为 5.7 ~ 6.6℃,预测值变化范围为 5.6 ~ 6.5℃,预测值与实际值最小误差为 0℃,最大误差为 0.12℃,平均误差为 0.034℃,数据变化趋势较为平缓,呈周期性变化。冷库能耗最大误差较大




图 8 TiDE - PatchTST 模型预测结果

Fig. 8 TiDE - PatchTST model prediction results

的原因可能是冷库能耗波动过大且数据变化趋势较为迅速,其高值在 50 ~ 70 W · h 之间变化,低值在 5 ~ 8 W · h 之间变化,模型预测高值与低值错误,会产生较大误差。此外,柑橘温度最大误差仅 0.12℃可能归因于温度波动范围较小且变化趋势较为平缓。

2.4 不同模型准确性比较

为进一步验证模型预测效果,使用基于自注意力机制的 PatchTST、Informer、Autoformer 和 Transformer 模型与基于 MLP 的 DLinear 模型进行对比实验。与本文提出的 TiDE - PatchTST 模型使用相同的数据集进行训练和测试。表 2 为不同模型预测冷库能耗和柑橘温度的 MAE 和 RMSE。

表 2 模型预测精度对比

Tab. 2 Comparison of model prediction accuracy

模型	冷库能耗/(W·h)		柑橘温度/℃	
	MAE	RMSE	MAE	RMSE
PatchTST	4.547	12.492	0.035	0.044
Informer	6.072	15.967	0.063	0.059
Autoformer	5.839	14.659	0.055	0.057
Transformer	6.224	17.159	0.040	0.055
DLinear	5.043	13.391	0.036	0.045
TiDE - PatchTST	3.645	10.421	0.034	0.042

如表 2 所示,TiDE - PatchTST 模型预测冷库能耗和柑橘温度上均优于 PatchTST 模型,能耗预测的 MAE 和 RMSE 分别为 3.645、10.421 W · h,柑橘温度预测的 MAE 和 RMSE 分别为 0.034、0.042℃。传统的 Transformer 模型在能耗预测上最差,其能耗预测 MAE 和 RMSE 分别为 6.224、17.159 W · h。本文模型与传统的 Transformer 模型相比,冷库能耗预测 MAE 和 RMSE 分别下降 41.43% 和 39.27%。Informer 模型在柑橘温度预测上效果最差,其柑橘温度预测的 MAE 和 RMSE 分别为 0.063、0.059℃。本文模型与 Informer 模型相比,在柑橘温度预测上 MAE 和 RMSE 分别下降 46.03% 和 28.81%。

PatchTST 模型在冷库能耗预测上的预测精度仅

次于 TiDE - PatchTST 模型,与 Informer 模型、Autoformer 模型、Transformer 模型和 DLinear 模型相比,冷库能耗预测的 MAE 分别下降 26.59%、22.12%、26.94% 和 9.83%,RMSE 分别下降 21.8%、14.78%、27.19% 和 6.71%。柑橘温度预测的 MAE 分别下降 44.44%、36.36%、12.5% 和 2.78%,RMSE 分别下降 25.42%、22.81%、20% 和 2.22%。PatchTST 模型与同样基于自注意力的 Informer 模型、Autoformer 模型和 Transformer 模型相比,主要区别在于 PatchTST 模型将多个时间点作为一个 patch 输入,因而能够更好地保持时间序列的局部性。在时序预测中使用的时间序列数据相邻的时刻值较为接近,具有很强的局部性,因此以一个 patch 为 Attention 计算的最小单位更加合理。因此,保持时间序列的局部性,能够提升模型在长序列预测问题上的预测精度。

TiDE - PatchTST 模型与 PatchTST 模型相比,冷库能耗预测的 MAE 和 RMSE 分别下降 19.84% 和 16.58%,柑橘温度预测 MAE 和 RMSE 分别下降 2.85% 和 4.54%。TiDE - PatchTST 模型与 PatchTST 模型相比,主要区别在于 TiDE - PatchTST 模型增加了协变量特征提取模块。因此,使用残差块组成的协变量特征提取模块提取协变量特征信息并与基本 PatchTST 模型输出进行残差连接,使得基本 PatchTST 模型能够提取多元时序特征,能够进一步提升模型预测精度。

3 结论

(1) 以柑橘低温贮藏为例,通过在基础 PatchTST 模型中引入 TiDE 模型,使用 TiDE 模型的协变量提取模块提取多元特征,强化时序数据多元参数特征提取能力,进而构建一种基于优化 PatchTST 的低温贮藏柑橘冷藏效率(温度与能耗)时序预测模型。最后通过综合对比不同模型的预测结果,验证模型的准确性。

(2) 提出的 TiDE - PatchTST 模型对冷库能耗预测的 MAE 和 RMSE 分别为 3.645、10.421 W · h,对

柑橘温度预测的 MAE 和 RMSE 分别为 0.034、0.042℃。相比 PatchTST 模型,冷库能耗预测的 MAE 和 RMSE 分别下降 19.84% 和 16.58%,柑橘温度预测的 MAE 和 RMSE 分别下降 2.85% 和 4.54%。TiDE - PatchTST 模型精度高于 PatchTST、Informer 和 Autoformer 等模型的原因可能是 TiDE - PatchTST 模型能够提取多元时序特征,并能够更好地保持时间序列的局部性。

参 考 文 献

[1] 赵蕊. 柑橘的贮藏条件及影响因素分析[J]. 中国果菜, 2019, 39(8): 21 - 24,28.
ZHAO Rui. Storage conditions and influencing factors of citrus[J]. China Fruit & Vegetable, 2019, 39(8): 21 - 24,28. (in Chinese)

[2] 刘萍, 刘晓凤, 付慧敏. 常温和低温贮藏过程中沙糖橘、沃柑和 W. 默科特品质变化规律研究[J]. 南方园艺, 2023, 34(2): 1 - 4.

[3] SHA Y, HUA W, CAO H, et al. Properties and encapsulation forms of phase change material and various types of cold storage box for cold chain logistics: a review[J]. Journal of Energy Storage, 2022, 55: 105426.

[4] CALATI M, HOOMAN K, MANCIN S. Thermal storage based on phase change materials (PCMs) for refrigerated transport and distribution applications along the cold chain: a review[J]. International Journal of Thermofluids, 2022(16): 100224.

[5] 王霞, 潘敏, 周鹏成, 等. 基于数据监测与程序优化实现冷库能耗控制[J]. 中国港口, 2023(增刊 1): 106 - 109.

[6] 初勤亭, 吕美进. 基于 PLC 的模糊参数自整定冷库控制系统研究[J]. 制冷与空调, 2008(4): 67 - 70.
CHU Qinting, LÜ Meijin. Research on parameter-adaptive fuzzy controller for cold storage refrigeration system based on PLC[J]. Refrigeration and Air-Conditioning, 2008(4): 67 - 70. (in Chinese)

[7] 王佳豪, 张存喜. 基于 BP 神经网络 PID 控制对渔船冷库温度控制的研究[J]. 机械工程师, 2023(11): 25 - 28.
WANG Jiahao, ZHANG Cunxi. Research on temperature control of fishing vessel cold storage based on BP neural network PID control[J]. Mechanical Engineer, 2023(11): 25 - 28. (in Chinese)

[8] PATEL A M, PATEL R I. Optimization of different parameter of cold storage for energy conservation[J]. International Journal of Modern Engineering Research, 2012, 2(3): 1001 - 1005.

[9] 黄芳, 闫锐, 牛金洲. 基于时序指数平滑法的冷库能耗预测模型构建[J]. 上海节能, 2023(3): 336 - 341.
HUANG Fang, YAN Rui, NIU Jinzhou. Construction of energy consumption prediction model for cold store based on time series exponential smoothing method[J]. Shanghai Energy Saving, 2023(3): 336 - 341. (in Chinese)

[10] HUANG C M, HUANG C J, WANG M L. A particle swarm optimization to identifying the ARMAX model for short-term load forecasting[J]. IEEE Transactions on Power Systems, 2005(2): 20.

[11] CANZIANI A, PASZKE A, CULURCIO E. An analysis of deep neural network models for practical applications[J]. arXiv Preprint, arXiv: 1605. 07678, 2016.

[12] HAN Z, ZHAO J, LEUNG H, et al. A review of deep learning models for time series prediction[J]. IEEE Sensors Journal, 2019, 21(6): 7833 - 7848.

[13] MASINI R P, MEDEIROS M C, MENDES E F. Machine learning advances for time series forecasting[J]. Journal of Economic Surveys, 2023, 37(1): 76 - 111.

[14] WU H, XU J, WANG J, et al. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems, 2021, 34: 22419 - 22430.

[15] 谢秋菊, 马超凡, 王圣超, 等. 猪舍氨气与二氧化碳浓度变化时序预测模型优化[J]. 农业机械学报, 2023, 54(7): 381 - 391.
XIE Qiuju, MA Chaofan, WANG Shengchao, et al. Optimal prediction model for gas concentrations of NH₃ and CO₂ time-series in pig house[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 381 - 391. (in Chinese)

[16] 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)

[17] TOKGOZ A, UNAL G. A RNN based time series approach for forecasting turkish electricity load[C] // 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018: 1 - 4.

[18] ONOUFRIOU G, BICKERTON R, PEARSON S, et al. Nemesyst: a hybrid parallelism deep learning-based framework applied for internet of things enabled food retailing refrigeration systems[J]. Computers in Industry, 2019, 113: 103133.

[19] FURKAN E, REINOUT E, WIM C, et al. CNN - LSTM architecture for predictive indoor temperature modeling[J]. Building and Environment, 2021, 206: 108327.

[20] 王鹏新, 田惠仁, 张悦, 等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报, 2022, 53(2): 1 - 14.
WANG Pengxin, TIAN Hui ren, ZHANG Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1 - 14. (in Chinese)

[21] HOANG H M, AKERMA M, MELLOULI N, et al. Development of deep learning artificial neural networks models to predict temperature and power demand variation for demand response application in cold storage [J]. *International Journal of Refrigeration*, 2021, 131: 857 – 873.

[22] NIE Y, NGUYEN N H, SINTHONG P, et al. A time series is worth 64 words: long-term forecasting with transformers[J]. *arXiv Preprint*, arXiv: 2211. 14730, 2022.

[23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998 – 6008.

[24] HAN L, YE H J, ZHAN D C. The capacity and robustness trade-off: revisiting the channel independent strategy for multivariate time series forecasting[J]. *arXiv Preprint*, arXiv: 2304. 05206, 2023.

[25] DAS A, KONG W, LEACH A, et al. Long-term forecasting with TiDE: time-series dense encoder[J]. *arXiv Preprint*, arXiv: 2304. 08424, 2023.

(上接第 372 页)

[17] 李苗苗,吴炳方,颜长珍,等. 密云水库上游植被覆盖度的遥感估算[J]. *资源科学*, 2004, 26(4): 153 – 159.
LI Miaomiao, WU Bingfang, YAN Changzhen, et al. Estimation of vegetation fraction in the upper basin of Miyun reservoir by remote sensing[J]. *Resources Science*, 2004, 26(4): 153 – 159. (in Chinese)

[18] MILICH L, WEISS E. GAC NDVI interannual coefficient of variation (CoV) images: ground truth sampling of the Sahel along north-south transects[J]. *International Journal of Remote Sensing*, 2010, 21(2): 235 – 260.

[19] LIU H, JIAO F, YIN J, et al. Nonlinear relationship of vegetation greening with nature and human factors and its forecast—a case study of Southwest China[J]. *Ecological Indicators*, 2020, 111: 106009.

[20] ZHU L, MENG J, ZHU L. Applying Geodetector to disentangle the contributions of natural and anthropogenic factors to NDVI variations in the middle reaches of the Heihe River Basin[J]. *Ecological Indicators*, 2020, 117: 12.

[21] WANG J, LI X, CHRISTAKOS G, et al. Geographical detectors based health risk assessment and its application in the neural tube defects study of the Heshun Region, China[J]. *International Journal of Geographical Information Science*, 2010, 24(1): 107 – 127.

[22] 孙高鹏,刘宪锋,王小红,等. 2001—2020 年黄河流域植被覆盖变化及其影响因素[J]. *中国沙漠*, 2021, 41(4): 205 – 212.
SUN Gaopeng, LIU Xianfeng, WANG Xiaohong, et al. Changes in vegetation coverage and its influencing factors across the Yellow River Basin during 2001—2020 [J]. *Journal of Desert Research*, 2021, 41(4): 205 – 212. (in Chinese)

[23] 张乐艺,李霞,冯京辉,等. 2000—2018 年黄河流域 NDVI 时空变化及其对气候和人类活动的双重响应[J]. *水土保持通报*, 2021, 41(5): 276 – 286.
ZHANG Leyi, LI Xia, FENG Jinghui, et al. Spatial-temporal changes of NDVI in Yellow River Basin and its dual response to climate change and human activities during 2000—2018 [J]. *Research of Soil and Water Conservation*, 2021, 41(5): 276 – 286. (in Chinese)

[24] 王兴丽,蒋友严,张翼飞,等. 2001—2020 年甘南高原植被变化特征及驱动因素[J]. *草业科学*, 2023, 40(9): 2185 – 2198.
WANG Xingli, JIANG Youyan, ZHANG Yifei, et al. Characteristics and driving factors of vegetation changes in the Gannan Plateau from 2001 to 2020 [J]. *Pratacultural Science*, 2023, 40(9): 2185 – 2198. (in Chinese)

[25] 张波,牟建新,徐璐,等. 基于 MODIS EVI 的陇南山地植被覆盖时空变化[J]. *中国农业通报*, 2017, 33(26): 70 – 77.
ZHANG Bo, MU Jianxin, XU Lu, et al. Spatial and temporal variation of vegetation coverage in mountain area of Longnan based on MODIS EVI [J]. *Chinese Agricultural Science Bulletin*, 2017, 33(26): 70 – 77. (in Chinese)

[26] 王雄,张翀,李强. 黄土高原植被覆盖与水热时空通径分析[J]. *生态学报*, 2023, 43(2): 719 – 730.
WANG Xiong, ZHANG Chong, LI Qiang. Path analysis between veretation coverage and climate factos in the Loess Plateau [J]. *Acta Ecologica Sinica*, 2023, 43(2): 719 – 730. (in Chinese)

[27] 张军,陶华旻,李文杰,等. 甘肃省草地生态系统时空变化特征[J]. *草业科学*, 2022, 39(6): 1106 – 1114.
ZHANG Jun, TAO Huayang, LI Wenjie, et al. Spatial change of grassland ecosystem in Gansu Province [J]. *Pratacultural Science*, 2022, 39(6): 1106 – 1114. (in Chinese)

[28] JIANG W, YUAN L, WANG W, et al. Spatio-temporal analysis of vegetation variation in the Yellow River Basin [J]. *Ecological Indicators*, 2015, 51: 117 – 126.

[29] 王力,赵思妍,陈元鹏,等. 基于 GEE 云平台的黄土高原生态修复区植被变化与归因[J]. *农业机械学报*, 2023, 54(3): 210 – 223.
WANG Li, ZHAO Siyan, CHEN Yuanpeng, et al. Vegetation change and attribution in ecological restoration area of Loess Plateau based on GEE cloud platform [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(3): 210 – 223. (in Chinese)

[30] FENG X, TIAN J, WANG Y, et al. Spatio-temporal variation and climatic driving factors of vegetation coverage in the Yellow River Basin from 2001 to 2020 based on kNDVI [J]. *Forests*, 2023, 14(3): 620 – 633.