doi:10.6041/j.issn.1000-1298.2026.12.036

基于 xLSTM－TA 的稻谷多段逆流干燥预测模型

李成杰　陈衍成　纪思涵　夏婉熙　李长友　张　烨
（华南农业大学工程学院，广州 510642）

摘要：稻谷多段逆流干燥工艺呈现长时序、多阶段多参数耦合以及工况突变等复杂特性，致使干燥状态的精准预测仍面临挑战，稻谷爆腰问题突出。本研究提出了一种基于时序注意力增强型扩展长短期记忆网络的稻谷多段逆流干燥预测模型（xLSTM－TA－PD），其通过交替集成扩展长短期记忆网络（Extended long short-term memory，xLSTM）残差块构建网络主干，以提取干燥时序信息，增强模型的历史参数信息记忆能力，以及在应对参数突变时做出准确响应的能力。同时，引入时序注意力（Temporal attention，TA）机制改进网络结构，解决了网络对干燥阶段权重均一化的问题。以 5HNH－15 型连续式稻谷干燥机为研究对象开展模型验证试验，发现 xLSTM－TA 模型均方根误差为 0.068%，决定系数为 0.988，预测性能优于深床干燥解析模型及其他数据驱动模型。在阶跃工况下，模型最大预测误差为 0.44%，仅 2.7% 的样本绝对误差超过 0.2%，证明模型能够准确识别参数阶跃变化与干燥状态响应间的滞后特性。此外，模型平均推理时间为 0.056 6 s，速度较深床干燥解析模型提升 7.7 倍，满足实时预测需求。通过时序注意力权重可视化分析发现，模型对不同时间步的权重分配与实际干燥机理高度一致，显著增强了模型的可解释性。本研究为粮食干燥的智能化调控提供了高精度、低延迟的决策支持工具。

关键词：稻谷；多段逆流干燥；状态预测；时序预测模型；智能化调控
中图分类号：S226.6；TP183　　**文献标识码**：A　　**文章编号**：1000-1298(2026)12-0384-12　　**OSID**：

Prediction Model for Paddy Multi-stage Counter-flow Drying Based on xLSTM－TA

LI Chengjie　CHEN Yancheng　JI Sihan　XIA Wanxi　LI Changyou　ZHANG Ye
(*College of Engineering*, *South China Agricultural University*, *Guangzhou* 510642, *China*)

Abstract: The multistage counter-flow drying process of paddy exhibits complex characteristics such as long-term temporal sequences, multi-stage and multi-parameter coupling, and sudden condition changes, which pose challenges for accurate prediction of drying states and exacerbate the issue of rice fissuring. A prediction model for multistage counter-flow of paddy was proposed based on a temporal attention-enhanced extended long short-term memory network (xLSTM－TA－PD). The model constructed its backbone by alternately integrating residual blocks of the extended long short-term memory (xLSTM) network, enabling effective extraction of temporal drying information, enhancing the model's ability to memorize historical parameter data, and improving its responsiveness to abrupt parameter changes. Furthermore, a temporal attention (TA) mechanism was incorporated to refine the network architecture, addressing the issue of uniform weighting across different drying stages. Validation experiments were conducted by using a 5HNH－15 continuous paddy dryer. The results showed that the xLSTM－TA model achieved a root mean square error of 0.068% and a coefficient of determination of 0.988, outperforming the deep-bed drying analytical model and other data-driven models. Under step-change conditions, the model's maximum prediction error was 0.44%, with only 2.7% of samples exhibiting an absolute error exceeding 0.2%, demonstrating its capability to accurately capture the lag characteristics between parameter step changes and drying state responses. Additionally, the model's average inference time was

收稿日期：2025－10－13　修回日期：2026－01－19
基金项目：国家重点研发计划项目（2024YFD2000104）、国家自然科学基金项目（32401725）、广东省基础与应用基础研究基金项目（2025A1515011276）和广州市科技计划项目（2024A0J3960）
作者简介：李成杰（1994—），男，副教授，博士，主要从事智能干燥装备系统理论与技术研究，E-mail：chengjie.li@scau.edu.cn
通信作者：张烨（1986—），男，副教授，主要从事农产品干燥装备技术研究，E-mail：zhangye@scau.edu.cn

only 0.056 6 s, representing a 7.7-fold speed improvement over traditional deep-bed drying analytical models, thus meeting the requirements for real-time prediction. Visualization analysis of temporal attention weights revealed that the model's weight distribution across different time steps aligned closely with the actual drying mechanism, significantly enhancing model interpretability. The research result can provide a high-precision, low-latency decision-support tool for intelligent control in grain drying processes.

Key words: paddy; multistage counter-flow drying; state prediction; temporal prediction model; intelligent control

0　引言

稻谷多段逆流干燥机具有作业效率高、处理量大的优点，在我国东北、黄淮海、西南稻谷产区得到了广泛推广。稻谷进入干燥机，自上而下历经多次流动干燥和缓苏调质交替，去水期间伴随介质状态变化、进机粮含水率波动、随机扰动等诸多不确定因素，致使完全依赖物理检测手段难以实时掌握含水率及其分布，从而无法有效控制干燥速率，导致稻谷多段逆流干燥爆腰问题十分突出[1-2]。

研究人员围绕稻谷深床干燥建立的机理模型主要有 4 类，即对数模型、平衡模型、基于薄层干燥速率方程的非平衡模型、基于自由液面蒸发理论的解析模型[3]。对数模型假设介质状态沿等焓线变化，忽略了稻谷升温和排气热损，仅适用于低温干燥过程解析，且精度十分有限[4]。平衡模型将稻谷与介质视为处于热、湿平衡状态的物系，这种假设在高温高流速介质干燥时不符合实际，应用范围有限[5]。基于薄层干燥速率方程的非平衡模型，其解析精度高度依赖于薄层干燥方程，且模型中诸多过程参数难以准确定量[6]。基于自由液面蒸发理论，建立了干燥蒸发、相界面水分传递、介质吸水三者的质平衡方程，并引入无量纲分析法，得到一种稻谷深床干燥稳态解析模型[7]，并通过物料与干燥介质间的湿含量势差耦合确定深层最大去水速率，拓展至变干燥条件、变物性参数下的稻谷瞬态干燥过程[8]，但模型中诸如有效传质系数、有效换热系数、过程比热、冷却系数等过程参数仍无法准确定量。

数据驱动预测方法为稻谷深床干燥建模提供了新途径[9]。较早研究多聚焦于误差反向传播算法，构建以介质条件为输入、物料参数变化为输出的干燥预测模型[10-11]，但此类静态结构网络难以记忆干燥的历史条件，无法准确捕捉前期干燥参数对后期干燥状态的影响，这与多段逆流干燥工艺的长时序特性不符。基于门控循环机制的稻谷深床干燥预测模型[12-13]，一定程度提升了时序处理能力，但其在面对多段逆流干燥的超长时序过程时，记忆效果仍会因信息增加而受限[14]，且其对不同干燥阶段赋予相同的权重，未能考虑各阶段对稻谷状态影响的实际差异[15]，与工艺多段特性不符。为解决上述问题，Transformer 架构通过自注意力机制实现了对干燥过程的全局感知，增强了对不同干燥阶段特征提取能力，有助于实现稻谷多段逆流干燥含水率预测[16]。然而，该架构缺陷是模型对参数突变的响应能力较弱[17]，在面对介质状态突变、进机粮含水率波动等工况时，模型预测含水率在时间上会落后于真实情况，导致预测出现滞后。

针对上述问题，本研究在课题组前期完成的粮食深床干燥解析理论基础上[18-20]，结合数据驱动建模方法，设计一种适用于稻谷多段逆流干燥工艺的预测模型，强化对干燥长时序历史数据的记忆能力，响应干燥参数突变，通过考虑各阶段对稻谷状态影响的实际差异优化干燥段权重分配，以期实现稻谷多段逆流干燥状态精准预测，为实现粮食深床干燥状态跟踪、参数匹配、智能决策提供参考。

1　xLSTM－TA 预测模型构建

1.1　扩展长短期记忆网络

针对稻谷逆流干燥工艺长时序、多参数耦合及工况多变等复杂系统特性，构建了基于扩展长短期记忆网络的稻谷状态预测模型，模型引入标量长短期记忆网络（Scalar long short-term memory，sLSTM）与矩阵长短期记忆网络（Matrix long short-term memory，mLSTM）2 种协同设计的变体，分别从门控机制与记忆结构 2 个维度对传统 LSTM 进行扩展[21]，有效提升了模型对干燥历史信息的记忆能力及对参数突变的响应速度。

为应对干燥过程大规模长时序数据的建模需求，引入了 mLSTM 模块。模块将传统 LSTM 的标量记忆单元扩展为矩阵形式，并采用协方差更新规则，显著提升了模型对历史干燥参数的记忆容量和交互关系的提取能力，能够更深刻地描述温度、相对湿度等多维参数共同作用下的干燥机理。此外，其矩阵化结构还支持并行计算，满足实时性要求。

为进一步提升模型对干燥过程瞬时工况突变

的动态响应与状态修订能力，引入 sLSTM 模块。模块核心在于指数门控机制，能够实现对历史记忆状态的快速覆盖与调整，有效避免模型在应对参数突变时响应滞后问题。同时，该模块融合归一化与稳定化技术，保障了长序列训练中梯度稳定与数值收敛。此外，其记忆混合机制能够同步追踪多变量间的耦合变化，增强了模型对复杂干燥时序的表达灵活性。

1.2 时序注意力模块

在多段逆流干燥过程中，稻谷状态变化受高低温干燥段及缓苏段等多环节影响，各阶段对最终含水率的贡献程度存在差异。传统神经网络模型往往对不同时间步赋予均等权重，难以有效区分不同干燥阶段的影响程度。为实现不同干燥时刻重要性的动态分配，本研究设计了时序注意力模块，通过与 xLSTM 网络协同作用，提升对稻谷状态的预测精度。时序注意力机制能有效聚焦时序数据中的关键信息，在时间序列预测任务中表现突出[22]，其核心在于构建了 T 个（时间步总数）参数共享的自注意力模块，通过多层隐藏层连接，专注于评估不同时间步的重要性。随后，通过激活函数进行非线性映射，以此对原始隐藏状态进行加权求和，最终生成蕴含时序注意力信息的深层状态表征。当稻谷处于不同干燥阶段时，模块会动态调整权重，以聚焦于对稻谷状态变化影响显著的关键时段，避免了传统模型对各干燥阶段均等赋权导致的细节丢失问题。时序注意力网络公式为

$$\boldsymbol{Y}_i = \sigma(\boldsymbol{W}_i \boldsymbol{H} + \boldsymbol{b}_i) \tag{1}$$

$$\boldsymbol{Y}_i = \boldsymbol{W}_i \boldsymbol{Y}_{i-1} + \boldsymbol{b}_i \tag{2}$$

$$\boldsymbol{\beta} = \boldsymbol{W}_{L+1} \boldsymbol{Y}_L + \boldsymbol{b}_{L+1} \tag{3}$$

$$\alpha = \mathrm{Softmax}(\boldsymbol{\beta}) \tag{4}$$

$$\boldsymbol{S} = \tanh\left(\sum_{t=1}^{T} \alpha_t \boldsymbol{H}_t \right) \tag{5}$$

式中 $\boldsymbol{H}$——注意力网络输入

$\boldsymbol{W}$——注意力网络权重矩阵

$\boldsymbol{b}$——网络偏置向量

$\boldsymbol{Y}$——神经元节点状态矩阵

σ——Sigmoid 激活函数

$\boldsymbol{\beta}$——重要程度向量

α——Softmax 激活转换后的权重

$\boldsymbol{S}$——输出的深层时间状态矩阵

1.3 时序注意力增强型扩展长短期记忆网络

提出的融合时序注意力机制的扩展长短期网络流程如图 1 所示，其中包含时间序列输入模块、扩展长短期记忆网络模块、时序注意力模块及预测输出模块。

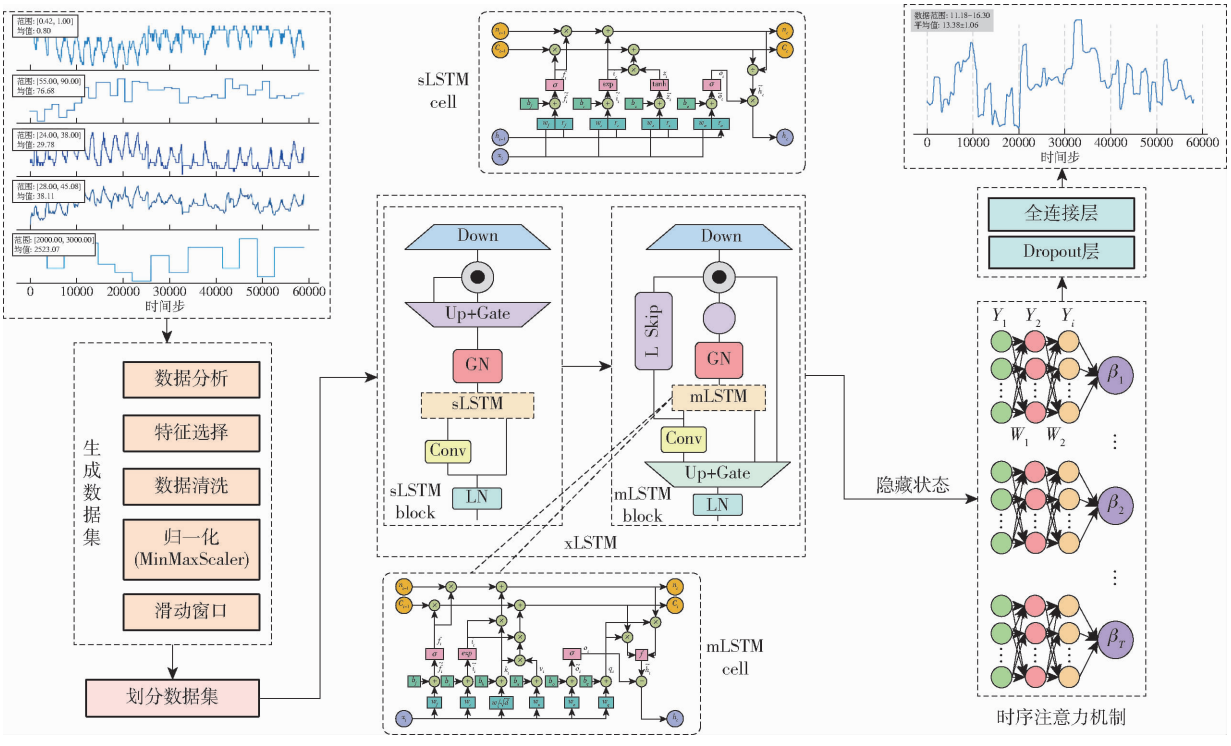

图 1 网络流程图

Fig. 1 Network flowchart

时间序列输入模块首先对原始数据进行清洗与特征筛选，以消除冗余特征与异常值的干扰。随后采用最大最小归一化技术对原始数据进行标准化处理以消除量纲差异。接着，基于干燥机的最长干燥周期，运用固定步长的滑动窗口机制，将连续时间序列数据转换为样本数据集。每个样本包含 3 200 个

历史时间步的多维特征(该数值基于干燥机最长干燥周期与采样间隔计算),为后续建模与分析提供标准化的输入格式。

xLSTM 核心模块将预处理后的输入特征经嵌入层映射到高维空间。随后输入到由 sLSTM 与 mLSTM 残差块构成的主干网络中。如图 1 xLSTM 模块所示,sLSTM 残差块采用后上投影结构,mLSTM 残差块采用预上投影结构。残差块的设计有助于在高维空间非线性表征与归纳历史信息,促进不同时段特征的分离,并通过线性映射保留关键信息[23]。2 种模块协同工作,使模型既能保留长期干燥历史的影响,又能快速适应工况突变的情况,为后续注意力聚焦提供全面的时序特征基础。基于前期多次预试验,本研究确定的 xLSTM 网络主干最终为 1 个 sLSTM 模块和 1 个 mLSTM 模块,并按 sLSTM 在前、mLSTM 在后的顺序连接,该结构在记忆长时序依赖与响应突变工况之间取得了最优平衡。

时序注意力模块以 xLSTM 输出的隐藏状态张量 $\boldsymbol{H}$ 作为输入。该模块对 $\boldsymbol{H}$ 进行线性变换,并采用 Sigmoid 激活函数进行非线性映射生成注意力评分,以反映不同时间步的相对重要性。评分经 Softmax 归一化处理后生成注意力权重 α;将隐藏状态 $\boldsymbol{H}$ 与 α 进行加权融合,得到聚焦于关键干燥阶段的深层时序状态矩阵 $\boldsymbol{S}$。该模块能够增强高温干燥阶段等关键时间区间的特征表示,同时抑制非关键时段的影响,有效提升模型对时序特征的判别能力。

预测输出模块将注意力加权后的特征进行 Dropout 正则化以抑制过拟合。随后,经全连接层将高维特征映射为单维含水率预测值。最后,该预测值通过反归一化处理还原至原始物理尺度,输出最终的稻谷状态预测结果。

1.4　评价指标

为量化模型预测的整体误差与对目标变量的拟合效果,采用均方根误差(RMSE)和决定系数(R^2)作为模型评估指标。

2　数据来源与处理

2.1　数据来源

以湘早籼 45 号稻谷为试验对象,于 2022—2024 年每年 7 月,在湖南宁乡卫红米业开展连续性干燥试验。所选稻谷收获后品质新鲜、成熟度良好,经自然通风预干燥和调质处理后,置于 5HNH－15 型连续式干燥机进行干燥。图 2 为该干燥机主体结构及所采用的逆流干燥工艺原理,其组成包括储粮段、2 段高温干燥段、2 段低温干燥段、排粮段以及设置在各干燥段之间的缓苏段。整机设计高度为 16.36 m,干燥层总厚度(含角盒)为 0.5 m,静容积(不含角盒)为 145.8 m^3,标准机容量约为 90 t 湿稻谷。干燥段内部由 2 层进气角盒和 2 层排气角盒间隔排列,形成 4 层厚度均为 0.5 m 的风道,总厚度为 2 m;缓苏段总厚度为 1.58 m。干燥段和缓苏段净截面积(排除角盒)分别为 9.92 m^2 和 12.66 m^2。该设备采用逆流干燥工艺,其核心特征在于干燥全过程中物料与干燥介质始终保持逆向流动的热质交换状态[24]。图 2 局部放大图清晰呈现了稻谷与热风流向关系,干燥过程中的稻谷在重力作用下自上而下流动,依次经过各干燥层和缓苏层;而热风则从各干燥段下层角盒送入,自下而上穿透粮层,从上层角盒排出。

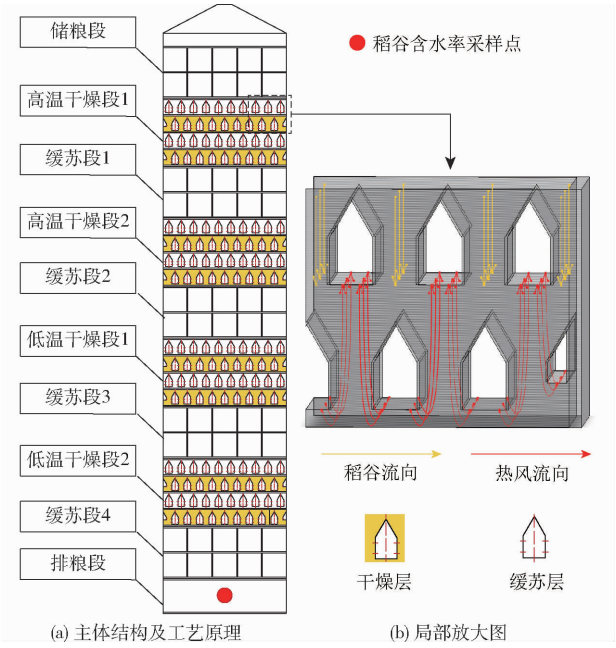

图 2　5HNH－15 型连续式粮食干燥机结构

Fig. 2　Structural diagrams of 5HNH－15 continuous grain dryer

建模试验采用长期连续性干燥方案,数据采集覆盖 3 个年度的生产季,旨在充分捕捉实际生产中因环境温湿度昼夜变化、进机稻谷初始含水率自然差异等因素引起的工况波动,确保所构建数据集的多样性与代表性。试验期间,在各级干燥段的进气风道安装 PT100 型温度传感器(精度为 0.1℃,上海远亚电子有限公司)监测热风温度;在各级干燥段排气风道布置 AM2305 型温湿度传感器(温度精度为 0.3℃,相对湿度精度为 2%,广州奥松电子有限公司)监测排气湿度和温度;在各段风道测量孔安装 AS8336 型风速仪(精度为 ±0.01 m/s,广州西玛瑞电子有限公司)测定并计算平均干燥风速;在稻谷入机前与干燥机排粮口采样点(位置见图 2a)安装自动取样器,每个取样机按固定时间间隔采集 3 份

平行样品,并使用 DHG070B 型空气对流烘箱(上海安亭科学仪器厂)通过标准烘箱法测定各时刻稻谷平均含水率[25];在排粮段出口处设置 DY-718 型电子秤(精度为 ±1 g,金华富瑞斯电子有限公司)估算物料流量。所有传感器均连接至自主研制的数据采集系统,实现数据自动采集与记录,采样间隔为 9 s。

试验共采集 17 类特征参数,包括进机粮食含水率、环境温湿度、各干燥段风温与风速、粮食流速以及 4 个干燥段排气温湿度,最终获得 17 类特征共 8.7×10^5 组数据。为清晰呈现关键参数总体分布,表 1 为训练数据集中所有输入特征与输出目标的详细范围。

表 1 建模试验参数

Tab.1 Modeling test data parameters

参数	数值
进粮含水率/%	22.1 ~ 24.8
环境温度/℃	19 ~ 38
环境相对湿度/%	24 ~ 100
高温段风温/℃	50 ~ 71
高温段风量/(kg·h^{-1})	24 096 ~ 36 144
高温段风速/(m·h^{-1})	2 000 ~ 3 000
低温段风温/℃	40 ~ 50
低温段风量/(kg·h^{-1})	10 939 ~ 14 362
低温段风速/(m·h^{-1})	908 ~ 1 192
粮食流速/(m·h^{-1})	1.92 ~ 2.48
排气相对湿度/%	65.1 ~ 99.9
排气温度/℃	23.45 ~ 46.54

2.2 数据处理

原始数据集中多个特征之间存在高度相关性,其携带的信息高度冗余或重叠。若将此类高相关特征全部输入模型,可能会因共线性问题导致模型泛化能力下降。为去除冗余信息,使用皮尔逊相关性对 17 类特征进行分析[26]。该系数用来量化特征与目标变量之间线性关系的强度和方向,通过计算协方差标准化后的值,可以识别出变量显著正相关或负相关的特征,为后续模型构建提供更简洁、更具解释性的输入依据。

计算所得特征间相关系数如图 3 所示。由图 3a可看出不同干燥段的排气温度与排气湿度之间存在较强的线性关联。为确保特征的独立性,参照文献[27]并结合预试验,确定皮尔逊相关系数阈值为 0.75,最终保留 9 类关键参数,其中包括进粮含水率(M_{in})、环境温度(T_e)、环境湿度(φ_e)、高温段风温风速(T_h、v_h)、低温段风温风速(T_l、v_l)、粮食流速(v_g)和第一高温段排气温度(T_{h1})。这些特征分别从输入条件、控制变量和过程状态等多维度,较为全面地反映了干燥系统的物理过程。其中,第一

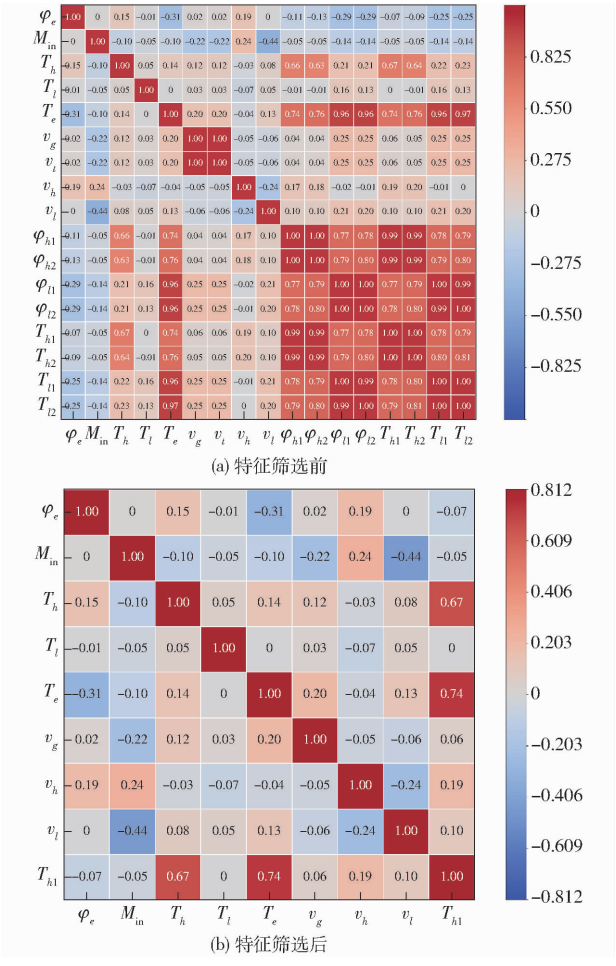

图 3 特征相关系数

Fig.3 Feature correlation coefficient maps

高温段排气温度作为干燥前期最早的状态监测指标,能够更敏锐地反映干燥过程中的动态变化,对稻谷状态变化具有较强的表征能力。

经特征筛选后,对数据进行缺失值填充与异常值处理,并采用最大最小归一化消除量纲差异。随后利用滑动窗口法构建时序样本,以 9 类特征为输入,出粮含水率为输出,依据最长干燥周期(8 h)与采样间隔(9 s),设定窗口长度为 3 200 步。最终获得 866 800 组数据,每组数据维度为 9×3 200。

3 结果与分析

为完成模型从构建到现场应用的完整验证,依次进行了 3 项干燥试验。第 1 项为建模干燥试验,旨在采集大量现场干燥数据为模型训练提供基础。第 2 项为独立干燥数据验证试验,采用时间上完全独立的新数据集,旨在评估模型在全新干燥周期中的预测精度,检验其脱离训练环境后的实际适用性。第 3 项为阶跃干燥工况测试试验,进一步考察模型在训练数据未覆盖的极端工况下的表现,通过主动施加参数突变,检验模型在实际应用中应对复杂扰动的动态响应。

3.1　模型训练与测试

模型训练与测试基于建模干燥试验数据集，按比例 14∶3∶3划分为训练集、验证集与测试集，对 xLSTM 网络模块比例、学习率、批处理大小及迭代次数等超参数进行训练优化，以确定最佳模型架构。

xLSTM 模型由 sLSTM 和 mLSTM 模块组合构成，其排序和配比会使模型产生不同的预测结果[28]。由于干燥数据中既包含需要快速响应的短期波动（如进粮含水率变化），也包含复杂的长期依赖关系（如多干燥段条件对最终含水率的累积影响），初步确定 sLSTM 在前、mLSTM 在后的连接顺序。sLSTM 模块凭借其快速记忆更新机制适于优先捕获短期波动特征，处理后数据长期依赖关系更趋清晰，便于后续 mLSTM 模块进行建模。若顺序颠倒，短期波动信息可能被侧重长期依赖的 mLSTM 模块平滑，进而削弱模型对实时工况变化的响应能力。在模块数量方面，研究遵循在功能完备前提下确保结构最简的原则，将任意模块最大数量上限设定为 2 个。

为验证上述顺序设计并确定具体模块构成，开展了模型比例试验。试验结果如表 2 所示，其中［a∶b］表示 a 个 sLSTM 与 b 个 mLSTM 依次连接。试验结果表明，当模块排序遵循先 sLSTM 后 mLSTM，且配比为［1∶1］时，模型拥有最佳的预测效果，RMSE 为 0.134%，R^2 为 0.988。相比之下，采用 mLSTM 在前、sLSTM 在后顺序的各种配比，性能均显著低于前者，这证实顺序设计的合理性。在数量配比方面，该组合架构的预测效果显著优于单一模块的模型，验证了 sLSTM 与 mLSTM 在功能上的协同效应。此外，在同时引入 2 种模块的情况下，增加 mLSTM 的比例会导致模型性能下降，这源于 mLSTM 模块数量增多引发的过拟合现象；而增加 sLSTM 模块数量并未带来预测精度的显著提升，反而会降低模型的稳定性和计算速度。综上所述，采用［sLSTM∶mLSTM］＝［1∶1］作为 xLSTM－TA－PD 模型最终主干架构。

表 2　xLSTM 模块比例试验结果

Tab. 2　Proportional experimental results of xLSTM module

sLSTM∶mLSTM	RMSE/%	R^2	mLSTM∶sLSTM	RMSE/%	R^2
［0∶1］	0.194	0.976	［0∶1］	0.174	0.981
［0∶2］	0.200	0.975	［0∶2］	0.176	0.980
［1∶1］	0.134	0.988	［1∶1］	0.170	0.982
［1∶2］	0.170	0.982	［1∶2］	0.189	0.978
［2∶1］	0.143	0.987	［2∶1］	0.195	0.976
［2∶2］	0.171	0.982	［2∶2］	0.232	0.971

模型训练过程中，学习率（Learning rate，L_r）控制权重更新的步长，批处理大小影响梯度更新频率，迭代次数影响模型训练精度与时长。图 4a、4b 分别为多次重复运行中不同 L_r 下 R^2 和 RMSE 测试结果。由图 4a、4b 可知，当 $L_r \leqslant 0.000\,5$ 时，随着 L_r 增大，RMSE 逐渐减小，R^2 逐渐增大，模型预测性能上升；当 $L_r > 0.000\,5$ 时，随着 L_r 增大，RMSE 逐渐增大，R^2 逐渐减小，模型预测性能降低。当 L_r 为 0.000 5 时，模型表现稳定且 R^2 和 RMSE 均处于最优水平，因此取 L_r 为 0.000 5。

图 4c、4d 分别为模型迭代次数与批处理大小对 R^2 和 RMSE 的影响。由图 4c、4d 可见，迭代次数和批处理大小对模型的影响较为复杂，当模型迭代次数为 400 至 450、批处理大小为 16 或 32 时，模型 R^2 与 RMSE 均优于其他组合。为规避过拟合风险并提升训练效率，最终选取迭代次数为 400，批处理大小为 32 的训练配置。基于上述试验，确定最优训练参数：L_r 为 0.000 5、迭代次数为 400、批处理大小为 32，在此参数配置下，模型拥有最佳的预测性能。

3.2　模型验证

3.2.1　对比试验

为评估所提模型性能，将其与本课题组前期建立的深床干燥解析模型及现有神经网络模型进行对比[29－33]。所有模型均基于划分好的建模干燥试验数据集进行训练与测试。参与对比的模型包括时序注意力增强型扩展长短期记忆网络（xLSTM－TA）（图 5a）、扩展长短期记忆网络（xLSTM）（图 5b）、时序注意力增强型长短期记忆网络（LSTM－TA）（图 5c）、高效长序列时间序列预测模型（INFORMER）（图 5d）、时间卷积网络（TCN）（图 5e）、神经基础扩展时间序列预测模型（N－BEATS）（图 5f）、深床干燥解析模型（图 5g）。

各模型对连续干燥过程中的出粮含水率预测效果如图 5 所示，展示了各批次稻谷最终含水率随时间变化的过程，含水率波动区间囊括干燥不足与过度干燥等工况，旨在验证模型对出粮含水率超出安全区间的预警能力，从而为干燥作业安全提供可靠的数据支持。图 6 为对应的性能评估指标。试验表明，所有模型均能捕捉含水率的宏观波动，但在局部拟合精度上差异显著。由图 5 可知，xLSTM－TA 预测值与实际值吻合度最高，在干燥中期波动阶段与含水率峰值区域拟合紧密，R^2 为 0.988，RMSE 为 0.134%，最大绝对误差为 0.415%。INFORMER 模型可通过稀疏自注意力机制区分不同干燥段的作用，其 R^2 为 0.983，RMSE 为 0.165%，最大绝对误差为 0.541%，但在误差控制上劣于 xLSTM－TA 模

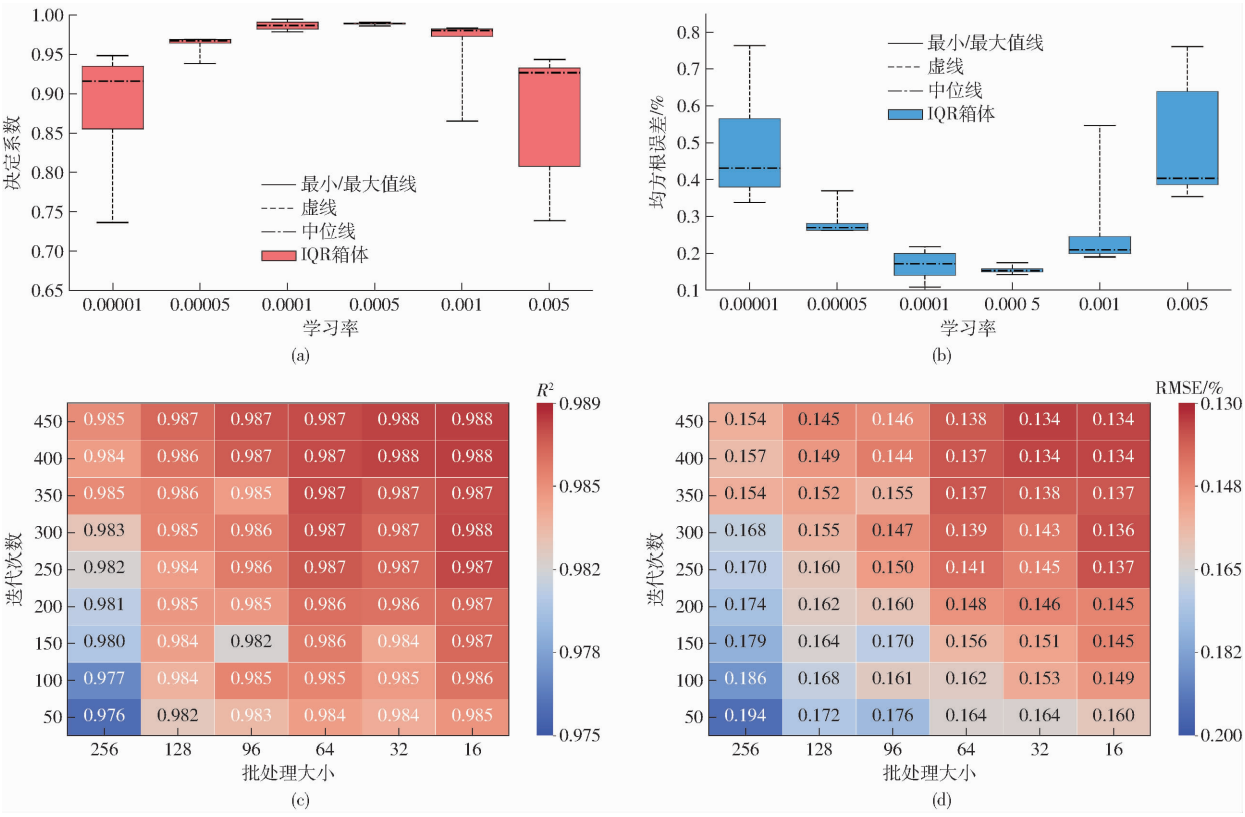

图 4 模型参数选择

Fig. 4 Model parameters selection

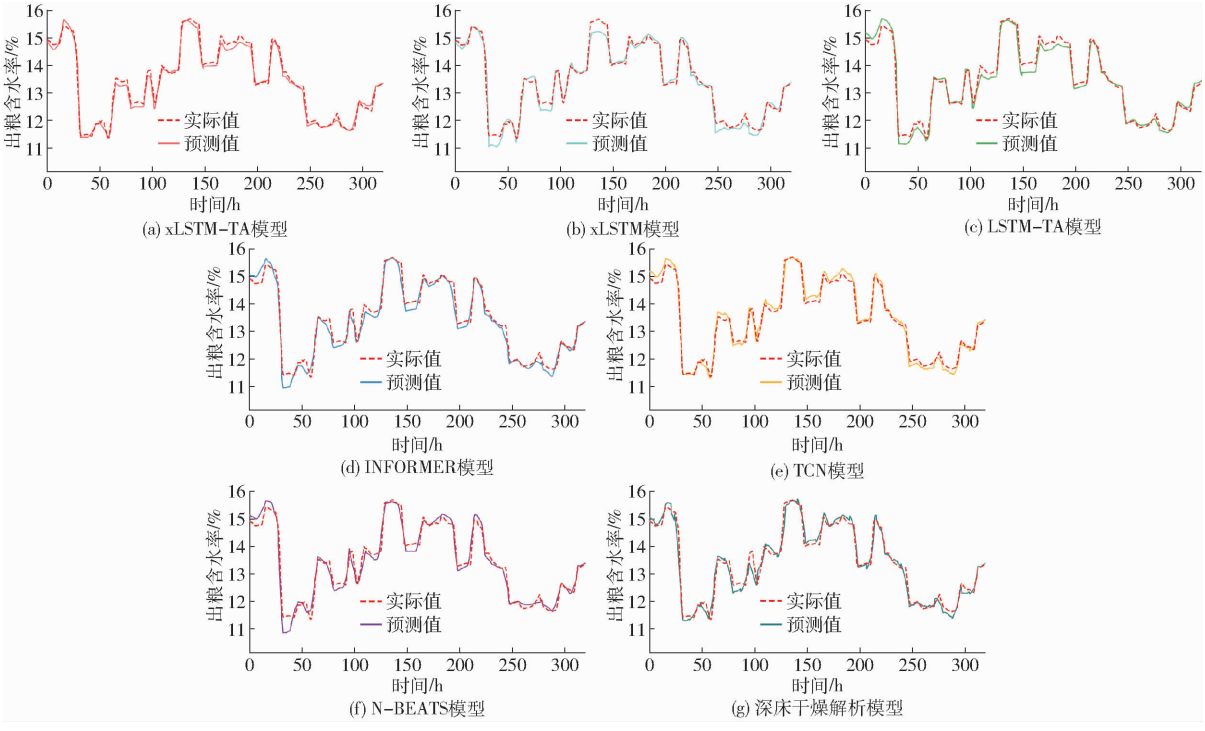

图 5 不同模型下出粮含水率预测趋势图

Fig. 5 Trend charts of grain moisture content prediction under different models

型。xLSTM 模型因缺乏时序注意力机制,预测含水率峰值时出现失真,其 R^2 为 0.975,RMSE 为 0.198%,最大绝对误差为 1.180%,表明区分不同干燥段对提升预测精度具有关键作用。基于残差结构的 N-BEATS 模型在拟合含水率峰谷时表现与 xLSTM 模型相近,尤其在120 ~ 150 h 区间未能准确捕捉峰值,其 R^2 为 0.980,RMSE 为 0.181%,最大绝对误差为 0.497%。受限于其固有的卷积结构特性,TCN 模型整体拟合效果较差,R^2 为 0.970,RMSE 为 0.221%,最大绝对误差为 0.816%,预测存在响

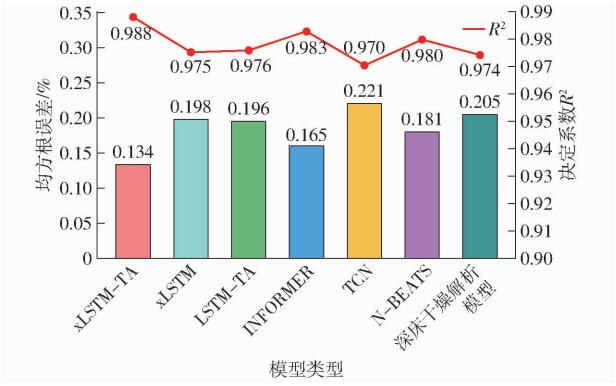

图 6　不同模型下稻谷含水率预测结果

Fig. 6　Predicted results of grain moisture content under different models

应滞后与幅度失真问题。LSTM－TA 模型在部分突变区间(如 80～100 h 和 210～220 h)拟合良好,但其未引入增强模块,对干燥过程长期时序依赖关系的建模能力不足,R^2 为 0.976,RMSE 为 0.196%,最大绝对误差为 1.04%。深床干燥解析模型 R^2 为 0.974,RMSE 为 0.205%,最大绝对误差为 0.945%,性能虽略优于 TCN 模型,但仍低于其他数据驱动模型。这与前文所述机理模型的固有局限相符,即该类模型因难以精准确定所有过程参数,在复杂的干燥工况中表现出明显的解析局限。综上所述,在 RMSE、R^2 和最大误差 3 项指标上,xLSTM－TA 展现出最优的综合预测性能。

3.2.2　消融试验

为验证模型各模块有效性,基于建模干燥试验数据集进行了消融试验[34],逐一去除 sLSTM、mLSTM 及 TA 模块来观察模型的预测效果,结果如表 3 所示。移除 sLSTM 模块后,RMSE 升至 0.197%、R^2 降至 0.976,验证了该模块对整体预测性能的重要贡献,表明快速响应机制是处理干燥过程波动的必要组成部分。移除 mLSTM 残差块后,RMSE 增至 0.174%、R^2 降至 0.981,这表明 mLSTM 的长期记忆能力是模型学习长期依赖关系的基础。移除 TA 模块后性能下降最为显著,RMSE 升至 0.198%、R^2 降至 0.975,这是由于模型失去了对关键干燥阶段的聚焦能力,使其无法准确量化不同干燥段对最终含水率的贡献差异,从而削弱了模型学习干燥规律的能力。

表 3　消融试验结果

Tab. 3　Ablation test results

sLSTM 模块	mLSTM 模块	TA 模块	RMSE/%	R^2
√	√	√	0.134	0.988
×	√	√	0.197	0.976
√	×	√	0.174	0.981
√	√	×	0.198	0.975

注:√表示使用此模块,×表示未使用此模块。

3.3　模型应用与性能分析

3.3.1　模型应用

为检验模型在面对全新干燥周期和真实工况时的实际预测能力,开展第 2 次干燥试验作为独立现场验证。试验旨在获取 1 个在时间上与建模数据集完全独立的新数据集,以克服训练集、验证集和测试集因来自同一连续时间序列所导致的关联性局限,从而更有效地评估模型的实用性[35]。采用干燥时长为 30 h 的新数据,其关键参数见表 4。用训练完成的模型对出粮含水率进行预测,结果如图 7 所示。结果表明,预测值与实测值曲线趋势一致,R^2 为 0.988,RMSE 为 0.068%,最大绝对误差仅为 0.12%。在含水率快速下降阶段,预测值能紧密跟随实际值变化,证明了其在真实干燥场景中的实用性。

表 4　独立干燥试验关键参数

Tab. 4　Key parameters of independent drying test

参数	数值
进粮含水率/%	23.60
环境温度/℃	25～31
环境相对湿度/%	62～89
粮食流速/(m·h^{-1})	1.95～2.11
高温段风温/℃	60～66
高温段风速/(m·h^{-1})	2 400～3 000
高温段风量/(kg·h^{-1})	62 312～77 890
低温段风温/℃	50
低温段风速/(m·h^{-1})	1 092
低温段风量/(kg·h^{-1})	28 326

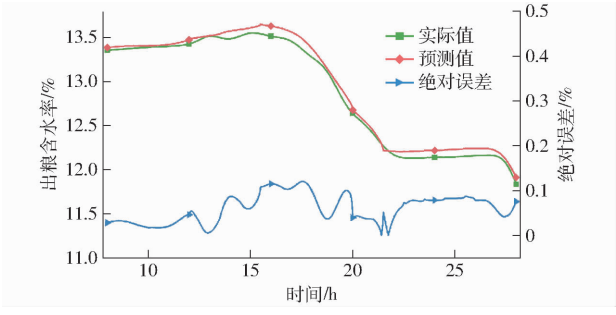

图 7　独立干燥试验出粮含水率预测结果

Fig. 7　Predicted grain moisture content curves from independent dataset

3.3.2　阶跃性响应

在实际生产中,干燥系统常因设备调控(如温度骤升、风速突变)以及自然环境状态突变,导致干燥条件发生阶跃变化,进而使数据分布产生偏差。为评估本模型在训练数据未覆盖场景与参数突变工况下的泛化性能,进行第 3 项干燥试验,试验聚焦于干燥条件的阶跃变化[36]。试验在环境相对湿度 89%、环境温度 28℃、高温段风速 2 600 m/h、低温段

风速 1 092 m/h 固定条件下，主动对高温段与低温段进气温度、粮食表观流速及进粮含水率 4 个关键参数进行了阶跃调整，变化曲线如图 8 所示，其中高温段进气温度 85℃ 与低温段进气温度 40℃ 为训练集未覆盖数值，旨在验证模型对未知工况的泛化性能。

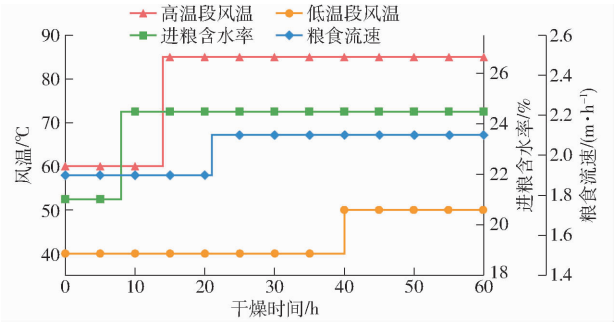

图 8 干燥条件阶跃变化曲线

Fig. 8 Step change curves of drying conditions

从干燥过程第 8 小时起稻谷出粮含水率的变化情况如图 9 所示，其变化呈现明显的阶段性特征。初始 0 ~ 8 h 内，含水率快速下降；第 8 小时进粮含水率由 21% 阶跃上升至 24.5%，因逆流干燥系统中进粮端对出粮端无直接作用，出粮端稻谷含水率变化滞后约 8 h，从第 16 小时起开始快速上升。第 14 小时高温段风温由 60℃ 升至 85℃，该段位于干燥塔上半段，稻谷流至出粮端约 4 h，因此含水率自第 18 小时起逐渐下降。第 21 小时粮食表观流速从 1.9 m/h 提高至 2.1 m/h，流速加快导致干燥停留时间缩短，引起干燥不足，含水率随之升高。第 40 小时低温段风温由 40℃ 升至 50℃，由于该段靠近排粮端，热风直接作用于即将排出的稻谷，使得稻谷含水率在 1 h 内迅速下降，并于 4 h 后恢复平稳。模型预测值与实际含水率变化趋势基本一致，最大误差为 0.44%，RMSE 为 0.10%，R^2 为 0.972，仅 2.7% 的样本绝对误差超过 0.2%。该结果与本课题组前期解析结果的最大误差 0.41% 相近，而 RMSE 较前期研究的 0.23% 有所降低，体现了整体预测精度的提升。同时，模型准确再现了含水率响应滞后规律，与前期在深床干燥系统动态特性方面的研究结论相互印证[37]，表明稻谷含水率变化不仅受当前参数影响，更依赖于历史干燥条件的积累影响。在面对训练集中未曾出现的高温（85℃）与低温（40℃）工况下，模型仍能够准确捕捉含水率的动态响应，表明其具有良好的泛化性能。

3.3.3 推理时间

在实际工程应用中，预测模型的推理效率决定其能否集成至嵌入式系统并实现在线实时调控。为评估所提出模型的计算推理性能，将其与深床干燥解析模型进行对比[29]，结果如图 10 所示。

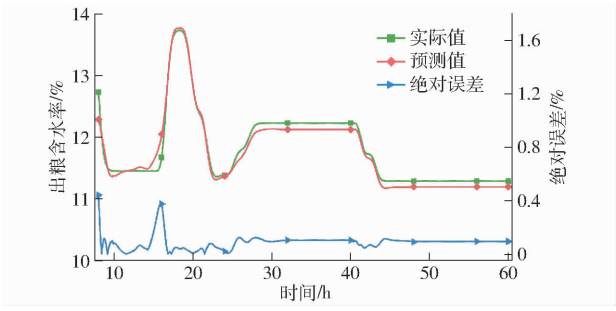

图 9 阶跃工况下出粮含水率预测结果

Fig. 9 Predicted results of grain moisture content under step operating conditions

图 10a、10b 为 2 种模型对大量单样本进行推理所需时间的分布直方图。统计分析表明，深床干燥解析模型平均推理耗时为 0.492 8 s，且稳定性欠佳，最大耗时为 0.518 s，有 9.24% 的样本推理时间超过 0.5 s。这种较差的稳定性源于其复杂的迭代数值求解过程，计算负载严重依赖于输入数据的复杂程度。相比之下，本研究模型平均耗时为 0.056 6 s，最大耗时为 0.141 s，平均推理速度较深床干燥解析模型提升 7.7 倍。其耗时分布更为集中，表明计算过程受输入数据波动的影响小，稳定性和一致性更高。从图 10c、10d 可看出，深床干燥解析模型的推理时间随不同输入数据呈无规律波动；而本研究模型则表现出规律的频繁波动，其波动幅度被严格控制在较低水平，这反映出该模型计算架构的精简性与调度过程的可控性。

本系统数据采样间隔为 9 s，深床干燥解析模型平均耗时 0.492 8 s，约占单个采样周期的 5.5%，虽基本满足实时性要求，但余量较为紧张，且对现场硬件算力要求较高。本研究模型平均耗时 0.056 6 s，占 1 个采样周期的 0.63%，留有充足的计算余量。该模型训练完成后可部署于边缘计算设备，降低了对工程硬件算力的依赖，在满足高频实时预测的同时，也为集成更复杂的预测控制算法提供了性能空间。因此，xLSTM - TA - PD 模型在推理效率上较深床干燥解析模型具有明显优势，能够为实时智能决策提供高效的技术支持。

3.3.4 时间步权重

图 11 为本模型在预测稻谷含水率过程，对不同时间步所分配的注意力权重，图中颜色可直观反映模型对不同历史时刻的关注程度，该关注程度对应于干燥塔中不同干燥段对稻谷含水率的影响强度。

由图 11 可知，模型赋予时间步 0 ~ 200 权重较低，此阶段为初始缓苏段，并未接触热风，因此参数对含水率的累积影响较小。时间步 200 ~ 300 权重

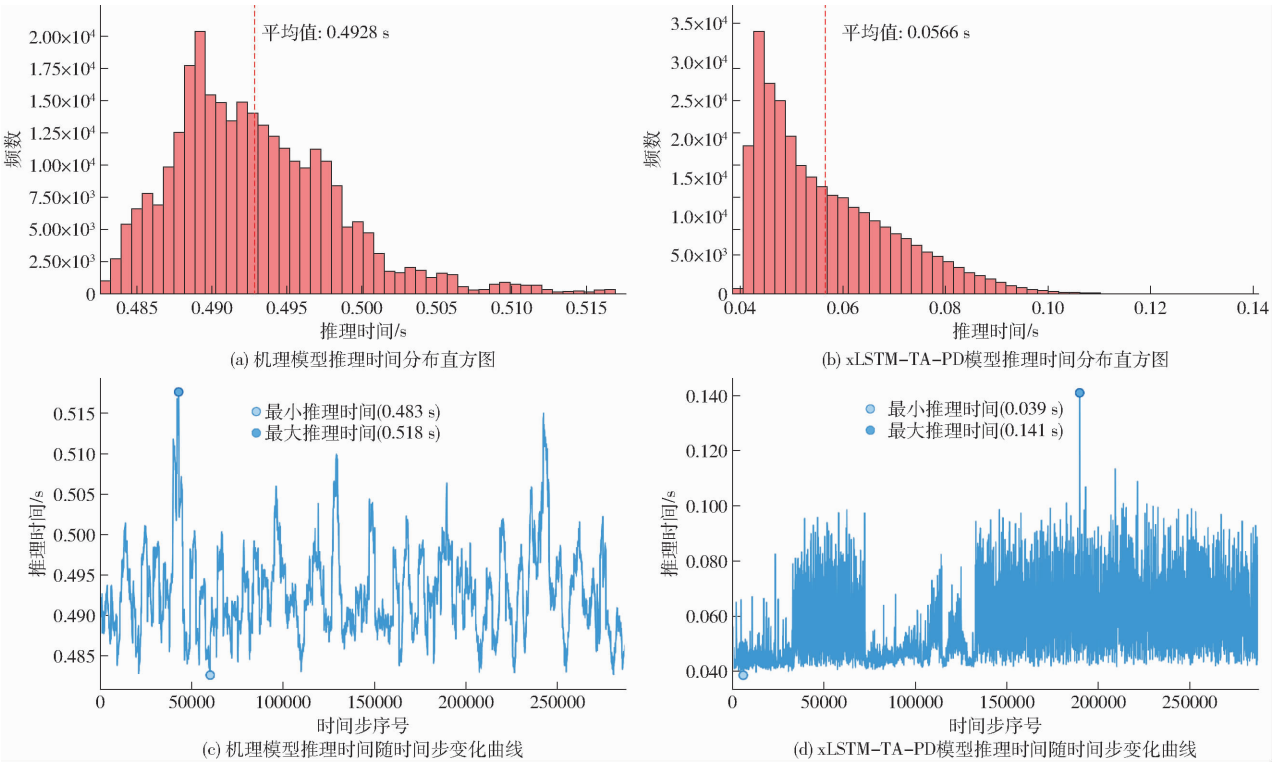

图 10　不同模型推理时间测试结果

Fig. 10　Test results of inference time between different models

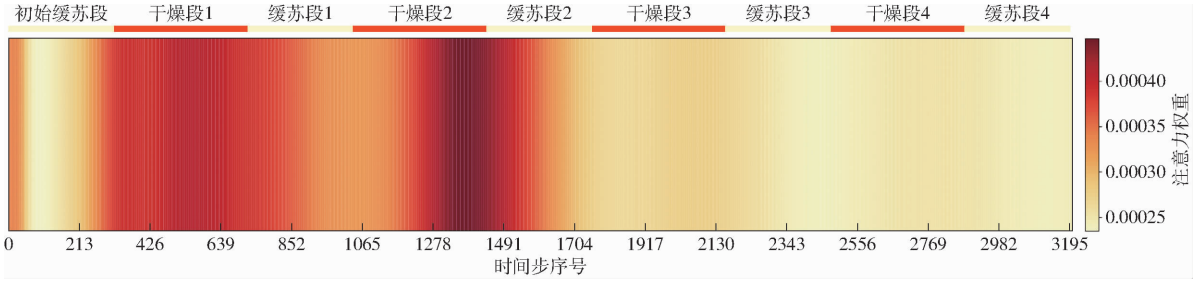

图 11　时间步权重热力图

Fig. 11　Time-step weighted heat diagram

有所上升，此时稻谷缓慢接近干燥段，表面温度缓慢升高，水分开始蒸发。但此时蒸发的主要是表面吸附的少量非结合水，内部水分向表面迁移速度较慢，因此该时段参数对最终含水率的累积影响较小，模型赋予的权重不高。模型对时间步 300～1 600 赋予较高权重，这与 5HNH－15 型干燥机物理过程一致，此时稻谷处于 2 处高温段及中间的缓苏段，内部水分快速向表面迁移，表面水分持续高效且稳定地蒸发。其中，时间步 1 300～1 450 权重最高，表明此时热风与稻谷的热质交换最为剧烈，含水率变化速率最大。在时间步 1 900～2 300 以及 2 560～2 900 时，稻谷位于 2 个低温段及之间的缓苏段，权重相较于高温段有所降低，这是因为此时稻谷非结合水与部分结合水已完成蒸发，剩余的结合水难以蒸发，内部水分迁移速度减慢，表面水分蒸发速率也随之下降。

注意力权重的分布规律与实际干燥机理高度吻合[38]，表明模型能够依据物理过程自主学习不同时段的重要性，这在工程应用中具有重要价值。在工艺优化上，可通过识别核心影响时段，指导操作人员针对性调控风温与风速，以提升干燥效率与品质。在模型改进层面，该权重分布可为机理建模提供参考，例如在不同时段的水分迁移方程中引入差异性权重，从而降低传统模型的解析误差。该权重分析为理解干燥过程与实现精准调控提供了数据驱动视角。

4　结论

（1）围绕稻谷多段逆流干燥工艺的干燥状态预测需求，构建了基于时序注意力增强型扩展长短期记忆网络的稻谷多段逆流干燥预测模型（xLSTM－TA－PD），所建预测模型通过顺序连接 1 个 sLSTM 残差块与 1 个 mLSTM 残差块构建网络主干，加强了对干燥长时序历史信息的记忆与对参数突变的准确

响应能力,同时引入时序注意力机制解决传统模型对干燥阶段权重均一化的问题。消融试验结果表明,任意模块缺失均会导致模型预测性能下降,验证了各模块的必要性与协同作用。

(2)通过特征分析,成功识别并移除了干燥系统各段冗余度高的排气参数,将模型输入特征简化至 9 类关键参数,明确了反映稻谷状态变化的主要因素,避免了重复信息干扰。

(3)在最优训练配置下,模型 R^2 为 0.988,RMSE 为 0.068%,最大绝对误差为 0.12%,能够完整预测连续干燥过程的稻谷含水率变化,预测效果显著优于深床干燥解析模型及其他数据驱动模型。在阶跃工况下,模型准确识别参数阶跃变化与干燥状态响应间的滞后特性(如进粮含水率影响滞后约 8 h、高温风温影响滞后约 4 h 等),最大绝对误差为 0.44%,仅 2.7% 的样本绝对误差高于 0.2%,体现出模型对干燥参数突变的准确响应能力及对未知工况的泛化能力。模型最大推理耗时为 0.141 s,平均单次推理耗时为 0.056 6 s,仅占采样周期(9 s)的 0.63%,相较深床干燥解析模型效率提升 7.7 倍,满足干燥过程实时监控要求。

(4)提供了一种量化不同干燥段对稻谷状态影响的新方法。通过分析模型时序注意力权重,实现了不同干燥阶段对干燥状态影响程度的量化,增强了模型可解释性,为理解干燥机理和实现精准工艺调控提供了数据驱动视角。

参 考 文 献

[1] 刘春山,陈思羽,肖世伟,等. 稻谷变温均质干燥装置工艺优化与性能试验[J]. 农业机械学报, 2023, 54(增刊 1): 366 – 372.
LIU Chunshan, CHEN Siyu, XIAO Shiwei, et al. Process research and performance verification of variable temperature homogeneous drying device for paddy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 366 – 372. (in Chinese)

[2] YING T Y, SPANG E S. Paddy drying technologies: a review of existing literature on energy consumption[J]. Processes, 2024, 12(3): 532.

[3] DYCK G, HAWLEY E, HILDEBRAND K, et al. Digital twins: a novel traceability concept for post-harvest handling[J]. Smart Agricultural Technology, 2023, 3: 100099.

[4] RAZAVIZADEH N, ZARE D, NASSIRI S M, et al. Experimental study and numerical simulation of resistance to airflow in a storage bin of rough rice with three inlet duct configurations[J]. Biosystems Engineering, 2023, 225: 118 – 131.

[5] SITORUS A, PUTRA S A, CEBRO I S, et al. Modelling drying kinetics of paddy in swirling fluidized bed dryer[J]. Case Studies in Thermal Engineering, 2021, 28: 101572.

[6] AMANTEA R P, BALBINO G P, FORTES M. Dynamic analysis of grain quality during drying in fluidised beds[J]. Biosystems Engineering, 2023, 228: 149 – 165.

[7] 李长友. 粮食干燥解析法[M]. 北京: 科学出版社, 2018.

[8] 方壮东,李长友,赵懿琨. 稻谷逆流循环干燥瞬态解析模型[J]. 农业工程学报, 2019, 35(23): 286 – 295.
FANG Zhuangdong, LI Changyou, ZHAO Yikun. Transient mathematical modeling of circulation counter-flow rice drying system [J]. Transactions of the CSAE, 2019, 35(23): 286 – 295. (in Chinese)

[9] ZHU H, LI X, ZHANG Y. Application of artificial neural networks in agricultural product drying: a review of recent advances [J]. Frontiers of Agricultural Science and Engineering, 2025, 12(1): 15 – 28.

[10] CHOKPHOEMPHUN S, HONGKONG S, CHOKPHOEMPHUN S. Artificial neural network for drying behavior prediction of paddy in developed chamber fluidized-bed dryer[J]. Computers and Electronics in Agriculture, 2024, 220: 108888.

[11] HUANG J, XIONG W, XU H L, et al. Expert system for drying schemes of agricultural products based on fuzzy control and BP neural network[J]. Journal of Internet Technology, 2021, 22(6): 1253 – 1263.

[12] ZHANG Y, FANG Z D, LI C Y, et al. Deep-learning-based model predictive control of an industrial-scale multistate counter-flow paddy drying process[J]. Foods, 2024, 13(1): 43.

[13] ZHANG L, REN G F, DU J S, et al. A novel spatio-temporal attention-based bidirectional LSTM model for moisture content prediction in drying process[J]. Drying Technology, 2024, 42(14): 2122 – 2136.

[14] MUSKEH A, AUSIF M. xLSTMTime: long-term time series forecasting with xLSTM[J]. AI, 2024, 5(3): 1482 – 1495.

[15] TIWARI D, BHATI B S, NAGPAL B, et al. Attention-augmented hybrid CNN – LSTM model for social media sentiment analysis in cryptocurrency investment decision-making[J]. Scientific Reports, 2025, 15: 33201.

[16] ZHENG W G, ZHENG K, GAO L T, et al. GRU-Transformer: a novel hybrid model for predicting soil moisture content in root zones[J]. Agronomy, 2024, 14(3): 432.

[17] WANG H. Raptor-T: a fused and memory-efficient sparse transformer for long and variable-length sequences[J]. IEEE Transactions on Computers, 2024, 73(7): 1852 – 1865.

[18] LI C J, HUANG J J, CHEN Y C, et al. Transient thermodynamic analysis and energy optimization of a circulation counter-flow wheat drying system utilizing a closed-loop heat pump configuration[J]. Energy Conversion and Management, 2025, 346: 120508.

[19] 李长友. 干燥物系的特征函数及其理论解[J]. 农业工程学报, 2020, 36(12): 286－295.
LI Changyou. Characteristic functions of drying material system and its theoretical solution[J]. Transactions of the CSAE, 2020, 36(12): 286－295. (in Chinese)

[20] LI C J, REN J Y, SETH A, et al. Hierarchical model predictive control for energy consumption regulation of industrial-scale circulation counter-flow paddy drying process[J]. Energy, 2025, 321: 135431.

[21] TIAN J, WANG S. Tool wear prediction based on xLSTM combined with the ECA attention mechanism model[J]. Journal of Mechanical Science and Technology, 2025, 39: 519－530.

[22] 赵秀艳,王彬,都晓娜,等. 基于时域卷积网络与 Transformer 的茶园蒸散量预测模型[J]. 农业机械学报, 2024, 55(9):337－346.
ZHAO Xiuyan, WANG Bin, DU Xiaona, et al. Evapotranspiration prediction model of tea garden based on temporal convolutional network and Transformer[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 337－346. (in Chinese)

[23] ZIGNIC L, BEGUSIC S, KOSTANJCAR Z. Block-diagonal idiosyncratic covariance estimation in high-dimensional factor models for financial time series[J]. Journal of Computational Science, 2024, 81: 102348.

[24] LI C J, FANG Z D, ZHONG J H, et al. Evaluating the dynamic characteristics and energetic performance of a paddy multistage counter-flow dryer[J]. Biosystems Engineering, 2022, 221: 208－223.

[25] 邓安,徐永阳,邱伟强,等. 基于电学参数的稻谷含水率和出糙率机器学习预测模型[J]. 农业工程学报, 2024, 40(15): 245－252.
DENG An, XU Yongyang, QIU Weiqiang, et al. Predicting moisture content and husked rice yield using electrical parameters and machine learning[J]. Transactions of the CSAE, 2024, 40(15): 245－252. (in Chinese)

[26] SIMONIC M, FICKO M, KLANCNIK S. Predicting corn moisture content in continuous drying systems using LSTM neural networks[J]. Foods, 2025, 14(6): 1051.

[27] ALQAHTANI H, RAY A. Feature selection of surface topography parameters for fatigue-damage detection using Pearson correlation method and neural network analysis[J]. Fatigue & Fracture of Engineering Materials & Structures, 2023, 46(5): 1810－1820.

[28] XIANG N, ZHANG T Y, LIU Y. State of health prediction for lithium-ion batteries using extended long short-term memory network and frequency enhanced channel attention mechanism with variational mode decomposition[J]. Measurement, 2025, 249: 117084.

[29] 李长友,方壮东.高湿稻谷多段逆流干燥缓苏解析模型研究[J].农业机械学报,2014,45(5):179－184.
LI Changyou, FANG Zhuangdong. Analytical models of multistage counter flow drying and tempering process of grain[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(5): 179－184. (in Chinese)

[30] ZHU Q B, HAN J L, CHAI K, ZHAO C S. Time series analysis based on Informer algorithms: a survey[J]. Symmetry, 2023, 15(4): 951.

[31] ORESHKIN B N, DUDEK G, PELKA P, et al. N-BEATS neural network for mid-term electricity load forecasting[J]. Applied Energy, 2021, 293: 116918.

[32] 耿磊,吴寒冰,张芳,等. 基于 TCN 和 Transformer 的鸡胚心跳混淆信号分类方法[J].农业机械学报, 2023, 54(8): 296－308.
GENG Lei, WU Hanbing, ZHANG Fang, et al. Classification method of heartbeat confusion signals of hatching eggs based on TCN and Transformer[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 296－308. (in Chinese)

[33] TANG L C. Paddy moisture content and drying time prediction using neural networks[C] // Proceedings of the 10th International Conference on Industrial Engineering and Application, 2023.

[34] 庄煜,徐琨林,李美琪,等.基于改进 YOLO v11n 的轻量化葡萄穗梗采摘点定位方法与试验[J].农业机械学报, 2025, 56(9):618－627.
ZHUANG Yu, XU Kunlin, LI Meiqi, et al. Lightweight grape cluster stalk picking point localization method and test based on improved YOLO v11n[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 618－627. (in Chinese)

[35] 周敏姑,闫云才,高文,等. 基于多光谱遥感和 CNN 的玉米地上生物量估算模型[J].农业机械学报, 2024, 55(9): 238－248.
ZHOU Mingu, YAN Yuncai, GAO Wen, et al. Estimating aboveground biomass of maize based on multispectral remote sensing and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 238－248. (in Chinese)

[36] ZHAO H, PAN R. Gaussian derivative change-point detection for early warnings of industrial system failures[J]. Reliability Engineering & System Safety, 2025, 256: 110681.

[37] 方壮东.粮食深床干燥解析法及控制系统研究[D].广州: 华南农业大学, 2019.

[38] 李长友.粮食干燥传递和转换特征及其理论表达[J].农业工程学报, 2018, 34(19): 1－8.
LI Changyou. Theoretical analysis of exergy transfer and conversion in grain drying process[J]. Transactions of the CSAE, 2018, 34(19): 1－8. (in Chinese)