



郝璇,任守纲,舒欣,等. 基于 TimesTransformer 的农业设施环境预测与调控研究[J]. 南京农业大学学报,2026,49(3):653-664.

Hao X, Ren S G, Shu X, et al. Research on environmental prediction and regulation of agricultural facility environment based on TimesTransformer[J]. Journal of Nanjing Agricultural University, 2026, 49(3):653-664.

基于 TimesTransformer 的农业设施环境预测与调控研究

郝璇,任守纲*,舒欣,顾兴健,严家兴,徐焕良

(南京农业大学人工智能学院,江苏 南京 211800)

摘要:[目的]设施农业高投入、高产出,如何提高设施环境调控效益、降低能源消耗已成为其能否可持续发展的关键。构建精准的农业设施环境时序变化预测模型并据此开发设施环境智能调控算法,是实现农业低碳生产的可行途径。然而,现有预测模型未充分利用时序数据中存在的多周期性特征,导致多步预测精度提升受限,从而制约了设施环境的精准调控。本文提出了一种用于农业设施环境预测的模型及相应的调控方案。[方法]本研究在 Transformer 架构的基础上设计了农业设施环境预测模型 TimesTransformer,采用傅里叶变换获取多个时序周期特征,将其进行二维转换,随后利用局部-全局 Transformer 对二维数据实现基于时序依赖性的长期预测。基于已知环境参数,利用环境变化预测模型结合粒子群算法,搜索能耗较低且符合预期效果的环境调控方案,并与使用其他预测模型的调控方案进行对比。[结果]相比于 Crossformer 等模型,TimesTransformer 模型对农业设施环境温度的预测结果最贴合真实趋势。以溧水鸭舍数据集为例,在 12 h 预测 12 h 时,TimesTransformer 模型的决定系数(R^2)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean squared error, RMSE)3 个评价指标分别为 0.918、0.501 °C 和 0.621 °C;在 12 h 预测 6 h 时,上述 3 个评价指标分别为 0.934、0.456 °C 和 0.516 °C,优于 Crossformer 等时序预测模型。环境调控方案在 1 周内的能源消耗为 341.4 kW·h⁻¹,相比阈值控制法(504.6 kW·h⁻¹)降低了约 32.3%。[结论]本研究提出的环境变化预测模型 TimesTransformer 可以用于实现农业设施环境的长期精准预测,其配套调控方案能够显著降低调控过程中产生的能源消耗。

关键词:农业设施环境;温度预测;环境调控;快速傅里叶变换;TimesTransformer;模型预测控制

中图分类号:S625.5⁺1

文献标志码:A

文章编号:1000-2030(2026)03-0653-12

Research on environmental prediction and regulation of agricultural facility environment based on TimesTransformer

HAO Xuan, REN Shougang*, SHU Xin, GU Xingjian, YAN Jiaying, XU Huanliang

(College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 211800, China)

Abstract:[Objectives] Facility agriculture has high input and high output. How to improve the efficiency of facility environmental regulation and reduce energy consumption has become the key to its sustainable development. Constructing an accurate predictive model of the temporal changes in the agricultural facility environment and developing intelligent control algorithms for the facility environment based on this model is a feasible way to achieve low-carbon agricultural production. However, existing predictive models have not fully utilized the multi-periodicity characteristics in the temporal data, which limits the improvement of multi-step prediction accuracy and thus restricts the precise control effect of the facility environment. This paper proposed a model for the environmental prediction of agricultural facilities and the corresponding regulation scheme. [Methods] In this study, an agricultural facilities environmental prediction model, TimesTransformer, was designed based on the Transformer architecture. The Fourier transform was adopted to obtain the characteristics of multiple time series periods, which were then transformed into two-dimensional data. Subsequently, the local-global transformer was utilized to achieve long-term prediction based on the temporal dependence for the two-dimensional data. Based on the known environmental parameters, the environmental change prediction model proposed in this paper was combined with the particle swarm optimization algorithm to search for an environmental regulation scheme with low energy consumption and meeting the expected effects, and this scheme was compared with the regulation schemes using other prediction models. [Results] Compared with models such as Crossformer, the prediction results of the TimesTransformer model for the environmental temperature of agricultural facilities were the most consistent with the real trends. Taking the Lishui duck house dataset as an example, when predicting 12 h with a prediction horizon of 12 h, the three evaluation indices of the TimesTransformer model, namely the coefficient of determination (R^2), the mean

收稿日期:2025-01-19

基金项目:国家自然科学基金项目(62072247);江苏省碳达峰碳中和技术创新专项(BE2022310)

*通信作者:任守纲,副教授,博士,主要从事人工智能和农业信息化研究, E-mail:rensng@njau.edu.cn。

absolute error(MAE), and the root mean squared error(RMSE), were 0.918, 0.501 °C, and 0.621 °C, respectively. When predicting 6 h with a prediction horizon of 12 h, the above three evaluation indices were 0.934, 0.456 °C, and 0.516 °C, respectively, which were superior to time series prediction models such as Crossformer. Moreover, the energy consumption of the environmental regulation scheme proposed in this study within one week was 341.4 kW·h⁻¹, which was approximately 32.3% lower than the 504.6 kW·h⁻¹ of the threshold control method. [Conclusions] The environmental change prediction model TimesTransformer proposed in this study can be used to achieve long-term accurate prediction of agricultural facility environments. Its accompanying control scheme can significantly reduce the energy consumption generated in the control process.

Keywords: agricultural facility environment; temperature prediction; environment regulation; fast Fourier transform; TimesTransformer; model predictive control

设施农业是实现农业高效生产和逆季节生产的重要手段^[1],相较于露天农业,设施农业可通过人为干预与调控实现对温度、湿度、光照等环境要素的精细控制^[2],创造适宜生长环境,提高农业生产效益。在全球人口持续增长,农产品需求不断攀升,各国普遍面临资源紧缺与环境污染挑战的背景下,设施农业在农业领域的应用日益广泛^[3-5]。在家禽养殖业领域,适宜的环境条件对充分发挥家禽的生长潜能至关重要,而不利的环境因素则可能会抑制其生长发育^[6-7],造成出栏率下降或质量不佳^[8]。因此,对农业设施环境进行合理调控,对于提高家禽生长发育水平和实现高效稳定生产具有关键作用^[9]。

农业设施环境调控的关键在于对环境因素的精准预测。通常,农业设施内的环境因素包括温度、湿度及 CO₂ 浓度等。其中,温度对家禽的生长发育影响尤为显著^[10-11]。过低的温度可能会导致家禽生长迟缓与养殖效率下降^[12-13],而过高的温度则易引发家禽热应激,严重时甚至会导致死亡^[14]。因此,研究人员需要优先对环境温度进行精准预测,并综合考虑预测结果、其他相关环境因子及天气预报等信息,以实现对环境温度的合理调控。此类研究不仅有助于养殖人员在消耗较少能源的前提下保障家禽的健康生长,还可提升设施农业的生产效益^[15-16]。

在设施农业环境预测领域,时间序列预测算法已得到广泛应用。Nandi 等^[17]针对温度的季节性特征,设计了基于编码器-解码器结构的注意力模型(ALTf)以实现环境温度的长期预测。Zhang 等^[18]在 Transformer 模型的基础上构建了温室温度预测模型(TGTP),有效利用温室温度受多种因素影响的特性,提升了温度预测精度。Mao 等^[19]针对温室小气候的非线性与时变性问题,提出了双向门控循环单元(BiGRU-attention)和光梯度增强机(LightGBM)的变权组合预测模型,较单一模型和等权模型有更好的性能。陈冲等^[20]根据畜禽养殖环境标准,提出了基于变尺度混沌布谷鸟算法优化混合核最小二乘支持向量回归机的哺乳母猪舍养殖环境舒适度评价预测模型(MSCCS-LSSVR),提高了猪舍环境评价预测水平。农业设施环境温度的时间序列通常呈现复杂的多重周期变化(如年、月、日周期)的相互重叠与混合,这些多重周期变化导致时序存在周期内和周期间的变化,这对环境温度建模具有极大挑战性。然而,上述研究均将重点放在预测时序的时间变化上,并未研究不同周期期间和周期内的变化特征,难以对复杂的时间模式进行有效解耦,从而导致对农业设施温度预测的效果不佳。

在农业环境的调控工作中,在保证精准调控的基础上,如何降低设备能耗与提升生产效率被视为主要目标^[21]。农业设施环境调控方法中较为常用的是阈值控制法与人工控制法^[22]。阈值调控法通过设定特定的环境阈值(如温度),当环境指标达到该阈值后启动诸如风机、侧窗等调控设备,将环境参数维持在适宜范围内。然而,阈值控制法最大的缺点是能源消耗较高并且调控响应不够及时^[23]。人工控制法具有易实施的特点,但存在严重依赖经验和人工成本高昂的缺陷^[24]。除上述传统方法外,近年来环境调控领域不断有创新性研究涌现。例如,谢秋菊等^[25]提出了基于双深度 Q 网络(double deep Q-network, Double DQN)的猪舍环境优化控制策略,相较于传统温度阈值法可节省约 7.39% 的耗电量。Siskandar 等^[26]针对温室自动化系统生产效率不高的难题,采用模糊逼近法确定温室内最佳温度和湿度,从而提升产出质量与数量。然而,这些调控模型均未能利用环境因素的预测结果对环境进行调控,无法在条件变化前及时采取适当措施,为培育对象创造更为有利的生长环境,从而导致调控效率低下且能源消耗偏高。

鉴于上述设施农业环境预测和调控中的不足,本研究提出了基于 TimesTransformer 的设施环境预测与调控解决方案。在环境预测阶段,以环境温度为预测对象,面向时序数据的多周期性特征,构建出 TimesTransformer 模型。首先,利用傅里叶变换(Fourier transform)确定时序数据中最显著的 k 个周期,并依据周期大小将一维序列转换为二维数据格式。其次,设计并构建分层的 Transformer 模型,以转换后的

二维时序数据为输入,从而同时捕获时序数据在周期间和周期内的时序依赖关系,实现对农业设施环境温度的长期精准预测。在调控方案方面,本研究以模型预测得到的温度序列为基础,结合其他环境因子序列数据,采用模型预测控制(model predictive control)^[27]方法,并根据粒子群算法在调控方案解空间内搜索最优解,从而指导控制系统实施相应的调控操作,达到降低能源消耗与提升调控效率的目标。

1 材料与方法

1.1 试验数据采集与分析

1.1.1 数据采集 溧水鸭舍数据集的采集地点位于江苏省南京市溧水区(31°25'N,119°02'E),试验对象为智能化养殖鸭舍。鸭舍南北朝向,长90 m,宽17 m,高4 m,面积为1 530 m²。鸭舍建造时使用C型钢梁,房顶铺设彩钢夹芯板,采用网床养殖方式,共6张网床,每张网床距离地面1.5 m。共采集11种环境因子,分别为室内温度、室外温度、室内湿度、室外湿度、室内CO₂含量、室外CO₂含量、室内压强、室外压强、侧窗角度、湿帘、风机。鸭舍前、中、后区分别设有温度传感器和湿度传感器,中区设CO₂传感器,前区设压强传感器和小窗传感器,侧墙和山墙设置湿帘传感器。采用的传感器技术参数如表1所示。数据采集时间为自2023年5月25日00:00至2023年7月18日03:00,记录间隔为5 min,共15 589条数据。

表1 传感器技术参数

Table 1 Technical specifications of sensors

传感器类型 Sensor types	型号 Model	精度 Accuracy	测量范围 Measurement range
室内温度/℃ Indoor temperature	RS-WS-N01	±0.35	-40~80
室外温度/℃ Outdoor temperature	RS-WS-N01	±0.35	-40~80
室内湿度/% Indoor humidity	RS-WS-N01	±3	0~100
室外湿度/% Outdoor humidity	RS-WS-N01	±3	0~100
室内CO ₂ 含量/(mg·m ⁻³) Indoor carbon dioxide concentration	RS485	±50	0~5 000
室外CO ₂ 含量/(mg·m ⁻³) Outdoor carbon dioxide concentration	RS485	±50	0~5 000
室内压强/Pa Indoor pressure	RS-QY	±0.5	0~1 000
室外压强/Pa Outdoor pressure	RS-QY	±0.5	0~1 000
侧窗/(°) Side window	NVW5792	±0.2	0~90
湿帘/(m ³ ·h ⁻¹) Wet curtain	DR-35	±1.5	0~600
风机/Pa Fan	DF-1000	±0.5	0~1 000

公共数据集:阿布扎比温室使用风机湿帘降温系统,室内布置3个温度、湿度采集点,位置分别为距入口2、15和28 m的地方,另外采集室内风机湿帘状态等;室外采集数据包括温度、湿度、光照强度、风速等。自2015年12月11日00:00至2016年2月10日23:55,记录间隔为5 min,共17 856条数据。

1.1.2 数据预处理与特征变量选择 由于数据量纲不同,对多变量时间序列中的每一个变量 x 采取如式(1)的数据归一化。

$$x' = \frac{x - \bar{x}}{\sqrt{\text{var}(x)}} \quad (1)$$

式中: x 是多变量时间序列中的一个变量序列; $\bar{x}$ 是 x 的平均值; $\sqrt{\text{var}(x)}$ 是 x 的方差; x' 是经过标准化计算后的数值,原始数据中的各变量均按照标准化方法处理。

通过相关系数(R)衡量每个环境变量与室内温度之间的相关性。当 $0.8 < |R| \leq 1$ 时,两者被认为具有极强的相关性;当 $0.6 < |R| \leq 0.8$ 时,两者被认为具有较强相关性;当 $0.4 < |R| \leq 0.6$ 时,两者被认为具有中等相关性;当 $0.2 < |R| \leq 0.4$ 时,两者被认为具有较弱相关性;当 $0 < |R| \leq 0.2$ 时,两者被认为具有极弱相关性。采用 $|R|$ 大于0.5的变量作为最终的特征输入变量。相关系数(R)的计算如式(2)所示。

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2)$$

式中: X_i 、 Y_i 分别表示环境变量和室内温度序列在第 i 个时间步的数据; n 为样本数量; $\bar{X}$ 、 $\bar{Y}$ 分别表示环境变量与室内温度的平均值。

经计算,室外温度、室内湿度、室外湿度、室内CO₂含量、室外CO₂含量、室内压强、室外压强、侧窗角

度、湿帘状态、风机状态的 $|R|$ 分别为0.837、0.695、0.476、0.581、0.389、0.563、0.254、0.513、0.674、0.623。选择 $|R|$ 大于0.5的变量作为特征输入变量,因此,选择的特征输入变量为室外温度、室内湿度、室内 CO_2 含量、室内压强、侧窗角度、湿帘状态、风机状态。

1.2 TimesTransformer 模型结构

1.2.1 TimesTransformer 模型整体结构 TimesTransformer 模型包含3个主要部分:1)对一维时序数据进行二维空间转换;2)捕获二维序列中周期间和周期内时序特征的局部-全局 Transformer 模型;3)对不同周期对应二维特征的自适应聚合。TimesTransformer 模型整体结构图如图1所示。




图1 TimesTransformer 模型整体结构图

Fig. 1 Overall structure diagram of TimesTransformer model

模型以长度为 T 的一维时间序列 $X_{1d} \in \mathbf{R}^{T \times C}$ 为输入,首先通过嵌入层 $X'_{1d} = \text{Embed}(X_{1d})$ 将时间戳特征融入时序数据中,即 $X'_{1d} \in \mathbf{R}^{T \times d_{\text{model}}}$ 。周期内和周期外的变化涉及多个高度结构化的二维张量,利用快速傅里叶变换,分析输入时序数据中蕴含的周期叠加情况,筛选出最显著的 k 个周期。依据周期将一维时序数据分别转换为对应的二维序列,二维序列输入局部-全局 Transformer 后,将计算后得到的 k 个一维表示 $\{\hat{X}_{1d}^1, \dots, \hat{X}_{1d}^k\}$ 完成跨周期和周期内的特征捕获。基于振幅的一维表示聚合:

$$\hat{A}_{f_1}, \dots, \hat{A}_{f_k} = \text{Softmax}(A_{f_1}, \dots, A_{f_k}) \quad (3)$$

$$X_{1d} = \sum_{i=1}^k \hat{A}_{f_i} \times \hat{X}_{1d}^i \quad (4)$$

式中: k 为所选最显著周期的数量; f_k 为频率; A_{f_k} 为振幅; $\hat{A}_{f_k}$ 为经过 $\text{Softmax}(\cdot)$ 计算后的成分权重;根据各频率的相对重要性分配权重, $\hat{X}_{1d}^i$ 为一维表示的时间序列数据; X_{1d} 为根据权重聚合后的一维时序数据。

1.2.2 快速傅里叶变换 农业设施环境的时序变化往往呈现多重周期特征,例如日周期、周周期与月周期,这些周期相互叠加与影响,增加了时序数据建模与预测的复杂性。充分提取时序数据中的多周期性对于精确预测设施环境温度至关重要。采用快速傅里叶变换(FFT)^[28]对时序数据进行多周期性分析,如式(5)所示。

$$f_k = \sum_{t=0}^{T-1} X'_{1d} \cdot e^{-j\frac{2\pi}{T}kt}, \quad k=0, 1, \dots, T-1 \quad (5)$$

式中: k 为所选最显著周期的数量; T 为时序数据长度; C 为变量数量; $X_{1d} \in \mathbf{R}^{T \times C}$ 表示长度为 T , 包含 C 个变量的一维时间序列, 本研究中 C 的值为 8; j 为虚数单位 ($j = \sqrt{-1}$); $e^{-j\frac{2\pi}{T}kt}$ 为复指数形式的基函数, 用于表示不同频率的正弦波; X_{1d}^t 为一维时序信号的第 t 个样本点; f_k 为频域信号的第 k 个频率分量。

为了捕获周期性和周期内的依赖性, 根据快速傅里叶变换在频域上对时间序列进行分析, 进而计算出时序数据的周期长度, 如式(6)一式(8)所示:

$$A = \text{AVG}(\text{AM}(\text{FFT}(X_{1d}))) \quad (6)$$

$$f_1, \dots, f_k = \text{Topk}(A) \quad (7)$$

$$p_i = \lceil \frac{T}{f_i} \rceil, \quad i \in \{1, \dots, k\} \quad (8)$$

式中: X_{1d} 为一维时间序列; $\text{FFT}(\cdot)$ 为快速傅里叶变换运算; $\text{AM}(\cdot)$ 用于计算幅度值; $\text{AVG}(\cdot)$ 用于计算多个变量的幅度值的平均值; A 代表每个频率所对应的振幅; k 为所选最显著周期的数量; $\text{Topk}(\cdot)$ 用于从所得结果中选取最高的若干个值; $f_1, \dots, f_k$ 为选取出的 k 个最显著频率; T 为时序数据长度; f_k 为频率; p_i 为与频率 f_i 相对应的周期长度。

根据 k 个频率 $f_1, \dots, f_k$ 及其对应的 k 个周期 $p_1, \dots, p_k$, 可以将一维时间序列 $X_{1d} \in \mathbf{R}^{T \times C}$ 转换为二维序列。将时间序列沿着时间维度进行零扩展, 以实现如图 1 所示的维度转换, 转换后的二维序列表示为 $X_{2d}^i \in \mathbf{R}^{p_i \times f_i \times C}$ 。式中: p_i 和 f_i 分别代表二维序列在周期长度为 p_i 时的周期内变化和周期间变化。基于选取的 k 个最显著频率, 可以构建一组二维序列 $\{X_{2d}^1, \dots, X_{2d}^k\}$, 每个二维序列分别表示时间序列在对应周期下的二维变化趋势。

1.2.3 局部-全局 Transformer 模块 在时序分析领域, Transformer 通常只适用于处理一维数据, 无法直接处理二维时序数据。本研究对 Transformer 模型进行了改进, 提出了局部-全局 Transformer 模型, 旨在分阶段地捕获时序数据在周期内和周期间的依赖关系。二维时序数据 X_{2d}^i 经过局部-全局 Transformer 特征提取后得到二维表示 $\hat{X}_{2d}^i$, 将 $\hat{X}_{2d}^i$ 转换回一维空间得到 $\hat{X}_{1d}^i \in \mathbf{R}^{T \times d_{\text{model}}}$, 并将长度为 $p_i \times f_i$ 的填充序列截断为长度为原始长度 T 的序列数据。为了提高参数利用率, 对不同的二维张量 $\{X_{2d}^1, \dots, X_{2d}^k\}$ 使用共享的局部-全局 Transformer, 使模型的大小不会随超参数 k 的变化而变化。局部-全局 Transformer 模块的结构图如图 2 所示。




图 2 局部-全局 Transformer 模块结构图

Fig. 2 Local-global Transformer module structure diagram

局部-全局 Transformer 模型中的局部位置编码(local position encoder)、全局位置编码(global position encoder)使用正弦和余弦函数对输入进行编码。与标准的 Transformer 不同, 局部-全局 Transformer 编码器的数据处理过程如图 3 左侧所示。编码器由局部编码器(local encoder)和全局编码器(global encoder)组成, 使用局部编码器进行周期内的信息提取, 同时还对二维空间的序列数据进行重塑, 使之可以按照时间

步处理每个周期的数据。局部编码器的输出为 $E_{\text{local}} \in \mathbf{R}^{L \times (B \cdot P) \times d_{\text{model}}}$ 。为了获取周期内的时序依赖性,将局部编码器的输出聚合,即在每个周期内的时间步平均池化(average pooling),得到每个周期的代表性向量,并输入全局编码器中,对周期之间的关系进行编码。全局编码器输入 $E_{\text{global}} \in \mathbf{R}^{P \times B \times d_{\text{model}}}$,全局编码器输出为 $E_{\text{global}} \in \mathbf{R}^{P \times B \times d_{\text{model}}}$ 。




图 3 局部-全局 Transformer 数据处理过程

Fig. 3 Local-global Transformer data processing process

B 为批次大小; P 为周期数量; L 为周期长度; d_{model} 为嵌入维度; N_{predict} 、 GT'_{predict} 、 T'_{predict} 分别为初始、转换后和结果的预测序列长度; N_{label} 、 GT'_{label} 、 T'_{label} 分别为原始、转换后和结果的标签序列长度; D_{global} 、 D_{local} 、 D'_{global} 分别为全局、局部和扩展后全局解码器输出; E_{global} 、 E_{local} 为全局、局部编码器输出; I_{global} 为全局编码器输入; I_{2D} 、 I_{1D} 分别为二维、一维时序输入。

B is the batch size; P is number of cycles; L is cycle length; d_{model} is embedding dimension; N_{predict} , GT'_{predict} , T'_{predict} are the lengths of initial, transformed, and result prediction sequences; N_{label} , GT'_{label} , T'_{label} are lengths of initial, transformed, and result label sequences; D_{global} , D_{local} , D'_{global} are global, local, and expanded global decoder outputs; E_{global} , E_{local} are global, local encoder outputs, respectively; I_{global} is input to the global encoder; I_{2D} , I_{1D} are 2D and 1D temporal input.

解码器的数据处理过程如图 3 右侧所示,采用自回归的方式预测未来目标序列。在输入解码器前将序列沿着时间维度整体向后移动预测长度 N_{predict} ,从而创建滞后时间步,因此解码器输入总长度为原始标签序列长度(N_{label})和初始预测序列长度(N_{predict})的和。与编码器相似,解码器同样经过维度转换将一维时序转换至二维空间,分别对局部依赖性和全局依赖性进行解码,依次经过局部解码器和全局解码器计算,从而根据局部依赖关系和全局信息特征预测出对应长度的结果(T'_{predict})。局部解码器输出为 D_{local} ,全局解码器输出为 D_{global} 。

1.3 预测相关序列数据对齐方式

不同于其他预测模型所进行的单变量预测,对农业设施环境的预测采用多变量预测,不同序列之间的数据对齐方式如图 4 所示。历史环境相关因子序列包括历史室内湿度、 CO_2 含量等序列,调控方案序列指各类调控设备的调控记录序列,历史室外温度序列指农业设施环境外不同位置的温度值序列,室外温度预测序列指预测时间段内当地的天气预测所提供的温度值,目标序列即需要预测的序列。设定为固定点位的室内温度,时间点以 t_1 为划分, t_1 前的数据为历史数据, t_1 至 t_2 内的时间为预测时间段。利用历史环境相关因子序列、历史调控方案序列、未来调控方案序列、历史室外温度序列、室外温度预报序列、历史目标序列对目标序列进行预测。




图4 预测相关序列数据对齐方式示意图

Fig. 4 Schematic diagram of alignment method for prediction related sequence data

1.4 基于 TimesTransformer 与粒子群算法的优化调控

以降低农业设施环境调控过程中的能源消耗为目标,设计基于 TimesTransformer 与粒子群算法结合的优化调控方案。利用粒子群算法生成不同的调控方案,根据预测模型 TimesTransformer,依据能源消耗投入最低对方案进行评价,确定最优调控方案。流程如图5所示。

首先,将时序数据输入模型,时序数据包括历史环境相关因子序列即驱动序列、初始调控方案序列、历史室外温度序列、室外温度预报序列、历史目标序列。将时序数据作为模型参数,设计其编码方式,根据降低能源消耗的原则建立目标函数。利用粒子群算法在调控设备控制组合空间中随机生成指定数量的粒子,初始化粒子群体以满足输入需求,生成调控方案,调控方案序列输入时序预测模型 TimesTransformer,利用模型对目标序列进行预测,判断预测结果是否符合调控要求。如果符合要求即目标温度在规定区间内,则更新粒子群速度和位置,继续判断是否满足结束条件,满足结束条件输出最优调控方案,否则返回生成调控方案。若不符合调控要求则重新生成调控方案,进行下一轮迭代。结束条件是达到最大迭代次数或输出结果收敛。最终,通过粒子群优化更新迭代,输出最优的调控方案以指导控制系统执行相应调控。

调控方案的编码方案(式(9)),即不同设备在输入窗口中的调控序列。这些序列与设备的操作和类型有关,使用浮点数来表示调控操作。在预测模型的训练过程中,设备的输入参数都经过标准化处理,数值范围为 $-1 \sim 1$,因此在此处采用相似的数值范围。

$$X = \begin{pmatrix} x^{11} & \cdots & x^{1d} \\ \vdots & x^{\frac{T}{2} \frac{d}{2}} & \vdots \\ x^{T1} & \cdots & x^{Td} \end{pmatrix} \quad (9)$$

式中: T 为时序数据长度; d 为调控设备的总数量; x^{ij} 为第 j 个设备 i 时间步所需执行的操作; $x^{ij} \in (-1, 1)$ 。 $X = \{x^1, x^2, \dots, x^{dxT}\}$ 为粒子的位置,其中每个分量与上式中的元素一一匹配。

目标函数(式(10))是评价粒子群优劣的重要指标。针对需要解决的限定条件下搜索最优调控方案的目标,调控的目的是让农业设施环境温度介于设定范围之间,同时降低所需能耗。




图5 基于粒子群的设施农业模型预测控制算法

Fig. 5 Predictive control algorithm for facility agriculture model based on particle swarm optimization

$$f(X) = \sum_t^T \sum_j^d (\text{prices}_j \cdot X^{tj}) \quad (10)$$

式中: T 为时序数据长度; d 为调控设备的总数量; prices_j 表示调控第 j 个设备所消耗的能源; X^{tj} 表示第 j 个设备在 t 时间步所需执行的操作; $f(X)$ 表示对当前调控方案的总能源消耗的衡量。

2 试验结果与分析

2.1 评价标准

本研究采用的模型评价指标包括平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和决定系数 R^2 。其表达式如式(11)~式(13)所示:

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} \quad (13)$$

式中: n 为样本总数; y_i 表示第 i 个真实值; $\hat{y}_i$ 表示第 i 个预测值。

2.2 试验配置

利用 pytorch2.2.2 深度学习框架,在 NVIDIA Quadro P5000 显卡上搭建模型。模型参数设置:输入序列长度为 144 步,即 12 h;预测序列长度为 144 步、72 步,即 12 h、6 h;学习率为 0.000 1;最显著周期数量 (k) 为 3;训练迭代次数为 40;批量大小 (batch size) 为 32。为了模型对比的公平性,不同模型设置相同的参数。

2.3 温度预测结果

2.3.1 预测拟合效果 为了充分验证 TimesTransformer 模型相比 Transformer 模型以及现有研究中应用较为广泛的几种典型深度学习模型在温度预测方面的提升效果,将 TimesTransformer 模型与预测控制模型相结合可以实现对温度的精确调控,在不同预测时长下将 TimesTransformer 模型与 5 种应用广泛的深度学习模型 (Transformer、Crossformer、Autoformer、TimesNet、PatchTST) 对农业设施环境温度预测的表现进行对比与分析。

图 6 分别为 TimesTransformer、Transformer、Crossformer、Autoformer、TimesNet、PatchTST 模型在预测时长分别为 6 和 12 h 时预测值和真实值的对比曲线,GT 表示温度真实值。试验数据分别选取 2023 年 6 月 15 日 06:00—12:00 和 2023 年 6 月 15 日 06:00—18:00。通过观察图 6 中 TimesTransformer 模型与其他 5 种模型对溧水鸭舍温度的预测曲线可以得出,在不同预测长度下,TimesTransformer 模型所预测的温度变化趋势与真实值的拟合程度最好。




图 6 预测时长 6 和 12 h 预测值与真实值曲线对比

Fig. 6 Comparison of predicted and actual value curves for a duration of 6 and 12 h

GT: 温度真实值 True temperature.

2.3.2 预测误差分析 在相同的试验环境中,使用 TimesTransformer、Transformer、Crossformer、Autoformer、TimesNet、PatchTST 模型进行多变量多步预测,收集各模型的预测结果,使用输入步长为 144 步(12 h)来分别预测步长 144 步(12 h)和 72 步(6 h)。详细试验结果如表 2 所示。预测时长为 72 步即 6 h 时,TimesTransformer 模型预测的平均绝对误差为 0.456 °C,均方根误差为 0.516 °C,其他 5 种模型的平均绝对误差最小为 0.775 °C,均方根误差最小为 0.901 °C,均大于 TimesTransformer 模型的预测误差。预测时长为 144 步即 12 h 时,TimesTransformer 模型预测的平均绝对误差为 0.501 °C,均方根误差为 0.621 °C,其他 5 种模型的平均绝对误差最小为 0.911 °C,均方根误差最小为 1.184 °C,均大于 TimesTransformer 模型的预测误差。并且,在 2 种预测长度条件下,TimesTransformer 模型的决定系数(R^2)均大于其他对比模型。综上,在不同预测时长的条件下,通过决定系数、平均绝对误差、均方根误差评价指标的对比得出,TimesTransformer 模型具有更高的预测精度,能够更为准确地预测农业设施环境温度。

表 2 不同模型试验结果对比

Table 2 Comparison experimental results of different models

预测模型 Prediction model	预测步长 Prediction step length	MAE/°C	RMSE/°C	R^2
TimesTransformer	72	0.456	0.516	0.934
	144	0.501	0.621	0.918
Transformer	72	1.003	1.131	0.847
	144	1.313	1.740	0.839
Crossformer	72	1.056	1.125	0.917
	144	1.128	1.330	0.865
Autoformer	72	1.383	1.461	0.851
	144	1.612	1.693	0.822
TimesNet	72	0.775	0.939	0.904
	144	0.911	1.184	0.891
PatchTST	72	0.822	0.901	0.893
	144	1.354	1.755	0.864

2.3.3 模型泛化能力验证 在相同的试验环境中,使用 TimesTransformer、Transformer、Crossformer、Autoformer、TimesNet、PatchTST 模型分别在阿布扎比数据集上进行多变量多步预测,验证模型的泛化能力。使用输入步长为 144 步,即 12 h,预测步长分为 144 步(12 h)和 72 步(6 h)两种情况。由表 3 的试验结果对比可知,在阿布扎比数据集上,预测时长为 72 步(6 h)时,TimesTransformer 模型预测的平均绝对误差为 0.409 °C,均方根误差为 0.525 °C,其他 5 种模型的平均绝对误差最小为 0.412 °C,均方根误差最小为 0.530 °C,均大于 TimesTransformer 模型的预测误差。预测时长为 144 步(12 h)时,TimesTransformer 模型预测的平均绝对误差为 0.435 °C,均方根误差为 0.632 °C,其 5 种模型的平均绝对误差最小为 0.431 °C,小于 TimesTransformer 模型,均方根误差最小为 0.642 °C,均大于 TimesTransformer 模型的预测误差。并且,在两种预测长度条件下,TimesTransformer 模型的决定系数(R^2)均大于其他对比模型。综上,在不同预测时长的条件下,通过决定系数、平均绝对误差、均方根误差评价指标的对比得出,TimesTransformer 模型在阿布扎比数据集上具有较好的预测精度。

表 3 阿布扎比数据集预测结果对比

Table 3 Comparison of prediction results for Abu Dhabi dataset

预测模型 Prediction model	预测步长 Prediction step length	MAE/°C	RMSE/°C	R^2
TimesTransformer	72	0.409	0.525	0.917
	144	0.435	0.632	0.908
Transformer	72	0.412	0.530	0.824
	144	0.447	0.693	0.816
Crossformer	72	0.428	0.546	0.849
	144	0.452	0.687	0.832
Autoformer	72	0.646	0.782	0.874
	144	0.684	0.902	0.859
TimesNet	72	0.418	0.587	0.903
	144	0.431	0.719	0.892
PatchTST	72	0.436	0.592	0.871
	144	0.445	0.642	0.868

2.3.4 效率分析 TimesTransformer 模型的计算复杂度主要来源于傅里叶计算和局部-全局 Transformer, 快速傅里叶计算的计算复杂度为 $O(L \log_2 L)$, 局部-全局 Transformer 的计算复杂度为 $O(LD^2)$, 所以 TimesTransformer 模型整体的计算复杂度为 $O(L \log_2 L + LD^2)$ 。其中: L 代表序列长度; D 代表数据的维度。

TimesTransformer 的计算复杂度显著低于 Transformer 模型的 $O(L^2)$, 但高于 PatchTST 模型的 $O\left(\frac{L}{L_{\text{seg}}}\right)$, L_{seg} 代表序列分段长度。

为对比分析模型的效率, 本研究比较了不同时序预测模型的运行时间。分析结果如图 7, 数据集采用溧水鸭舍数据集, 模型运行次数设为 50, 记录每个 batch 的平均运行时间。在相同试验环境下, TimesTransformer 模型的运行时间明显短于 Transformer 模型和 Crossformer 模型, 与 Autoformer、TimesNet 模型整体上比较接近。当输入序列长度增长时, TimesTransformer 模型的运行时间略高于 PatchTST 模型。

2.3.5 消融试验 TimesTransformer 模型使用快速傅里叶变换提取时序数据周期, 利用局部-全局 Transformer 模块捕获周期内与周期间的依赖关系。快速傅里叶变换提取周期的目的是将

一维时间序列数据转换为二维时间序列数据, 这个操作对于时间序列预测的作用可以由 2.3.2 节的试验体现。为验证局部-全局 Transformer 模块对模型预测能力的提升, 通过消融试验对其作用进行评估。消融试验用常见的神经网络 ResNet 和 CNN 替代局部-全局 Transformer 模块。分别记录使用 3 种不同的神经网络模块在相同试验条件下进行预测的 MAE 值和 RMSE 值, 设置输入步长为 144 步, 预测步长分别为 72 步和 144 步。结果如表 4 所示。




图 7 模型运行时间对比
Fig. 7 Comparison of model running time

表 4 不同二维特征提取模块对模型预测精度的影响

Table 4 Influence of different two-dimensional feature extraction modules on model prediction accuracy

数据集 Data set	预测步长 Prediction step length	局部-全局 Transformer Local-Global Transformer		ResNet		CNN	
		MAE/℃	RMSE/℃	MAE/℃	RMSE/℃	MAE/℃	RMSE/℃
溧水鸭舍	72	0.456	0.516	0.629	0.732	0.653	0.781
Lishui duckhouse	144	0.501	0.621	0.704	0.819	0.854	0.972
阿布扎比	72	0.409	0.525	0.587	0.692	0.627	0.743
Abu Dhabi	144	0.435	0.632	0.613	0.841	0.782	0.965

由表 4 可知, 在 TimesTransformer 中采用局部-全局 Transformer 模块作为二维特征提取模块时, 模型的预测误差最小, 预测效果均优于将 ResNet 和 CNN 作为二维特征提取模块。以溧水鸭舍数据集且预测步长为 72 步为例, 使用局部-全局 Transformer 模块作为二维特征提取模块时 MAE 为 0.456 ℃, RMSE 为 0.516 ℃, 使用 ResNet 作为二维特征提取模块时 MAE 为 0.629 ℃, RMSE 为 0.732 ℃, 使用 CNN 作为二维特征提取模块时 MAE 为 0.653 ℃, RMSE 为 0.781 ℃, 均高于使用局部-全局 Transformer 模块作为特征提取模块时的预测精度。消融试验结果表明, 局部-全局 Transformer 模块在 TimesTransformer 模型中表现出较好的预测能力, 可以实现更加精准的农业设施环境时序预测。

2.4 温度调控结果

溧水鸭舍中各设备的数量和单个设备的能源消耗情况如表 5 所示。根据调控的实际需求, 设置粒子各参数的边界为 0~1, 所采用的溧水鸭舍数据集包括 3 种可调控设备, 精细调控步骤为 20, 粒子的位置设置为 $x \in (0, 1)^{120}$, 并将惯性因子设置为随迭代次数线性下降。经过超参数寻优, 使用加速因子 $c^{(1)} = 0.5$, $c^{(2)} = 0.5$, 惯性因子 $w = 0.8$, 种群数量为 40, 最大迭代次数为 50。

表 5 溧水鸭舍环境调控执行器

Table 5 Lishui duckhouse environmental control actuator

处理 Treatment	执行器 Actuator	操作类型 Operation type	能源消耗/(kW·h ⁻¹) Energy consumption	数量 Number
通风 Ventilation	侧窗 Side window	电机 Motor	0.45	30
降温 Cooling	湿帘 Wet curtain	电机 Motor	1.25	8
换气 Change air	风机 Fan	电机 Motor	1.50	12

将不同的预测算法应用于模型预测控制进行对比,将阈值控制法和应用不同预测算法的模型预测控制方法在 2023 年 5 月 25 日至 5 月 31 日 1 周内调控的能源消耗记录见表 6,每日调控时间段为 10:00—16:00,调控目标为鸭舍中区温度为 28~32℃。从表 6 的结果对比可以看出,将时序预测模型 TimesTransformer 应用于模型预测控制进行调控后的能源消耗是最低的,相比阈值控制法能源消耗降低了约 32.3%,验证了将多元时序预测模型 TimesTransformer 应用于农业设施环境后的预测准确度较高,并可以以此指导农业设施环境的调控,降低调控过程中所产生的能耗。

表 6 不同调控模型一周能源消耗对比
Table 6 Comparison of weekly energy consumption among different regulation models kW·h⁻¹

指标 Index	TimesTransformer	阈值法 Threshold	Transformer	Crossformer	Autoformer	TimesNet	PatchTST
能源消耗 Energy consumption	341.4	504.6	389.5	392.8	423.2	372.4	419.5

3 结论

针对 Transformer 等传统模型在利用时间序列多周期性特征方面存在的不足以及预测精度不高的问题,本研究在 Transformer 架构的基础上创新提出 TimesTransformer 模型。该方法首先采用快速傅里叶变换提取时序数据中的不同周期特征,并将一维时间序列数据转换为二维空间表示。利用局部-全局 Transformer 分别捕捉时序数据在不同周期期间及周期内的依赖性,从而解决传统 Transformer 模型忽略时序多周期性的问题。此外,本研究将构建的预测模型与模型预测控制算法相结合,应用于农业设施环境温度的调控。通过试验验证 TimesTransformer 模型在预测精度和调控能源消耗方面的表现,并对试验结果进行对比分析,得出如下结论:

- 1) TimesTransformer 模型温度预测值与真实值的变化趋势高度一致。在溧水鸭舍数据集进行试验,预测时长为 6 h 时,其决定系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)分别为 0.934、0.456℃、0.516℃;在预测时长为 12 h 时, R^2 、MAE 和 RMSE 分别为 0.918、0.501℃、0.621℃,试验结果表明 TimesTransformer 在预测性能上优于 Transformer 及其他 5 种模型。此外,在 Abu Dhabi 数据集温室数据集上进行对比试验,验证了模型具有较强的泛化能力。效率分析试验表明 TimesTransformer 模型的运行效率仅次于 PatchTST 模型,高于其他对比模型。消融试验验证了 TimesTransformer 模型的核心局部-全局 Transformer 模块对预测精度的提升效果优于 ResNet 和 CNN。
- 2) 根据多变量多步时序预测模型——TimesTransformer 设计农业设施环境调控方法。试验结果表明,与阈值控制法及其他预测算法的模型预测控制方法相比,应用 TimesTransformer 在农业设施环境调控中,其整体能源消耗降低了约 32.3%。这表明 TimesTransformer 具有较高的时序预测精度,能够有效捕捉农业设施环境中的复杂时序特征,并准确预测环境参数的未来变化趋势。基于该预测结果,系统可以提前采取合理的调控措施,以更优的方式调度调控设备,避免不必要的能源消耗,提高调控的精细度和智能化水平。

参考文献 References:

[1] Maraveas C, Karavas C S, Loukatos D, et al. Agricultural greenhouses: resource management technologies and perspectives for zero greenhouse gas emissions[J]. Agriculture, 2023, 13(7): 1464–1509.

[2] Goh Y S, Hum Y C, Lee Y L, et al. A meta-analysis: food production and vegetable crop yields of hydroponics[J]. Scientia Horticulturae, 2023, 321(15): 112339.

[3] Gu D N, Andreev K, Dupre M E. Major trends in population growth around the world[J]. China CDC Weekly, 2021, 3(28): 604–613.

[4] Mittal A, Brajpuriya R, Gupta R. Solar steam generation using hybrid nanomaterials to address global environmental pollution and water shortage crisis[J]. Materials Today Sustainability, 2023, 21(1): 100319.

[5] Alabi T M, Aghimien E I, Agbajor F D, et al. A review on the integrated optimization techniques and machine learning approaches for modeling, prediction, and decision making on integrated energy systems[J]. Renewable Energy, 2022, 194(14): 822–849.

[6] 黄银锋, 孙国祥, 汪小岳, 等. 设施农业自主移动装备导航技术研究进展[J]. 智能化农业装备学报(中英文), 2025, 6(4): 1–16.
Huang Y F, Sun G X, Wang X C, et al. Research progress in navigation technology for autonomous mobile equipment in facility agriculture[J]. Journal of Intelligent Agricultural Mechanization(in Chinese and English), 2025, 6(4): 1–16(in Chinese with English abstract).

[7] 谢苗苗, 李华龙, 詹凯. 基于多元数据的夏季鸡舍环境质量评价及其对产蛋性能的影响[J]. 农业工程学报, 2024, 40(8): 188–197.
Xie M M, Li H L, Zhan K. Evaluating the environmental quality of layer house in summer based on multivariate data and its impact on production

- performance[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(8): 188–197 (in Chinese with English abstract).
- [8] Javaid M, Haleem A, Khan I H, et al. Understanding the potential applications of artificial intelligence in agriculture sector[J]. Advanced Agrochem, 2023, 2(1): 15–30.
- [9] 朱德兰, 涂泓滨, 王瑞心, 等. 基于分段多区间的温室夏季温湿度智能控制策略[J]. 农业机械学报, 2022, 53(9): 334–341.
Zhu D L, Tu H B, Wang R X, et al. Intelligent control strategy of temperature and humidity in greenhouse in summer based on subsection and multi-interval[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 334–341 (in Chinese with English abstract).
- [10] Chen J D, Zhu D D, Ding S J, et al. Government environmental concerns and corporate green innovation: evidence from heavy-polluting enterprises in China[J]. Business Strategy and the Environment, 2024, 33(3): 1920–1936.
- [11] Li H, Zhang L, Zhang J, et al. Impact of technological innovation on agricultural green total factor productivity in China: considering the threshold effect of environmental regulation[J]. Journal of Environmental Planning and Management, 2025, 68(5): 1057–1081.
- [12] 陈安琪, 杨春彦, 董丙强, 等. 家禽肉品质评价指标及其影响因素研究进展[J]. 东北农业大学学报, 2024, 55(5): 90–100.
Chen A Q, Yang C Y, Dong B Q, et al. Research progress on evaluation indices of poultry meat quality and its influencing factors[J]. Journal of Northeast Agricultural University, 2024, 55(5): 90–100 (in Chinese with English abstract).
- [13] Vandana G D, Sejian V, Lees A M, et al. Heat stress and poultry production: impact and amelioration[J]. International Journal of Biometeorology, 2021, 65(2): 163–179.
- [14] Chen S L, Liu A L, Tang F, et al. A review of environmental control strategies and models for modern agricultural greenhouses[J]. Sensors, 2025, 25(5): 1388–1410.
- [15] Peng B, Guan K Y, Tang J Y, et al. Towards a multiscale crop modelling framework for climate change adaptation assessment[J]. Nature Plants, 2020, 6(4): 338–348.
- [16] Sun N, Fan B B, Ding Y H, et al. Analysis of the development status and prospect of China's agricultural sensor market under smart agriculture[J]. Sensors, 2023, 23(6): 3307–3321.
- [17] Nandi A, De A, Mallick A, et al. Attention based long-term air temperature forecasting network: ALTF Net[J]. Knowledge-Based Systems, 2022, 252(18): 109442.
- [18] Zhang K N, Qiang S Y, Liang Z X, et al. A greenhouse temperature prediction framework based on transformer neural network[C]//2021 International Conference on Computer Information Science and Artificial Intelligence (CISAI). September 17–19, 2021, Kunming, China. Piscataway: IEEE, 2021: 232–236.
- [19] Mao X J, Ren N, Dai P Y, et al. A variable weight combination prediction model for climate in a greenhouse based on BiGRU-Attention and LightGBM[J]. Computers and Electronics in Agriculture, 2024, 219(4): 108818.
- [20] 陈冲, 刘星桥, 刘超吉, 等. 哺乳母猪舍环境舒适度评价预测模型优化[J]. 农业机械学报, 2020, 51(8): 311–319.
Chen C, Liu X Q, Liu C J, et al. Optimization of evaluation and prediction model of environmental comfort in lactating sow house[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 311–319 (in Chinese with English abstract).
- [21] Xu L Y, Jiang J, Du J G. How do environmental regulations and financial support for agriculture affect agricultural green development? The mediating role of agricultural infrastructure[J]. Journal of Environmental Planning and Management, 2025, 68(3): 557–584.
- [22] Ragaveena S, Shirly E A, Surendran U. Smart controlled environment agriculture methods: a holistic review[J]. Reviews in Environmental Science and Biotechnology, 2021, 20(4): 887–913.
- [23] Venkataramanan V, Kavitha G, Joel M R, et al. Forest fire detection and temperature monitoring alert using IoT and machine learning algorithm[C]//2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT). January 23–25, 2023, Tirunelveli, India. Piscataway: IEEE, 2023: 1150–1156.
- [24] Tran D, Schouteten J J, Degieter M, et al. European stakeholders' perspectives on implementation potential of precision weed control: the case of autonomous vehicles with laser treatment[J]. Precision Agriculture, 2023, 24(6): 2200–2222.
- [25] 谢秋菊, 王圣超, MUSABIMANA J, 等. 基于深度强化学习的猪舍环境控制策略优化与能耗分析[J]. 农业机械学报, 2023, 54(11): 376–384, 430.
Xie Q J, Wang S C, Musabimana J, et al. Pig building environment optimization control and energy consumption analysis based on deep reinforcement learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 376–384, 430 (in Chinese with English abstract).
- [26] Siskandar R, Santosa S H, Wiyoto W, et al. Control and automation: insmoaf (integrated smart modern agriculture and fisheries) on the greenhouse model[J]. Jurnal Ilmu Pertanian Indonesia, 2022, 27(1): 141–152.
- [27] Hu J F, Shan Y H, Guerrero J M, et al. Model predictive control of microgrids: an overview[J]. Renewable and Sustainable Energy Reviews, 2021, 136: 110422.
- [28] Ghanbari T, Mehraban A. Stator winding fault detection of induction motors using fast fourier transform on rotor slot harmonics and least square analysis of the Park's vectors[J]. IET Electric Power Applications, 2024, 18(3): 356–366.