doi:10.6041/j.issn.1000-1298.2025.07.051

基于 3DCNN 融合 TFT 的储粮结露风险预测研究

李欣泽[1]　乔星瀚[2]　王文越[3]　乌云山丹[1]　吴文福[1]　郭鸿鹏[1]　卢延辉[2]

(1. 吉林大学农业与生物工程学院, 长春 130022; 2. 吉林大学汽车工程学院, 长春 130022;
3. 新疆维吾尔自治区粮油科学研究所, 乌鲁木齐 830000)

摘要: 针对当前储粮结露风险预测主要依赖简单粮温监测和经验判断、缺乏准确预测工具的问题,本文提出了一种结合三维卷积神经网络(3DCNN)和时间融合变换器(TFT)的储粮结露风险预测方法。该方法通过 3DCNN 提取粮堆内部温度场的空间特征,结合 TFT 处理时间序列数据,基于历史气象数据和未来气象预报数据,实现了粮堆温度场的高精度预测,并利用预测结果与未来 7 d 气象预报数据进行结露风险预判。研究采用新疆塔城地区 8 个粮仓的实测数据进行了模型训练和验证,获得了精确的粮温预测模型。在测试集上进行了模型性能对比实验,结果显示,3DCNN-TFT 模型在粮堆温度场预测中的平均绝对误差(MAE)为 0.16℃,均方根误差(RMSE)为 0.18℃,显著优于其他预测模型。最后通过实仓实验验证了模型泛化能力,实验结果显示,3DCNN-TFT 模型具有较高的预测精度,平均 MAE 为 0.16℃,RMSE 为 0.19℃。同时,模型成功预测了结露风险并提前发出预警。本文方法显著提高了粮堆温度场预测精度,准确预测了结露风险,为储粮粮情监管与预测系统开发提供了有力支持。

关键词: 储粮; 结露风险; 温度场预测; 3D 卷积神经网络; 时间融合变换器

中图分类号: S24　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)07-0549-09　　**OSID**:

Grain Storage Condensation Risk Prediction Method Based on 3DCNN Combined with TFT

LI Xinze[1]　QIAO Xinghan[2]　WANG Wenyue[3]　WUYUN Shandan[1]　WU Wenfu[1]　GUO Hongpeng[1]　LU Yanhui[2]

(1. *College of Agricultural and Biological Engineering*, *Jilin University*, *Changchun* 130022, *China*
2. *College of Automotive Engineering*, *Jilin University*, *Changchun* 130022, *China*
3. *Xinjiang Uygur Autonomous Region Grain and Oil Science Research Institute*, *Urumqi* 830000, *China*)

Abstract: Aiming to address the issue that current grain storage condensation risk prediction mainly relies on simple grain temperature monitoring and empirical judgment, lacking accurate predictive tools, a grain storage condensation risk prediction method was proposed combining a three-dimensional convolutional neural network (3DCNN) and a temporal fusion transformer (TFT). The method utilized 3DCNN to extract spatial features of the internal temperature field of the grain heap and employed TFT to handle time series data. Based on historical meteorological data and future weather forecast data, it achieved high-precision prediction of the grain heap temperature field and used the prediction results along with the weather forecast data for the next seven days to assess condensation risk. The measured data from eight granaries in the Tacheng area of Xinjiang was used for model training and validation, achieving an accurate grain temperature prediction model. The comparative experiment on the test set showed that the 3DCNN-TFT model had a mean absolute error (MAE) of 0.16℃ and a root mean square error (RMSE) of 0.18℃ in grain temperature field prediction, significantly outperforming other predictive models. Finally, the real granary experiment validated the model's generalization ability, with results showing that the 3DCNN-TFT model had high predictive accuracy, with an average MAE of 0.16℃ and average RMSE of 0.19℃. The model also successfully predicted condensation risk and issued early warnings. The results indicated that the proposed method significantly improved the prediction accuracy of the grain heap temperature field, accurately predicted condensation risk, and provided strong support for the development of grain storage monitoring and prediction systems.

Key words: grain storage; condensation risk; temperature field prediction; 3D convolutional neural network; temporal fusion transformer

收稿日期: 2024-09-28　修回日期: 2024-10-21

基金项目: 新疆维吾尔自治区重点研发计划项目(2023B02043)

作者简介: 李欣泽(1997—),男,博士生,主要从事粮食信息化研究,E-mail: xzli23@mails.jlu.edu.cn

通信作者: 卢延辉(1974—),男,副教授,主要从事粮食储藏与运输研究,E-mail: luyh@jlu.edu.cn

0 引言

粮食安全是国家经济发展、社会稳定的基石。作为基本生活资料,粮食不仅直接关系到人民的温饱问题,更是国家社会经济体系中的重要组成部分[1-2]。随着全球人口的不断增长和气候变化的加剧,粮食安全面临的挑战愈发严峻。在这一背景下,粮食仓储安全在保障粮食安全中扮演着至关重要的角色[3]。粮食储藏安全直接影响到粮食的品质和数量,从而影响粮食市场的稳定性和供应的持续性。在粮食储存过程中,由于监管技术不完善,特别是储藏温度条件不理想的情况下,可能出现虫害、发热、霉变、结露等问题,从而引发粮食品质下降甚至大量损失[4-6]。因此,加强对粮食仓储期间储粮状态的监管,确保储粮安全,是保障国家粮食安全战略的重要组成部分。

在粮食仓储过程中,结露问题尤为突出。结露会导致粮食表面湿润,为霉菌生长创造条件,不仅影响粮食品质,还可能引发严重的粮食安全问题。因此,预防和应对储粮过程中可能出现的结露风险,成为了储粮监管的一个重要课题。研究表明,粮堆内部的温度梯度是导致结露的重要原因之一,因此,储粮温度是判断粮堆结露风险的重要指标。目前,我国大部分粮仓通过布置温度传感器,实现了储粮温度的实时检测[7-8]。然而,实时的粮温数据只能反映当前粮食的储藏状态,对于结露风险的提前预警,目前多数粮仓仍主要依赖人工经验。因此,提出一种精准的储粮结露风险预测方法显得尤为重要。

目前,全国大部分粮仓只能实现准确监测粮温,缺乏系统、可靠的粮堆内湿度和水分实时监测手段[9]。在这种情况下,通过温度场预测实现对粮堆内结露风险预测是一种可行的路径。近年来,国内外学者在粮堆温度场预测方面开展了大量研究[10-12]。这些研究中,粮温的时间相关性已经得到了验证,但仍存在问题。目前多数粮仓温度场预测主要考虑了粮温在时间序列上的依赖性,而忽略了粮堆内不同位置点粮温之间的空间依赖性。粮仓外部气象条件的变化对于粮堆内温度场的影响显著,但多数现有的粮温预测方法未将此因素纳入考虑。

针对上述问题,本文提出一种结合 3D 卷积神经网络(3D convolutional neural network, 3DCNN)和时间融合变换器(Temporal fusion transformer, TFT)的粮堆温度场预测模型,基于温度场预测结果和已知未来气象预报数据预判结露风险。该模型在预测过程中同时考虑粮温的时间和空间依赖性,并将粮仓外部的历史气象数据作为历史动态数据输入。此外,中国国家气象局发布的粮仓所在地未来 7 d 的气象预报数据也作为已知未来数据一起输入模型,以提高预测精度。

1 材料与方法

1.1 数据来源

本文使用的粮情数据来源于新疆维吾尔自治区塔城市某粮库共计 8 个平房仓,储粮品种均为小麦。选择塔城地区粮库作为数据集来源,主要是因为该地区全年气温波动大,2023 年全年最高温度 38℃,最低温度 -26℃。夏季期间该地区持续高温会导致粮堆内积累大量的热量形成热芯,在秋冬季节气温骤降时在粮堆中形成明显的温度梯度,具有典型的结露风险。该粮库所有粮仓中均已安装三维矩阵式布置的温度传感器用于记录粮温数据,其布置方案示例如图 1 所示。粮仓内传感器按照 X、Y、Z 3 个平面进行布置。传感器序号从(1,1,1)开始,图 1 中最靠近坐标轴原点的传感器标记为(1,1,1)。每个粮仓东北方向底角视为坐标原点,每个粮仓内位于东北方向底部的第 1 个传感器位置编码为(1,1,1),传感器位置编码沿 x、y、z 轴方向依次增加。同时粮仓外安装了温湿度传感器用以记录气象数据。在 2023 年 1 月至 2024 年 1 月期间进行持续的粮情监测并收集数据。

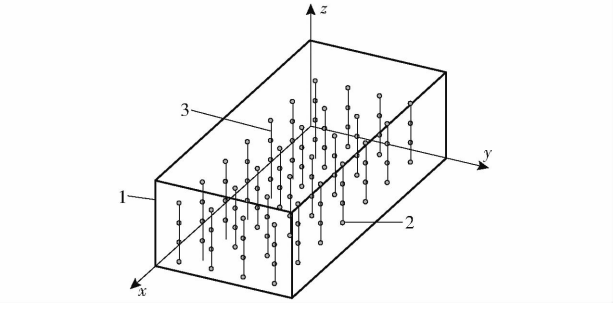

图 1 粮仓内传感器布置示例

Fig. 1 Example of sensor layout in granary

1. 粮仓 2. 温度传感器 3. 电缆

1.2 数据预处理

在粮情数据收集过程中,会出现如传感器损坏、数据上传缺失、数据报错等问题,需要对数据进行预处理。数据集中各粮仓连续检测的每日数据中存在一定的缺失和数据错误,所以需要剔除异常数据值。完成数据清洗后,为保持数据完整性,采用均值插值的方法用周围邻居数据的均值填补缺失值。为进行时间序列分析,需要将动态数据对齐到每一个时间步长,时间步长设置为 1 d。数据预处理后,数据集具体数据情况如表 1 所示。

表 1　数据集具体数据情况

Tab.1　Data set specific data situation

变量名称	变量类型	采样频率
储粮温度	动态历史变量	1/d
储粮入仓含水率	静态变量	/
仓外气象温度	动态历史变量	1/d
仓外气象湿度	动态历史变量	1/d
仓内传感器布置方案	静态变量	/
未来气象预报数据	已知未来变量	1/d

1.3　基于 3DCNN 融合 TFT 的储粮结露风险预测方法

本文提出的粮仓储粮结露风险预测方法主要分为 4 个步骤：基于 3DCNN 模块的三维数据空间特征提取、基于 TFT 模块的多变量输入粮仓温度场预测、粮仓温度场云图绘制和结露风险预判。算法具体流程如图 2 所示。其中，3DCNN 模块用于捕捉不同位置点粮温之间的空间依赖关系，并将其输出作为输入变量输入至 TFT 模块中。TFT 模块处理多类型输入变量捕捉时间依赖关系生成粮仓温度场预测结果，TFT 模块输出的粮温预测结果经过输出层映射回原始温度数据空间，产生最终的预测结果并使用插值算法生成预测的粮仓温度场云图，最后结合

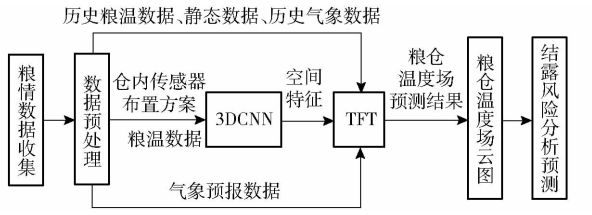

图 2　算法流程图

Fig. 2　Algorithm flowchart

未来气象预报数据和温度场云图分析判定是否出现结露风险。

1.3.1　基于 3DCNN 模块的三维数据空间特征提取

3D 卷积神经网络是一种扩展了传统二维卷积神经网络的模型，专门用于处理三维数据[13]。它通过在三维空间上滑动卷积核，提取输入数据的局部空间特征。3DCNN 能够有效捕捉空间维度上的复杂模式，在分析具有三维结构的时间序列数据时具有显著优势。在粮仓温度场预测任务中，3DCNN 模块通过逐层卷积和池化操作，捕捉空间特征，为后续的时间序列预测模型提供丰富的输入特征。本文算法中的 3DCNN 模块主要有 5 部分：输入层、卷积层、池化层、Flatten 层、全连接层，其结构如图 3 所示。

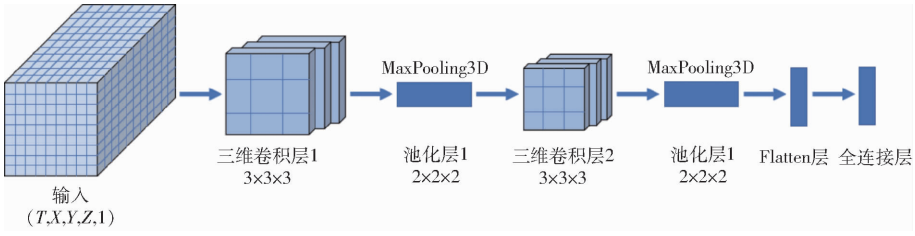

图 3　3DCNN 模块结构

Fig. 3　3DCNN module structure

其中输入层主要负责接收预处理后粮仓内不同位置点的粮温数据，组织成一个四维张量，形状为 $(T,X,Y,Z,1)$。其中 T 表示时间步数；(X,Y,Z) 为传感器位置点坐标；1 表示单一通道，即粮温。由于粮温在空间上是三维的，使用 3D 卷积作为卷积函数能够同时捕捉长、宽、高 3 个维度上的空间特征。3D 卷积操作通过一个三维卷积核在输入数据的 3 个空间维度 (X,Y,Z) 上滑动，提取局部区域内的特征。卷积核边长为 K 时，每个卷积核尺寸为 (KX,KY,KZ)，并且该卷积核在整个三维空间中滑动，逐步覆盖每个可能的局部区域。卷积操作中对于输入张量 $\boldsymbol{I}$ 和卷积核 W，输出特征图 O 中位置 (i,j,k) 处的值，计算公式为

$$O(i,j,k) = \sum_{m=0}^{KX-1}\sum_{n=0}^{KY-1}\sum_{p=0}^{KZ-1} W(m,n,p)\boldsymbol{I}(i+m,j+m,k+p) + b \tag{1}$$

式中　$W(m,n,p)$——卷积核中位置 (m,n,p) 处权重

$\boldsymbol{I}(i+m,j+n,k+p)$——输入张量中与卷积核对应的元素值

b——偏置项，用于调整卷积操作的输出

选取 ReLU 作为激活函数，增加网络非线性，帮助模型学习更复杂的特征。ReLU 函数在每个卷积层的输出上应用，它将所有负值置为 0，正值保持不变，其计算式为

$$\mathrm{ReLU}(x) = \max(0,x) \tag{2}$$

池化层的作用是对卷积层输出进行降采样，减少数据空间维度，从而降低计算复杂度，同时保留主要的空间特征。池化方式选择最大池化（Max - Pooling），即在每个局部立方块内取最大值。最大池化可以在降低特征图尺寸的同时保留最显著的特征，减少过拟合风险。Flatten 层将池化层的三维输出特征图展平为一维向量，展平的特征输入到全连

接层,进行最终的特征融合与输出,最后将其输入到 TFT 中。

1.3.2 基于 TFT 模块的多变量输入粮仓温度场预测

TFT 是一种为多模态输入和多步时间序列预测设计的深度学习模型[14-15],其结构如图 4 所示。TFT 模块用于结合 3DCNN 提取的空间特征、历史粮温数据、历史气象数据、静态数据以及已知未来气象预报数据,从而进行更加准确的粮仓温度场预测。TFT 的架构可以分为以下几个关键部分,每个部分在处理不同类型的输入数据时都发挥着重要作用:

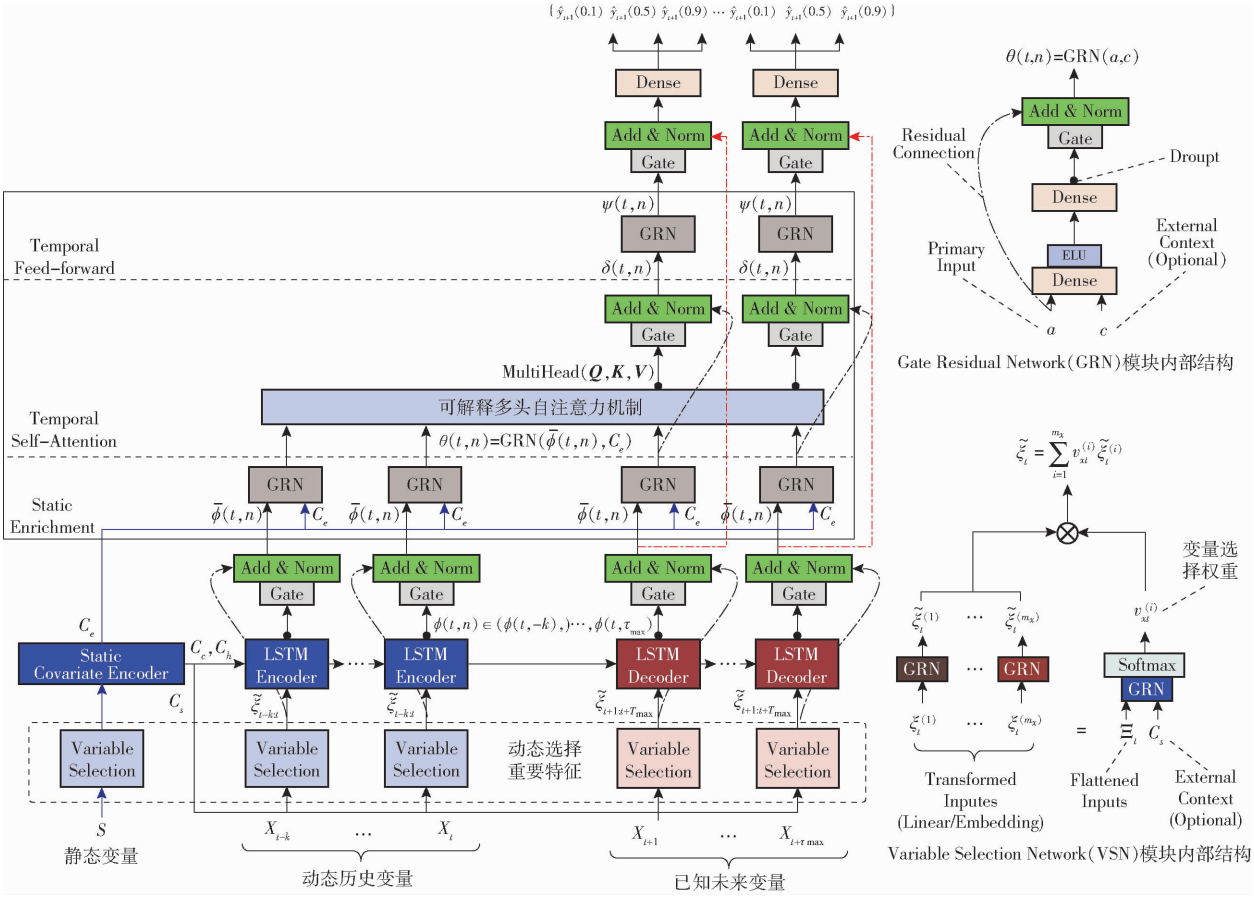

图 4 TFT 模块结构框图

Fig. 4 TFT module structure diagram

(1)多模态输入:将现有输入变量进行类别划分,其中将历史粮温数据、历史气象数据、3DCNN 提取的空间特征划分为历史动态变量;将未来气象预报温湿度数据划分为已知未来变量;将储粮入仓水分数据视为静态变量。完成变量类别划分后将其输入 TFT 模块中。

(2)多头自注意力机制:用于捕捉序列数据的时间依赖关系,以及各时间步之间的相互影响。它能够有效地关注长短期的时间依赖性,并且能够动态调整模型的注意力焦点。在粮仓温度场预测算法中,这一机制将帮助捕捉历史粮温、历史和未来气象数据之间的复杂关系,提升预测的准确性。多头自注意力机制中,所有输入特征首先经过嵌入层,将高维稀疏数据转换为低维稠密向量。接着将嵌入后的特征分割成多个小部分。每个部分由一个独立的注意力头处理,这样可以让模型在不同的子空间中学习数据的不同方面。在多头自注意力中,每个头计算可以表述为

$$\boldsymbol{Q}_i = \mathrm{split}(\boldsymbol{Q}) \tag{3}$$

$$\boldsymbol{K}_i = \mathrm{split}(\boldsymbol{K}) \tag{4}$$

$$\boldsymbol{V}_i = \mathrm{split}(\boldsymbol{V}) \tag{5}$$

$$h_i = \mathrm{Attention}(\boldsymbol{Q}_i, \boldsymbol{K}_i, \boldsymbol{V}_i) = \mathrm{softmax}\left(\frac{\boldsymbol{Q}_i \boldsymbol{K}_i^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V}_i \tag{6}$$

式中 $\boldsymbol{Q}$——查询(Query)矩阵

$\boldsymbol{K}$——键(Key)矩阵

$\boldsymbol{V}$——值(Value)矩阵

h_i——第 i 个注意力头的输出

d_k——键的维度,用于缩放点积,防止内部数值过大

split( )——把矩阵在最后一维按等份切分成子矩阵

Attention( )——缩放点积注意力操作

在所有的注意力头计算完自注意力之后,模型

将各个头的输出合并在一起，然后通过一个线性层 $\boldsymbol{W}^O$ 来融合信息

$$\text{MultiHead}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \text{Concat}(h_1,\cdots,h_h)\boldsymbol{W}^O \quad (7)$$

式中　Concat( )——拼接所有注意力头的输出沿着特定的维度

MultiHead( )——多头注意力的最终输出

$\boldsymbol{W}^O$——可学习的权重矩阵，用于综合多个注意力头的信息

(3)门控残差网络(Gated residual network，GRN)：在粮温预测模型中，针对多变量输入且数据存在非线性和多变量依赖的情况，GRN 的使用增强了模型处理复杂时间序列数据的能力。GRN 通过结合残差连接和门控机制，旨在改善信息流动，并增加模型对输入特征的自适应性。对于每个时间步，输入数据 a 和相关的外部上下文 c 被送入 GRN。将其进行线性组合，计算中间变量 η_1、η_2。计算式为

$$\eta_1 = \text{ELU}(W_{1,w}a + W_{2,w}c + b_{1,w}) \quad (8)$$

式中　ELU( )——指数线性单元激活函数，有助于处理激活值为负时的非线性行为

$$\eta_2 = W_{3,w}\eta_1 + b_{2,w} \quad (9)$$

最终输出通过 LayerNorm 层和残差连接得到

$$\text{GRN}_w(a,c) = \text{LayerNorm}(a + \text{GLU}_w(\eta_2)) \quad (10)$$

应用 GLU 来进一步处理，为模型提供门控机

$$\text{GLU}_w(\gamma) = \sigma(W_{4,w}\gamma + b_{4,w}) \odot (W_{5,w}\gamma + b_{5,w})$$
$$(\boldsymbol{W}(\cdot) \in R^{d_{\text{model}} \times d_{\text{model}}}, \boldsymbol{b}(\cdot) \in R^{d_{\text{model}}}) \quad (11)$$

其中　$\boldsymbol{W}(\cdot) = (W_{1,w}, W_{2,w}, W_{3,w}, W_{4,w}, W_{5,w})$

$\boldsymbol{b}(\cdot) = (b_{1,w}, b_{2,w}, b_{3,w}, b_{4,w}, b_{5,w})$

式中　$\boldsymbol{W}(\cdot)$——权重　　$\boldsymbol{b}(\cdot)$——偏差

γ——输入

$R^{d_{\text{model}}}$——d_{model} 维的实数向量空间

d_{model}——模型的隐藏维度

σ——激活函数，使用 Sigmoid 函数作为激活函数，用于将线性组合的结果压缩到(0,1)范围内，表示每个特征的重要性

$\odot$——元素乘法，用于应用门控信号到线性变换的结果上

GRN_w( )用于提取富含非线性的信息，通过门控和残差保证重要特征的保留与梯度的稳定传递；LayerNom( )为对所有特征维度做归一化；GLU_w( )用于简单高效地对特征进行门控。

(4)变量选择网络(Variable selection network，VSN)：TFT 使用 VSN 对每一时间步的输入特征进行选择。VSN 自动选择与输出最相关的输入特征，从而优化性能并减少不必要的噪声。

(5)长短期记忆网络(Long short term memory，LSTM)编码器-解码器架构：处理输入时间序列，捕捉其中的时间依赖关系。TFT 使用 LSTM 编码器处理历史时间序列数据，将其转换为潜在的时间序列表示。编码器会结合历史动态数据，捕捉数据的时间依赖性。解码器使用过去的编码表示和未来已知的气象预报数据来生成未来的温度预测。该部分使得模型在结合未来气象数据后获得更精准的预测结果。

1.3.3　基于温度场云图的粮仓结露风险预测

在基于 3DCNN 融合 TFT 的粮仓温度场预测后生成了离散的粮温预测数据，通过对离散的粮温预测数据进行插值获得粮仓温度场云图[16]。基于粮仓多场耦合理论对粮仓温度场云图进行分析，获得最终结露风险的预测结果。粮仓内结露现象可以归结为 2 种情况。

(1)夏季气温较高时，若粮堆表层粮温低于空气露点温度，表层出现结露风险[17-18]。其中空气露点温度 T_{DPTa} 计算式为

$$T_{DPTa} = \frac{474\ 242}{\frac{474\ 242}{273 + t_a} - 89.1\ln H_{RHa} + 410.34} - 273 \quad (12)$$

式中　H_{RHa}——空气相对湿度，%

t_a——粮仓内空气温度，℃

当粮堆温度场预测结果显示表层粮温低于仓内空气露点温度时，即可判定为出现结露风险，并将粮堆表层视为高风险区域。

在粮仓结露风险预测时，通过对该仓历史粮仓内空气温度与仓外气象温度进行拟合，获得仓内空气温度与仓外气象温度之间的关系，线性回归模型为

$$t_a = kt_{ao} + e \quad (13)$$

式中　k——回归系数

t_{ao}——粮仓外气象温度，℃

e——截距

(2)季节交替时，粮仓外部环境的温度及太阳辐射发生显著变化。由于粮食颗粒的热扩散系数较小，并且其本身具备一定的热阻，导致粮堆内部温度调整速度通常滞后于外部环境温度变化。这一现象进一步扩大了内部温度梯度。秋末冬初这一时期，经过夏季持续高温，外界环境热量逐渐传导至粮堆内部，导致粮堆中心区域温度升高，而表层粮温则明显受到环境温度下降的影响，从而形成低温区。由此，粮堆出现了典型的结露风险状态，此时粮堆的垂直截面呈现出“冷皮热芯”的特征。根据粮堆多场

耦合理论,对储粮状态及其变化进行分析,温度梯度是造成微气流形成的主要因素。受微气流的影响,在竖直向上方向,热量传递速度最快,竖直向下方向最慢。热芯区域的粮食热量和水汽随微气流迁移至表层低温区域。其中,热量可以散失于外界低温环境,而大量水汽一旦遇到低温粮食便会发生冷凝,甚至导致水汽板结,滞留在表层低温粮食的表面。当仓内空气温度低于该低温区域粮食的露点温度时,可以判断存在结露风险,表层低温区域因而成为高危区域[19]。粮食露点温度[20]计算公式为

$$T_{DPTg}=\frac{474\,242}{1\,872.7-89.1\ln H_{EAHg}}-273 \tag{14}$$

$$H_{EAHg}=\exp\left(\frac{\left[\frac{D}{222}\left(e^{\frac{B_1-M}{A_1}}-e^{\frac{B_2-M}{A_2}}\right)+0.9845\right]\left(1\,737.1-\frac{474\,242}{273+t_g}\right)+D\left(1-e^{\frac{B_1-M}{A_1}}\right)-65.87}{87.72}\right) \tag{15}$$

式中 T_{DPTg}——粮食露点温度,℃

H_{EAHg}——粮食平衡绝对湿度,mmHg

M——粮食含水率,%

t_g——粮食温度,℃

A_1、A_2、B_1、B_2、D——CAE 方程参数[21],取 4.874、4.767、4.671、3.639、201.676

2 结果与讨论

2.1 模型训练与超参数调优

本次模型训练所使用的环境是 Ubuntu 22.04 LTS,CPU 为 AMD Ryzen9 7950X,使用 NVIDIA RTX 4090 进行加速。选择 Adam 优化对整个模型的参数进行更新,迭代次数设置为 100。为了避免过拟合,采用了早停机制。将数据集按照比例 7∶2∶1划分为训练集、验证集和测试集,采用滑动时间窗口的方法进行训练,目标预测周期为 7 d。为了评估该模型对粮堆温度场的预测性能,选取 MAE、RMSE 作为模型的评估系数[22]。模型超参数调优采用网格搜索算法[23],对超参数进行细致筛选,确保对最优参数进行细致的探索。具体参数候选组合及模型最终参数设置如表 2 所示。

表 2 模型超参数及其候选组合

Tab.2 Hyperparameters and their candidate combinations

参数	候选组合	最终参数设置
隐藏层维度	64, 128, 256	128
LSTM 单元数量	64, 128	128
注意力头数	4,6,8	6
Dropout 率	0.2, 0.3	0.2
时间窗口大小	7, 14, 21	14
学习率	0.001,0.000 1	0.001
批量大小	32, 64	64

2.2 粮仓温度场预测性能对比实验

选用 Transformer[24]、TFT、RNN(recurrent neural network)[25]、LSTM[26] 4 种模型与本文提出的 3DCNN-TFT 粮仓温度场预测模型进行对比,通过对上述其他模型的改进实现同时输出多点粮温预测结果,使用相同的数据集进行训练,经过训练和超参数调优后计算各模型在测试集上的评估系数,计算结果如表 3 所示。

表 3 5 种模型评价指标对比

Tab.3 Comparison of five model evaluation indexes

℃

模型	MAE	RMSE
3DCNN-TFT	0.16	0.18
Transformer	0.24	0.28
TFT	0.21	0.23
RNN	0.29	0.33
LSTM	0.24	0.27

由表 3 可以看出,3DCNN-TFT 在测试集上预测精度良好,MAE 为 0.16℃,相比其他 4 种模型分别降低 33.33%、23.81%、44.83%、33.33%。RMSE 为 0.18℃,相比其他 4 种模型分别降低 35.71%、21.74%、45.45%、33.33%。本文提出的 3DCNN-TFT 模型能够精准地对粮堆温度场进行预测,预测精度优于其他方法。通过将 3DCNN-TFT 与 TFT 模型进行对比,验证了 3DCNN 模块有效提升了模型预测精度。

为对比 3DCNN-TFT 与其他 4 种模型对粮仓内不同位置点粮温预测性能,在测试集中,随机选取 2 个粮仓,并在每个粮仓每层传感器中随机选取 1 个位置点,对比各模型对各位置点粮温预测性能并计算评估系数。2 个粮仓中所有模型在 28 d 预测周期内对各点粮温预测值及真实值如图 5 所示。图 6 为各模型在粮仓中各点粮温预测值评估系数计算结果。从图 6 可以看出,位于粮堆表层 6 号仓(2,6,1)和8 号仓(2,7,1)2 个位置点的粮温预测中,3DCNN-TFT 模型预测精度最优。表层粮温受到气象变化的影响最为显著,因此在输入历史气象数据和已知未来气象预报数据情况下,3DCNN-TFT 模型在表层粮温预测方面精度显著高于其他 4 种模型。

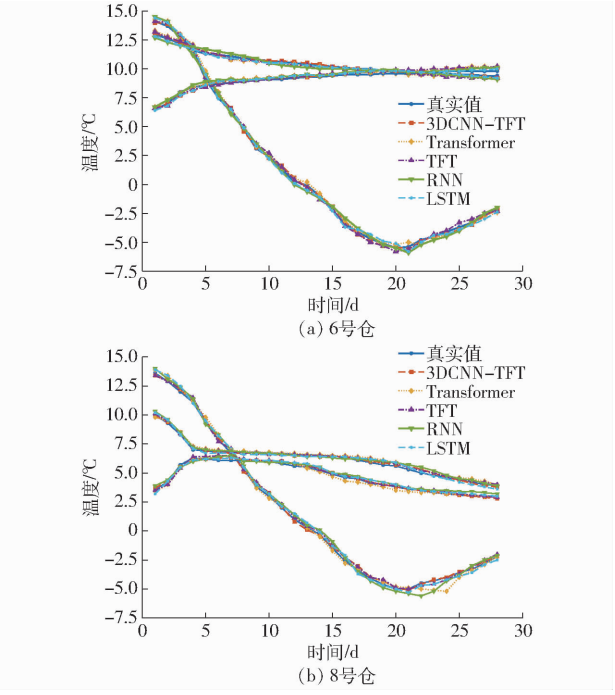

图 5　预测周期内各点粮温预测值及真实值

Fig. 5　Predicted and true values of grain temperature at each point in forecast period

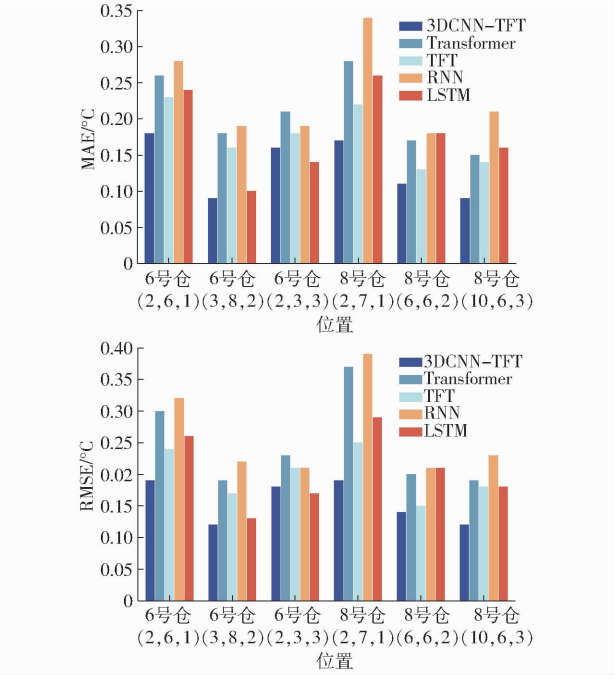

图 6　粮仓内不同位置点粮温预测评估系数

Fig. 6　Prediction and evaluation coefficient of grain temperature at different positions in granary

2.3　测试集中粮仓结露风险分析

测试集中出现的典型结露风险粮仓温度场云图如图 7 所示。图 7a 为塔城 5 号仓 2023 年 12 月 10 日 y 方向第 3 截面的粮仓温度场预测云图。图中可以看到粮堆表层存在均温约为 −2.7℃的低温区域，粮堆内部存在明显的热芯，热芯均温约为 11.9℃，热芯与表层低温区域存在明显的温度梯度。当日仓内空气温度为 −8.7℃，粮堆表层低温区域粮食露点温度为 −8.45℃，仓内空气温度低于其露点温度，出现结露风险。图 7b 为塔城 4 号仓 2023 年 12 月 11 日 y 方向第 3 截面粮仓温度场预测云图。图中粮堆表层存在均温约为 −2.5℃的低温区域，粮堆内部存在明显的热芯，热芯区域均温约为 10.3℃，热芯与表层低温区域存在明显的温度梯度。当日仓内空气温度为 −8.6℃，粮堆表层低温区域粮食露点温度为 −8.25℃，空气温度低于露点温度，出现结露风险。

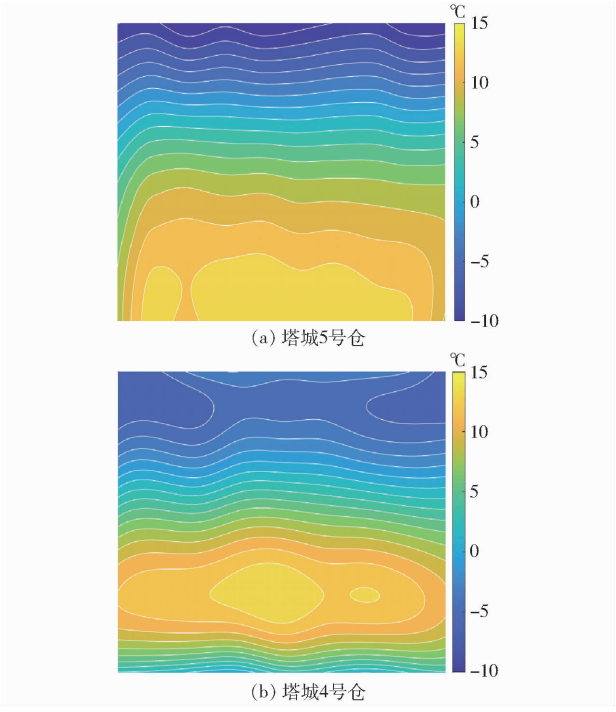

图 7　测试集中典型结露风险粮仓温度场云图

Fig. 7　Cloud maps of temperature field of typical condensation risk granary

2.4　实仓验证实验

为检测模型泛化能力，实仓验证实验选取未包含在数据集中的塔城 11 号仓。收集该仓 2023 年 11 月 17 日至 2024 年 1 月 18 日期间的历史粮情数据和气象数据，该时期为新疆塔城地区结露风险高发时期。实验过程中，每次输入该粮仓 14 d 的历史粮情数据，同时输入塔城地区未来 7 d 的气象预报数据，每次粮温预测周期为 7 d。进行下一段预测任务时将上一个预测周期的真实粮温加入到历史粮情数据中，用于预测未来粮温。实仓验证实验中共进行了 7 次粮仓温度场预测任务，计算 49 d 期间每次使用 3DCNN − TFT 模型对该粮仓进行温度场预测的评估系数，计算结果如表 4 所示。3DCNN − TFT 温度场预测结果呈现了较高的精度，平均 MAE 为 0.16℃，RMSE 为 0.19℃。

在第2次预测任务中，算法发出了结露风险预

表 4 实仓验证实验各预测周期评估系数

Tab. 4 Evaluation coefficient of each prediction cycle in real chamber verification experiment ℃

预测周期	MAE	RMSE
1	0.15	0.19
2	0.20	0.24
3	0.14	0.16
4	0.12	0.15
5	0.19	0.20
6	0.17	0.20
7	0.16	0.19

警。通过查询该时期的气象数据发现,塔城地区在 12 月 12 日至 14 日期间气温骤降,日平均气温从 -7℃迅速降至 -23℃。由于外部气温的快速下降,导致粮堆表层粮温也出现了骤降。而粮堆内部的温度通常相对滞后于外部环境的变化,因此在垂直方向上形成了明显的温度梯度:粮堆表层区域为低温,粮堆内部出现高温热芯。图 8 为该粮仓 12 月 13 日 y 方向第 3 截面的温度场云图,该图是根据模型预测的粮温数据绘制的。从图 8 可以看出,粮堆内部中心区域形成了一个均温为 13.1℃的热芯,而表层的低温区域粮温均值为 -2.3℃,两者之间形成了高达 15.4℃的温度梯度。这种温度梯度导致了热芯区域粮食水汽通过微气流迁移至表层低温区域,并在接触低温粮食时冷凝,产生结露风险。此时仓内空气温度为 -15.9℃,表层低温区域粮食露点温度为 -8.1℃,空气温度低于表层低温区域粮食的露点温度,出现结露风险。经实地调查分析发现,塔城地区部分粮库发生结露的风险较高。主要原因是部分粮仓年份较长,仓房围护结构基础条件较差,保温隔热性能及气密性不足,导致表层粮温受外部气象条件影响明显,加之近年来该地区气温波动较大,因此容易出现结露风险。因此在塔城地区及气候相近区域,对于基础条件较差的粮仓,后期储藏时在秋冬季节应特别关注粮堆内各位置点的粮温变化。当出现结露风险预警时,应及时采取通风

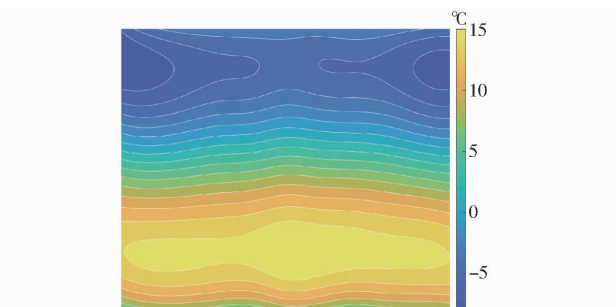

图 8 11 号仓 12 月 4 日 y 方向第 3 截面温度场预测云图

Fig. 8 Forecast cloud image of temperature field at Section 3 in y direction on December 4, Granary 11

措施以防止结露,确保储粮安全。

3 结论

(1)针对粮仓结露风险预测中存在的不足,如缺乏对粮堆内不同位置粮温空间依赖性的考虑及外部气象因素对粮仓温度场的影响,提出了一种基于 3DCNN 融合 TFT 的储粮结露风险预测方法。该方法通过融合 3DCNN 和 TFT 模块,能够同时捕捉粮仓温度场的时间依赖性和空间依赖性,从而构建了精准的粮仓温度场预测模型。同时,模型输入了历史气象数据和未来 7 d 的气象预报数据,以探索外部气象条件对粮仓温度场的影响,从而提升了预测精度。

(2)最后使用粮温预测结果绘制粮仓温度场云图并进行结露风险预测。模型对比实验结果表明,3DCNN - TFT 评估系数 MAE 为 0.16℃,RMSE 为 0.18℃,相较于其他模型具有更高的预测准确性,能够有效地预测粮仓温度场和结露风险。

(3)为验证模型泛化能力,进行了实仓验证实验,选择未包含在数据集中的粮仓,进行了 7 次连续的粮仓温度场预测。实验结果显示,该方法能够准确预测粮温和结露风险,7 次预测任务平均 MAE 为 0.16℃,RMSE 为 0.19℃,进一步证明了模型的有效性和可靠性。

参 考 文 献

[1] 张红涛,胡玉霞,毛罕平,等. 基于计算机视觉的储粮活虫检测系统软件设计[J]. 农业机械学报,2012,43(8):180 - 186.
ZHANG Hongtao, HU Yuxia, MAO Hanping, et al. Software design of detection system for stored-grain live insects based on computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012,43(8):180 - 186. (in Chinese)

[2] NGUYEN M H, HUU L H, BABEL M S, et al. Nature-based solutions for improving food security: a systematic global review [J]. Heliyon, 2024, 10(16): e36082.

[3] 梁琨,沈明霞,路顺涛,等. 基于平衡水分模型的稻谷含水率实时监测系统[J]. 农业机械学报,2013,44(1):125 - 130.
LIANG Kun, SHEN Mingxia, LU Shuntao, et al. Real-time monitoring system for grain moisture content based on equilibrium moisture model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013,44(1):125 - 130. (in Chinese)

[4] 施灿璨,周福君,夏吉庆,等. 自然冷资源低温储藏仓设计与稻谷储藏试验[J]. 农业机械学报, 2017,48(11):375 - 382.
SHI Cancan, ZHOU Fujun, XIA Jiqing, et al. Design of cool storage warehouse with natural cold resource and paddy storage experiment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017,48(11):375 - 382. (in Chinese)

[5] 陈坤杰,梁静,蒋维银,等. 储藏温度与初始含水率对稻谷和糙米食用品质的影响[J]. 农业机械学报,2022,53(9):390 - 398.
CHEN Kunjie, LIANG Jing, JIANG Weiyin, et al. Effect of storage temperature and initial moisture content on eating quality of rice and brown rice[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(9):390 - 398. (in Chinese)

[6] 韩少云,董晓光,熊黎剑,等. 基于 GC－MS 和电子鼻的面粉中粮虫快速检测方法[J]. 农业机械学报,2023,54(增刊 1):358－365.
HAN Shaoyun, DONG Xiaoguang, XIONG Lijian, et al. Rapid detection of stored grain pests in flour based on GC－MS and E-nose[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 358－365. (in Chinese)

[7] 连丰沛. 粮情监控系统开发及储粮温度预测算法研究[D]. 天津:天津工业大学,2019.
LIAN Fengpei. Grain monitoring system development and storage temperature prediction algorithm research[D]. Tianjin: Tiangong University, 2019. (in Chinese)

[8] 王磊. 基于无线传感网络的粮仓粮情监测系统设计研究[D]. 郑州:河南工业大学,2024.
WANG Lei. Research on the design of grain condition monitoring system of grain silo based on wireless sensor network[D]. Zhengzhou: Henan University of Technology, 2024. (in Chinese)

[9] 崔宏伟,吴文福,吴子丹,等. 基于粮温时空相关性的储粮数量监管方法研究[J]. 农业机械学报, 2019, 50(1):321－330.
CUI Hongwei, WU Wenfu, WU Zidan, et al. Reserves monitoring method for grain storage based on temporal and spatial correlation of grain temperature[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 321－330. (in Chinese)

[10] LI Zhihui, SI Yiyi, ZHU Yuhua. Research on grain-stored temperature prediction model based on improved SVR algorithm[J]. Journal of Computational Methods in Sciences and Engineering, 2023, 23(3): 1547－1559.

[11] QU Zhongke, ZHANG Yang, HONG Chao, et al. Temperature forecasting of grain in storage: a multi-output and spatiotemporal approach based on deep learning[J]. Computers and Electronics in Agriculture, 2023, 208: 107785.

[12] 尹君,吴子丹,张忠杰,等. 基于多场耦合理论浅析浅圆仓局部结露机理[J]. 中国粮油学报,2015,30(5):90－95.
YIN Jun, WU Zidan, ZHANG Zhongjie, et al. Analysis of the formation mechanism of partial condensation for the stored grain in steel squat silo based on multi-fields coupling theory[J]. Journal of the Chinese Cereals and Oils Association, 2015, 30(5): 90－95. (in Chinese)

[13] LUO Shaoyang, WEI Buowen, CHEN Liangjie. Multi-point deformation monitoring model of concrete arch dam based on MVMD and 3D－CNN[J]. Applied Mathematical Modelling, 2024, 125(PB): 812－826.

[14] BRYAN L, SERCAN Ö A, NICOLAS L, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. Int. J. Forecast, 2021, 37: 1748－1764.

[15] HE Kaijian, ZHENG Linyuan, YANG Qian, et al. Crude oil price prediction using temporal fusion transformer model[J]. Procedia Computer Science, 2023, 221: 927－932.

[16] 崔宏伟,吴文福,吴子丹,等. 基于温度场云图的储粮数量监控方法研究[J]. 农业工程学报,2019,35(4):290－298.
CUI Hongwei, WU Wenfu, WU Zidan, et al. Monitoring method of stored grain quantity based on temperature field cloud maps[J]. Transactions of the CSAE, 2019, 35(4): 290－298. (in Chinese)

[17] 张艺良. 成品粮仓储结露与结露预防过程的数值模拟研究[D]. 北京:北京邮电大学,2016.
ZHANG Yiliang. Numerical simulation study of condensation and condensation prevention process in finished grain storage[D]. Beijing: Beijing University of Posts and Telecommunications, 2016. (in Chinese)

[18] 王水寒,李瑞敏,张洪清,等. 基于温湿度场云图的稻谷粮堆状态和结露风险分析[J]. 粮油食品科技,2021,29(4):219－225.
WANG Shuihan, LI Ruimin, ZHANG Hongqing, et al. Analysis of storage state and condensation risk of paddy pile based on temperature and humidity field cloud map[J]. Science and Technology of Cereals, Oils and Foods, 2021, 29(4): 219－225. (in Chinese)

[19] 尹君. 小麦粮堆多场耦合模型及结露预测研究[D]. 长春:吉林大学,2015.
YIN Jun. Multi-field coupled modelling and prediction of condensation in wheat grain stacks[D]. Changchun: Jilin University, 2015. (in Chinese)

[20] 李兴军,吴子丹. 粮堆平衡绝对湿度和露点温度的查定方法[J]. 粮食加工,2011,36(4):34－37.
LI Xingjun, WU Zidan. Methods of checking the equilibrium absolute humidity and dew point temperature of grain stacks[J]. Grain Processing, 2011, 36(4): 34－37. (in Chinese)

[21] 尹君,吴子丹,张忠杰,等. 不同仓型的粮堆温度场重现及对比分析[J]. 农业工程学报,2015,31(1):281－287.
YIN Jun, WU Zidan, ZHANG Zhongjie, et al. Comparison and analysis of temperature field reappearance in stored grain of different warehouses[J]. Transactions of the CSAE, 2015, 31(1): 281－287. (in Chinese)

[22] TAO Shancheng, LI Bingchan, REN Chen, et al. Grain temperature prediction based on gated recurrent unit deep fusion mode[J]. Procedia Computer Science, 2022, 214: 763－770.

[23] 王鹏新,王颖,田惠仁,等. 基于 LightGBM 的冬小麦产量估测与可解释性研究[J]. 农业机械学报,2023,54(12):197－206.
WANG Pengxin, WANG Ying, TIAN Huiren, et al. Interpretability on yield estimation of winter wheat based on LightGBM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 197－206. (in Chinese)

[24] VASWANI A, SHAZZER N, PARMAR N, et al. Attention is all you need[J/OL]. arXiv, 2017. DOI: 10.48550/arXiv.1706.03762.

[25] 赫晓慧,罗浩田,乔梦佳,等. 基于 CNN－RNN 网络的中国冬小麦估产[J]. 农业工程学报,2021,37(17):124－132.
HE Xiaohui, LUO Haotian, QIAO Mengjia, et al. Yield estimation of winter wheat in China based on CNN－RNN network[J]. Transactions of the CSAE, 2021, 37(17): 124－132. (in Chinese)

[26] 李莉,李文军,马德新,等. 基于 LSTM 的温室番茄蒸腾量预测模型研究[J]. 农业机械学报,2021,52(10):369－376.
LI Li, LI Wenjun, MA Dexin, et al. Prediction model of transpiration of greenhouse tomato based on LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 369－376. (in Chinese)