doi:10.6041/j.issn.1000-1298.2026.23.015

心跳感知网络监测下鸡舍环境断联数据预测模型研究

贾宇琛[1,2]　李可行[3]　李丽华[3,4]　高立艾[2,3]　霍利民[2,3]

(1.河北农业大学信息技术学院,保定 071000;
2.河北省畜禽养殖智能装备与新能源利用重点实验室,保定 071000;
3.河北农业大学机电工程学院,保定 071000;4.农业农村部肉蛋鸡养殖设施工程重点实验室,保定 071000)

摘要:针对现代化鸡舍环境信息连续监测时出现的数据包丢失造成的决策失误问题,提出一种基于自适应心跳机制与 CNN-BiLSTM-Attention 模型的断网检测与环境数据预测方法。建立自适应心跳机制动态调整网络状态检测时间(范围 1~60 s),采用往返时延(Round-trip time, RTT)和丢包率(Packet loss rate, PLR)参数实现三阶段分级判定:网络质量下降时触发提示告警,出现断网风险时触发次要告警,断网时触发重要告警并启动预测模型。数据预测模型融合卷积神经网络(CNN)、双向长短期记忆网络(BiLSTM)和注意力机制(Attention),提升局部特征提取、序列信息处理和重点聚焦能力,实现断网间隔数据预测。模拟实验证明心跳机制可维持 99.3% 的连接存活率,日均通信量降低 81% 左右,异常检测延迟小于 5.8 s。采用所提模型在断网期间对温湿度、二氧化碳浓度等环境数据进行预测,预测值均方根误差(RMSE)和平均绝对误差(MAE)平均分别为 0.243℃ 和 0.194%,拟合优度 R^2 平均在 0.95 以上。网络状态监测协同数据预测的机制,有效保障断网期间的数据完整性,保障环境调控决策的准确性。

关键词:鸡舍环境;断网检测;CNN-BiLSTM-Attention 模型;自适应心跳机制;智能养殖

中图分类号:S24;S831　　**文献标识码**:A　　**文章编号**:1000-1298(2026)23-0161-10　　**OSID**:

Prediction Model of Disconnection Data of Henhouse Environment under Heartbeat Perception Network Monitoring

Jia Yuchen[1,2]　Li Kexing[3]　Li Lihua[3,4]　Gao Liai[2,3]　Huo Limin[2,3]

(1. *College of Information Technology, Hebei Agricultural University, Baodin* 071000, *China*
2. *Key Laboratory of Intelligent Equipment and New Energy Utilization in Livestock and Poultry Farming of Hebei Province, Baoding* 071000, *China*
3. *College of Mechanical and Electrical Engineering, Hebei Agricultural University, Baoding* 071000, *China*
4. *Key Laboratory of Facilities for Poultry and Egg Production Engineering, Ministry of Agriculture and Rural Affairs, Baoding* 071000, *China*)

Abstract: Aiming to address the issue of decision-making errors caused by data packet loss during continuous environmental monitoring in modern poultry houses, a network disconnection detection and environmental data prediction method was proposed based on an adaptive heartbeat mechanism and a CNN-BiLSTM-Attention model. An adaptive heartbeat mechanism was established to dynamically adjust the network status detection interval (ranging from 1s to 60 s). Parameters included round-trip time (RTT) and packet loss rate (PLR) were utilized to implement a three-level graded determination: a prompt warning was triggered when network quality degraded, a minor warning was issued upon the emergence of disconnection risk, and a major warning was activated upon actual network disconnection, which subsequently initiated the prediction model. The data prediction model integrated convolutional neural network (CNN), bidirectional long short-term memory (BiLSTM), and attention mechanisms, thereby enhancing capabilities in local feature extraction, sequential information processing, and key-point focusing, enabling data prediction during network interruption intervals. Simulation experiments demonstrated that the heartbeat mechanism maintained a connection survival rate of 99.3%, reduced

收稿日期:2025-12-10　修回日期:2025-12-25

基金项目:河北省现代农业产业技术体系建设专项资金项目(HBCT2024260203、HBCT2024270208)、河北省自然科学基金项目(C2025204036)和国家自然科学基金项目(32573279)

作者简介:贾宇琛(1979—),女,副教授,博士,主要从事农业电气化与自动化研究,E-mail:jiayuchen@163.com

daily communication volume by approximately 81%, and achieved an anomaly detection latency of less than 5.8 s. The proposed model was employed to predict environmental parameters such as temperature, humidity, and carbon dioxide concentration during network disconnections, yielding average root mean square error (RMSE) and mean absolute error (MAE) values of 0.243℃ and 0.194%, respectively, with an average coefficient of determination (R^2) exceeding 0.95. The synergistic mechanism of network status monitoring and data prediction effectively ensured data integrity during network interruptions and enhanced the accuracy of environmental regulation decisions.

Key words: henhouse environment; network disconnection detection; CNN - BiLSTM - Attention model; adaptive heartbeat mechanism; intelligent farming

0 引言

现代化养殖中,环境监测和调控对禽畜健康和生产效能至关重要[1]。然而,养殖场多位于偏远地区,网络基础设施薄弱,易受天气、地形及基站覆盖等因素影响,设备与服务器连接不稳定[2]。网络中断时关键环境信息丢失,导致监测系统数据缺失,造成调控系统不稳定[3]。失联状态降低了调控时效性和精度,导致环境参数偏离,引发热应激、呼吸道疾病等。据统计,环境管控不当导致的蛋鸡病死率高达 15% ~20%[4],对养殖可持续运营构成严重威胁。

网络通信保障是监测的一个重点,网络信号强度的监测与断网检测通常依赖心跳机制[5]。传统的心跳机制采用固定时间间隔,难以适应动态变化的网络环境。为此,研究者提出了自适应心跳机制[6],通过动态调整心跳间隔平衡实时性与能耗。具体实现方式多样:如结合 BP 神经网络[7]对网络状态进行趋势预测,预先调整心跳频率;二分法[8]应用于心跳间隔的搜索过程,通过快速收敛到最优值适应网络波动。在网络连接不可靠或间歇性中断的场景下,提高本地数据预测能力尤为重要。鸡舍环境具有以下特性:温度波动更为敏感,氨气积累速度更快,光照周期对生产性能影响显著。针对这些特点,Klotz 等[9]提出使用 LSTM 估计温度、湿度等;郭祥云等[10]将多种不同环境因素的时间序列数据作为输入,构建基于双阶段注意力机制的 LSTM 鸡舍氨气浓度预测模型,但其泛化能力和适应性不足。现有研究多集中于鸡舍中单一环境参数的静态分析,而针对多变量时序数据的动态预测模型仍有待深入探索[11]。CNN 以其卓越的局部特征提取能力在深度学习方法中著称,能够自动从复杂数据中挖掘关键空间特征[12]。然而,单一 CNN 模型难以捕捉长距离时序依赖关系,限制了其在时间序列预测中的精度。BiLSTM[13]由 2 个 LSTM 模型[14]组成,相比 CNN 能够更好地建模全局时序依赖,并通过双向学习(正向与反向)更有效地捕捉时序动态特征。但传统 BiLSTM 仍缺乏动态权重分配机制,可能导致关键时间步信息被忽略。为优化这一局限性,Attention[15-16]被引入时序预测模型。该机制通过动态权重分配使模型能够自适应聚焦于关键时间步,显著提升重要特征的提取能力。

综上所述,为解决鸡舍环境下网络连接不稳定导致断网数据流缺失的问题,提出一种心跳感知网络监测下鸡舍环境断联数据预测模型。首先,系统采用自适应心跳机制动态评估网络连接质量,并检测网络连通性。然后在判定网络中断后,系统对历史传感器数据进行预处理,并利用 Adam 优化算法结合早停策略等确定最优学习率及训练迭代次数。最后使用 CNN - BiLSTM - Attention 模型对数据进行预测。

1 数据断网预测系统整体框架

本研究在位于农村与高速交叉路口,网络基础建设较为薄弱的河北省石家庄市某养殖场开展实验,由于天气、地形等自然要素的影响,环境感知设备和目标服务器网络连接频繁出现异常状况,网络信号不佳。该鸡舍为立体叠层 H 型笼养蛋鸡舍,纵向长度为 90 m,横向宽度为 12 m,脊高为 5 m。鸡舍内部有 4 列鸡笼,5 个过道,饲养约 3.1 万只鸡。在鸡舍中共部署了 6 个传感器节点(用于采集温湿度、氧气浓度、二氧化碳浓度和大气压强)。设计了立体分层监测实验方案,如图 1 所示。在鸡舍纵向空间的 3 个等分区域(前、中、后区)部署传感器,实现环境参数的三维立体监测。

鸡舍环境监测系统通过本地与远程通信协同优化实现数据传输。终端节点(Endpoint)传感器采用 RS-485 和 LoRa 构建本地采集网络[17],边缘节点(Edge)部署本地数据库,承担数据存储与预处理功能,并作为终端与云平台的通信枢纽,采用 4G 模块搭载 MQTT 协议实现云端和边缘数据传输,建立云-边-端信息收集网络。

2 心跳感知与预测协同工作机制

自适应心跳机制与 CNN - BiLSTM - Attention

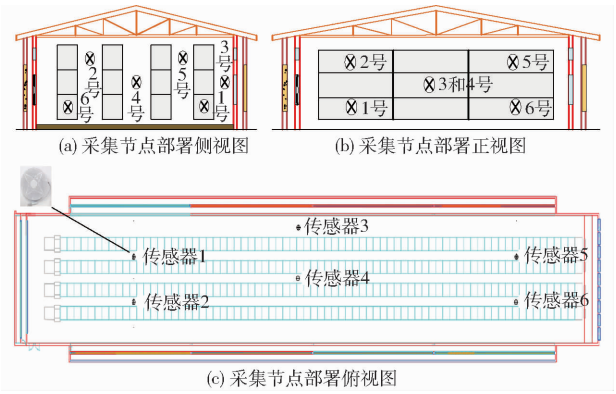

(a) 采集节点部署侧视图　(b) 采集节点部署正视图

(c) 采集节点部署俯视图

图 1　鸡舍内环境参数采集节点部署三视图

Fig. 1　Three views of deployment of environmental parameter acquisition nodes in henhouse

预测模型协同工作流程体现在 3 个方面，如图 2 所示。

(1)自适应心跳机制为预测模型提供触发信号。正常情况下，系统按周期发送心跳数据实时更新模型输入缓冲区。异常发生时，心跳机制判定网络断开，立即发出“断联触发信号”，指示连接状态变化，同时携带断网前的网络质量信息，为模型是否启动及如何初始化预测提供决策依据。

(2)模型根据历史数据进行预测。模型输入数据为断网前由心跳成功上传的完整时间序列。一旦接收到触发信号，模型立即启动，通过其内部组件的协同运算，输出未来一段时间的环境预测值，有效填补断联期间的数据空白。

(3)自适应机制优化系统资源与预测精度。在网络状况良好时，自适应延长心跳间隔，降低通信开销，保障数据上传稳定性。断网恢复后，系统将预测数据与实际值进行比较，预测误差作为反馈信号，进一步优化心跳机制的灵敏度与适应性。

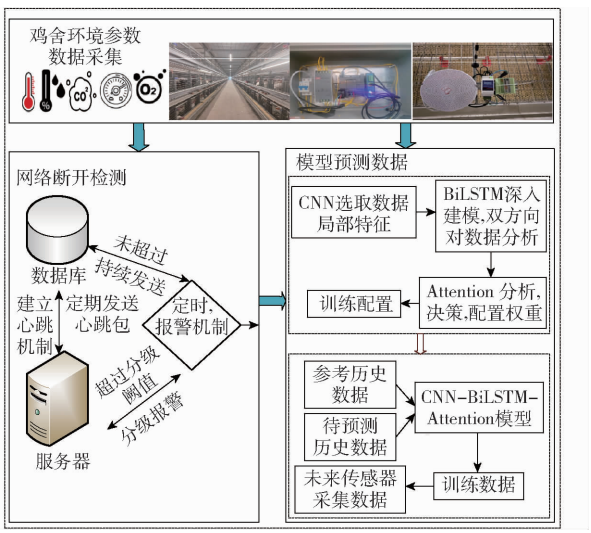

图 2　断网检测-预测框架

Fig. 2　Broken network detection - prediction framework

3　自适应心跳机制

在传感器网络中，节点常采用心跳机制实时监测网络状态。针对鸡舍监测网络低功耗、高灵敏度的要求，固定间隔难以适应动态网络变化，需构建自适应心跳机制，通过动态调整心跳包发送间隔、基于网络质量自动调节频率，降低通信开销并提升检测灵敏度。

3.1　自适应心跳检测

首先是生成心跳包。其中心跳包包含协议头部、序列号、时间戳以及设备 ID，其负载极小，不包含具体的环境数据。主要责任是服务端维护设备状态并执行超时判定。初始心跳间隔设定为 30 s。

然后，采用二分法搜索预设区间自适应选择最佳心跳间隔。网络性能评估采用离散化阈值划分策略：针对往返时延(RTT)和丢包率(PLR)分别建立量化区间，即

$$\begin{cases} r_i = t_{\text{ack}} - t_{\text{send}} \\ \bar{r} = \dfrac{\sum_{i=0}^{n-1} r_i}{n} \\ p = \left(1 - \dfrac{s_j}{f_z}\right) \times 100\% \end{cases} \tag{1}$$

式中　r_i——RTT 值

t_{ack}——发送端收到确认的时间戳

t_{send}——发送端发出数据包的时间戳

$\bar{r}$——RTT 平均值

p——丢包率

s_j——成功接收包数

f_z——发送总包数

n——参与计算样本个数

其中当 RTT 小于 200 ms，丢包率小于 2% 时判断为稳定阈值，当 RTT 不小于 500 ms，丢包率不小于 5% 时判断为不稳定阈值。具体步骤如下：

(1)参数定义

①设最大允许心跳为 $T_{\max}$，最小允许心跳为 $T_{\min}$，构成搜索区间 $[T_{\min}, T_{\max}]$。②初始测试 $t = (T_{\max} + T_{\min})/2$，目标心跳周期 T 为算法最终优化的输出值。

(2)设置动态调整策略

①网络稳定时：测试间隔 t 下响应时间低且丢包率低于阈值，逐步增大 t(记为 t^+)，趋近 $T_{\max}$。

$$t^+ = \begin{cases} \dfrac{t + T_{\max}}{2} & (\text{RTT 小于 200 ms}) \\ \leqslant T_{\max} & (\text{PLR 小于 2\%}) \end{cases} \tag{2}$$

②网络不稳定时：检测到高延迟或丢包率超阈值，减

小 t(记为 t^-),趋近 $T_{\min}$。

$$t^- = \begin{cases} \dfrac{t+T_{\min}}{2} & (\text{RTT 不小于 500 ms}) \\ \geqslant T_{\min} & (\text{PLR 不小于 5\%}) \end{cases} \tag{3}$$

(3)收敛性与效率

①二分法搜索快速逼近最优解,兼顾收敛性与稳定性。②最终目标函数 T 动态平衡网络可靠性与通信成本,网络连接良好时最大化优化心跳间隔。

二分法的时间复杂度为 $O(\lg n)$。达到了在能耗最低的条件下准确获取网络断点的目的。

3.2 云端心跳监听与处理

云边信息传输采用 MQTT 协议实现[18]。在云平台部署 MQTT Broker 作为消息代理,绑定 IP/端口监听连接。本地数据库作为客户端,通过 CONNECT 报文发起 TCP 长连接,并协商心跳间隔等参数。在客户端中按设定间隔向 Broker 发送心跳报文(PINGREQ),Broker 回复确认(PINGRESP)。若 Broker 在超时窗口内未收到心跳,则主动断开 TCP 连接,并记录最后活动时间戳,实时更新连接状态。

心跳包的定期发送和服务器端的时间戳记录保障系统清晰了解每个连接的活跃频率。其中 Broker 发送的报警信号分为 3 个等级。

第 1 等级,网络质量下降:检测到延迟增加或其他原因,提醒用户稳定降低。

第 2 等级,断网风险预警:若连接中心跳超过阈值,预警可能会出现断网。

第 3 等级,网络连接断开:当服务器判定连接的最后活动时间超过预设阈值,则触发断网告警。

其中第 1 等级的 RTT 区间为 200 ~ 500 ms,PLR 介于 3% ~ 7%;第 2 等级的 RTT 区间为 500 ~ 1 000 ms,PLR 范围为 7% ~ 10%;第 3 等级的 RTT 超过 1 000 ms,PLR 高于 10%。

当服务器检测到网络连接断开时,启动数据补偿传输流程(即运行 CNN - BiLSTM - Attention 模型),通过分级响应避免因短暂网络波动误触发高开销计算,降低平台负载。

3.3 心跳机制性能评估指标

在连接存活中,统计 MQTT Broker 维持的会话成功次数与理论应保持次数的比值,定义为存活率。通过解析 New client connected from 〈IP〉 as 〈clientID〉和 Client 〈clientID〉 disconnected 条目统计连接,判断存活率。在通信开销中,计算单位时间内传输的心跳包数量与单包大小的乘积,得到开销大小。通过解析技术量化通信开销,捕捉 Mqtt. type(心跳包)统计每分钟心跳包数量以及提取负载的字节[19]。从开始注入网络损伤信号到系统触发第 1 阶段告警的时间差来判断异常的信号。

使用网络损伤仪 Traffic Control Network Emulator(TC Netem),其中 TC Netem 是内核中流量控制模块,可以模拟网络环境中的各种异常情况,如延迟模拟:为数据包添加延迟时间来模拟长距离网络连接或者网络信号不佳导致的传输延迟。丢包模拟:按照一定概率的丢包率来测试在丢包环境下的网络连接和数据重传机制。

4 基于 CNN - BiLSTM - Attention 的数据预测模型

融合 CNN、BiLSTM 和 Attention 的特性构建 CNN - BiLSTM - Attention 深度学习模型[20],如图 3 所示。在该模型中,BiLSTM 为核心架构,通过其双向时序处理能力(正向和反向)有效捕捉温度、相对湿度、二氧化碳浓度等环境参数的长周期动态关联特征。

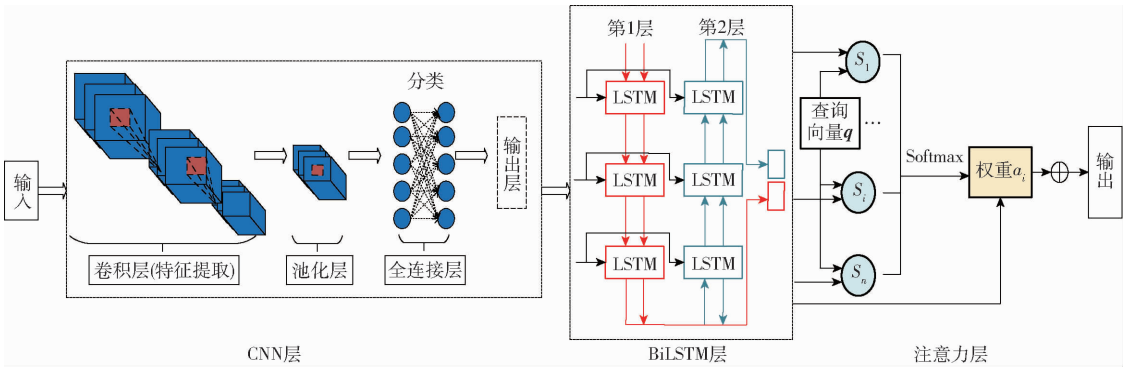

图 3 CNN - BiLSTM - Attention 预测模型结构框架

Fig. 3 Structural framework of CNN - BiLSTM - Attention prediction model

在采用 BiLSTM 模型对鸡舍传感器数据进行初步处理和分析后,发现在两方面存在局限:①原始数据中的局部模式(如温度骤变、相对湿度短时波动)因缺乏空间特征提取能力而被平滑化。②长序列中

关键时间点(如清晨通风时段)的影响易被均摊。通过分析模型各层输出,发现浅层 BiLSTM 对局部异常特征的响应较弱,而深层输出虽包含全局信息却未突出关键时段。

为弥补 BiLSTM 在局部特征提取上的不足,引入 CNN 进行前置特征优化,通过卷积层提取局部特征,利用池化层压缩特征维度,对原始数据进行空间特征提取和维度压缩,生成具有更强表征能力的特征图输入 BiLSTM。针对 BiLSTM 对时序关键信息敏感度不足的问题,集成注意力机制,通过动态权重分配策略对 BiLSTM 输出的时序特征进行自适应加权,提升对环境关键影响因子聚焦能力。

在模型架构的注意力层中,采用了加性软注意力机制,该机制能够自适应地学习不同时间步特征的重要性权重,有效抑制无关时间步的噪声干扰,同时增强对关键时序特征的敏感性。该机制的实现流程包含 5 个核心阶段:首先,将 BiLSTM 的输出序列作为输入;其次,通过加性评分函数计算各时间步的注意力得分;接着,利用 Softmax 函数将得分归一化为概率分布;然后,基于注意力权重生成上下文向量;最终,通过全连接层输出预测结果。该设计在混合架构中实现了计算效率与特征提取能力的优化平衡。三者结合,层层递进,分别承担特征提取、时序建模和特征优化的功能,最终生成能精准反映鸡舍实际环境状态的综合性输出。

4.1　模型滚动预测机制与运行流程

模型滚动预测机制与整体流程如图 4 所示。CNN－BiLSTM－Attention 算法求解过程如下:采用滑动时间窗口的数据更新策略,选取断网时刻前 7 d 历史数据(168 h)作为初始输入序列,当断网时间不超过 24 h 时,延续使用初始数据窗口,当断网超过 24 h,自动纳入前 24 h 的预测数据,并滚动更新输入窗口为[$T-6$ d 至 $T-1$ d 实测数据]+[最新 24 h 预测数据]。

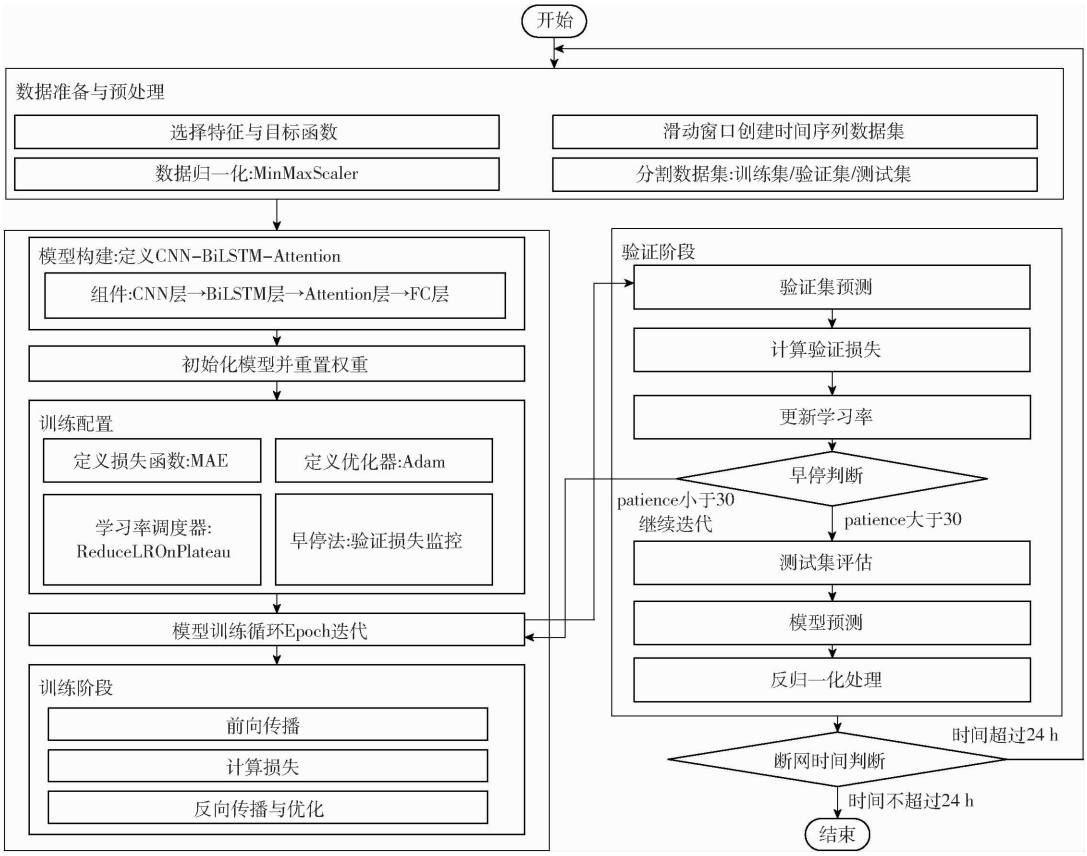

图 4　模型滚动预测机制与运行流程

Fig. 4　Model rolling prediction mechanism and operation process

4.2　模型参数优化

对原始数据的预处理包括去除重复数据、处理缺失值和纠正错误数据,中值滤波降噪处理[21]。针对温度这类一维时序数据,采用窗口长度为 3 的一维中值滤波进行平滑去噪。滤波完成后,进行归一化处理,有助于模型更好地学习特征之间的关系,提高模型的性能和泛化能力。

将数据集按照 60%、20% 和 20% 比例划分为训练集、验证集和测试集。其中,卷积层用于提取局部特征,设置卷积核数量为 64,尺寸为 3,步长为 1;BiLSTM 层用于捕捉时序依赖,隐藏层单元数设为 128,并引入丢弃率为 0.2 的 Dropout 层以防止过拟

合;注意力机制的维度设置为 256。

在优化策略上,选择对异常值不敏感的平均绝对误差作为损失函数(Loss function)[22]。模型采用 Adam 优化器进行参数更新,该优化器结合了动量法和 RMSProp 的优点,兼顾收敛速度与稳定性[23]。配合使用了 ReduceLROnPlateau 学习率调度器[24],当验证集损失连续 5 个周期(epoch)未下降时,学习率自动缩减为原来的 0.1 倍,有助于模型在训练后期逼近最优解。

迭代次数与早停法[25]共同决定了训练的终止条件。当验证集在损失连续若干个周期内都没有变化时,则触发早停。定义耐心参数 patience 为 30。从图 5 可知,随着迭代次数的增加,训练集损失值和验证集损失值都逐渐减小,在训练后面趋于平稳,在迭代次数 1 200 左右时,损失值不再变化。

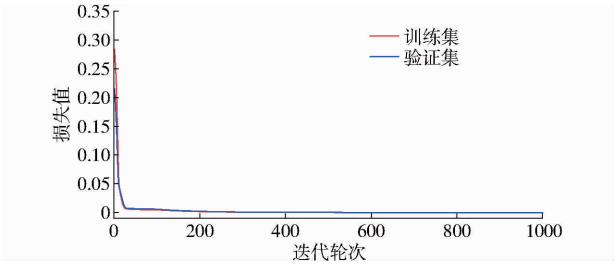

图 5 训练集损失值和验证集损失值变化曲线

Fig. 5 Loss curves for training set and validation Set

本文采用均方根误差(RMSE)、平均绝对误差(MAE)和 R^2 反映模型的性能。其中 RMSE 和 MAE 越小,模型的预测值和真实值越接近,R^2 越接近于 1,模型对鸡舍环境数据的拟合程度越好。

5 算例分析

5.1 自适应心跳机制实验结果分析

在模拟养殖场物联网场景中,在不同位置部署 6 个传感器节点,使用网络损伤仪 TC Netem(在实验中注入不同级别的延迟(50 ~ 1 200 ms)和丢包率(0% ~15%))进行 72 h 连续监测。比较固定心跳间隔(1 s、30 s 和 60 s)与自适应机制(初始间隔为 30 s,T_{max} = 60 s 和 T_{min} = 1 s)性能。

通过表 1 数据可知,在连接可靠性上,自适应策略以 99.3% 的存活率与最优的固定 1 s 间隔(99.8%)相当,显著优于固定 30 s(98.2%)和 60 s 间隔(95.1%)。通信效率上,自适应机制日均仅需 1 762 次心跳,较固定 1 s 间隔减少 98.8% 的通信量,比 30 s 间隔降低了 63.1%。在异常检测性能上,自适应机制 5.8 s 的检测延迟虽比 1 s 间隔慢 4.7 s,智能调节机制可在网络恶化时将延迟降至 3.2 s。根据实际监测数据,10 月份鸡舍环境监测过程中,系统共检测到 6 次网络中断事件,累计 23 h 的环境监测数据缺失。

表 1 不同心跳间隔策略性能对比

Tab. 1 Performance comparison of different heartbeat interval strategies

评估指标	间隔 1 s	间隔 30 s	间隔 60 s	自适应
连接存活率/%	99.8	98.2	95.1	99.3
日均心跳包数量	86 400	2 880	1 440	1 762
异常检测延迟/s	1.1	8.2	15.7	5.8

5.2 算法性能分析

选取石家庄市某鸡舍中 2024 年 4 月、2024 年 7 月及 2024 年 10 月各 7 d 的实际监测数据作为样本,6 个传感器同步采集温度、相对湿度、大气压强、二氧化碳浓度与氧气浓度等多维度数据。考虑到各传感器的空间分布差异可能影响数据特征,为确保预测结果的严谨性,实验特选定 1 号传感器的温度、2 号传感器的相对湿度、3 号传感器的大气压强、4 号传感器的二氧化碳浓度以及 5 号传感器的氧气浓度构建具有代表性的数据集。

5.2.1 环境参数的影响与对比

鸡舍环境变化对鸡只的影响程度因参数不同而异[26],温度每小时变化不超过 ±1℃;相对湿度每小时波动幅度在 ±5% 以内;大气压强每日变化限值为 ±1 kPa;二氧化碳浓度每小时允许波动 ±500 μmol/mol;氧气浓度每小时波动范围不应超过 ±0.3%。计算实际监测值与预测值平均偏差,24 h 均值为日平均偏差值。

根据表 2 可知,所有预测数据的误差均控制在安全波动阈值范围内,验证了预测模型的可靠性。

表 2 预测值与实际值的平均误差

Tab. 2 Average error between predicted value and actual value

参数	4 月	7 月	10 月
温度误差/℃	0.009 2	0.017 42	-0.049 2
相对湿度误差/%	-0.084 3	-0.054 8	-0.084 8
大气压强误差/kPa	0.002 5	0.015 1	0.000 7
二氧化碳浓度误差/(μmol·mol^{-1})	21.579 8	2.182 1	10.033 2
氧气浓度误差/%	-0.000 2	0.024 9	-0.000 2

5.2.2 模型数据分析

数据预处理后输入至模型中,其中测试集占总样本的 20%,共 3 000 条。实验结果表明,本文所提模型的预测值与真实值之间的误差更小,评价指标表现出更好的精确度,如表 3 所示。

为展示本文所采集数据以及模型的优越性,将 CNN - BiLSTM、BiLSTM 和 ARIMA(是一种经典的时

表 3　CNN－BiLSTM－Attention 方法的性能评价指标

Tab. 3　Performance evaluation index of CNN－BiLSTM－Attention method

参数	RMSE			MAE			R^2		
	4 月	7 月	10 月	4 月	7 月	10 月	4 月	7 月	10 月
温度	0.243 8℃	0.154 4℃	0.152 8℃	0.162 6℃	0.103 5℃	0.112 6℃	0.988 4	0.994 6	0.990 2
相对湿度	0.407 4%	0.457 2%	0.435 1%	0.309 4%	0.275 3%	0.392 9%	0.974 5	0.996 1	0.977 3
大气压强	0.024 9 kPa	0.037 8 kPa	0.027 8 kPa	0.017 3 kPa	0.023 8 kPa	0.020 4 kPa	0.995 1	0.966 4	0.995 2
二氧化碳浓度	0.687 8 μmol/mol	0.631 4 μmol/mol	0.843 2 μmol/mol	0.528 7 μmol/mol	0.380 4 μmol/mol	0.478 6 μmol/mol	0.963 1	0.958 5	0.945 4
氧气浓度	0.021 5%	0.057 9%	0.008 4%	0.008 1%	0.083 2%	0.017 9%	0.858 6	0.832 8	0.865 9

间序列预测模型，能够有效地捕捉时间序列数据中的趋势、季节性和随机性）的采集预测效果与 CNN－BiLSTM－Attention 进行对比。其中 BiLSTM 和 CNN－BiLSTM的学习率和迭代次数与本文模型参数一致。所有传感器参数的平均指标 RMSE 为 0.243℃，MAE 为 0.194℃，R^2 为 0.95 以上，综合预测准确率在 98.5% 以上。为了更加方便地看出模型的优良性，对其评价指标进行可视化展示。这里采用 1 号传感器采集到的温度来举例。

如图 6 所示，基于 1 号传感器温度数据的实验结果表明，CNN－BiLSTM－Attention 模型在不同月份均展现出优异的预测性能。在 10 月的测试中，该模型的 R^2 达到 0.990 2，显著优于 CNN－BiLSTM（0.974 9）、BiLSTM（0.970 9）和 ARIMA（0.954 5）等对比模型。同时，其 RMSE（0.152 8℃）和 MAE（0.112 6℃）指标也明显低于对比模型，显示出更好的预测精度。7 月的实验结果显示 CNN－BiLSTM－Attention 模型达到最佳性能，其 R^2（0.994 6）、RMSE（0.154 4℃）和 MAE（0.103 5℃）均优于其他月份的表现。相比之下，4 月的预测结果相对较弱（R^2 = 0.988 4，RMSE 为 0.243 8℃，MAE 为 0.162 6℃），这可能与季节性气候因素对温度数据的影响有关。尽管如此，该模型在 4 月的表现仍然优于 CNN－BiLSTM、BiLSTM 和 ARIMA 等基准模型。通过不同月份温度对比，得出 RMSE 均值为 0.183℃ 和 MAE 均值为 0.126℃，都高于其他模型。

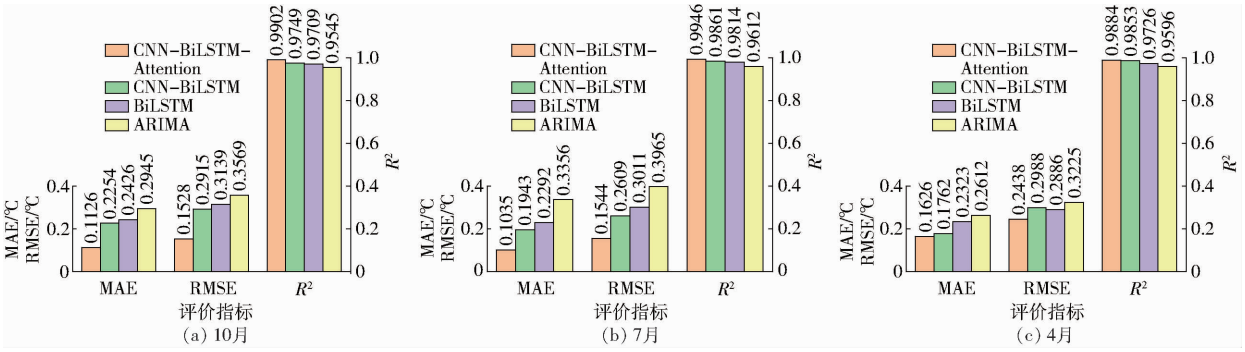

图 6　温度评价指标对比

Fig. 6　Comparison of temperature evaluation indexes

为定量评估 CNN－BiLSTM－Attention 模型的预测性能，将其与 CNN－BiLSTM、BiLSTM 及 ARIMA 模型在相同测试集上进行了对比。各模型在 1 号传感器温度数据上的预测曲线对比如图 7、8、9 所示。

分析图 7 所示的 4 月典型时间区间温度预测结果可见，在该时段采集的 100 个数据中，第 30 个到 40 个周期内，CNN－BiLSTM－Attention 模型预测曲线与真实值最为吻合。其 RMSE（0.243 8℃）较 CNN－BiLSTM、BiLSTM 和 ARIMA 分别降低 18.4%、15.5% 和 24.4%，且 R^2 最高（0.988 4），表明注意力机制能有效提升对春季复杂波动的捕捉能力，本文所提模型在细节与极值捕捉上优势显著。

7 月温度变化平缓，各模型性能均较好。但 CNN－BiLSTM－Attention 仍取得最佳拟合优度，R^2 达 0.994 6，MAE 为 0.103 5℃。在 55 到 60 的采集点数量的短期温度峰值处，ARIMA 预测出现明显平滑滞后，BiLSTM 预测值略偏低，而本文模型与 CNN－BiLSTM 均准确捕捉到峰值，且本文模型预测值最接近真实值，印证了 CNN 与 Attention 机制在关键特征提取上的协同作用。

在 10 月波动最频繁的测试期内，CNN－BiLSTM－Attention 的优越性最为突出。其预测曲线与真实值几乎重叠，尤其在第 60 个数据点周围快速升降区间，其他模型则出现不同程度滞后或振幅削弱。量化数据显示，其 RMSE（0.152 8℃）较次优

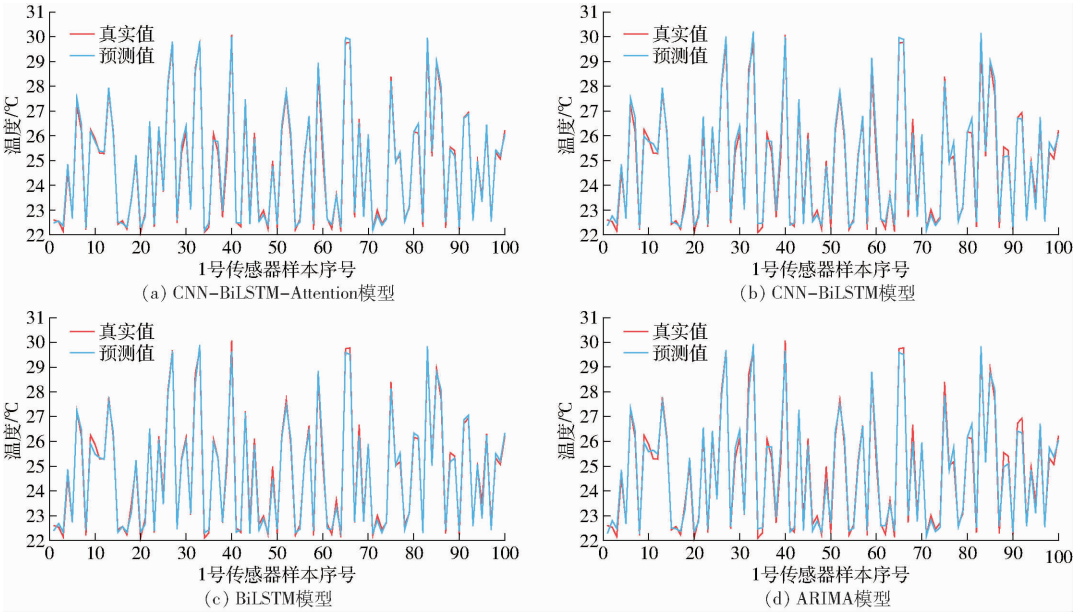

图 7 4 月模型预测对比效果

Fig. 7 Comparison of model prediction effects in April

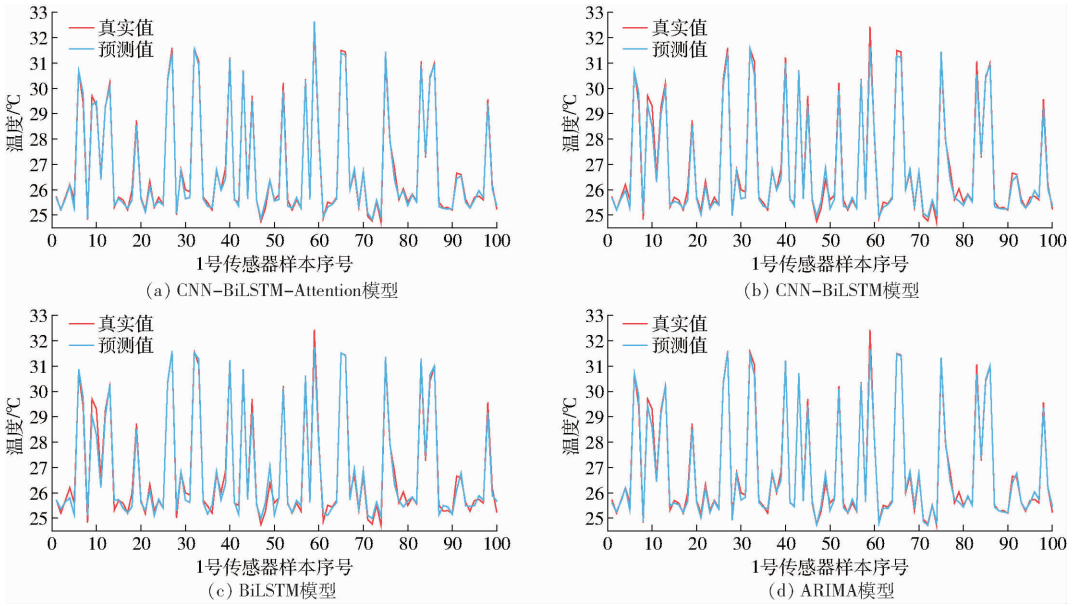

图 8 7 月模型预测对比效果

Fig. 8 Comparison of model prediction effects in July

的 CNN - BiLSTM 模型进一步降低约 47.5%，证明该混合模型对非线性、强波动数据具有最强的时序特征提取与关键信息聚焦能力。

综上所述，结合量化指标与预测曲线可知，CNN -BiLSTM - Attention 模型在所有测试场景下均表现最优，尤其在捕捉细节与极值方面优势明显。虽然湿度预测比温度预测数据对比稍有欠缺，但 CNN - BiLSTM - Attention 模型相较于现有方法仍能提供更准确且稳定的预测性能。观测到的性能差异可能源于相对湿度动态变化较温度模式具有更高的内在复杂性。模型在不同季节条件下都能保持稳定的预测性能，且显著优于传统时间序列预测方法和单一神经网络模型。其卓越性能源于模型的协同设计：CNN 提取局部特征，BiLSTM 建模长时序依赖，而 Attention 机制则动态聚焦于关键历史时刻，从而实现了更精准的预测。

6 结论

(1)针对养殖场鸡舍环境监测网络不稳定的问题，提出了一种融合自适应心跳机制与 CNN - BiLSTM - Attention 预测模型的鸡舍环境数据精准监测方法。

(2)为了提高鸡舍环境监测系统可靠性，建立了自适应心跳机制与云平台数据预测模型协同工

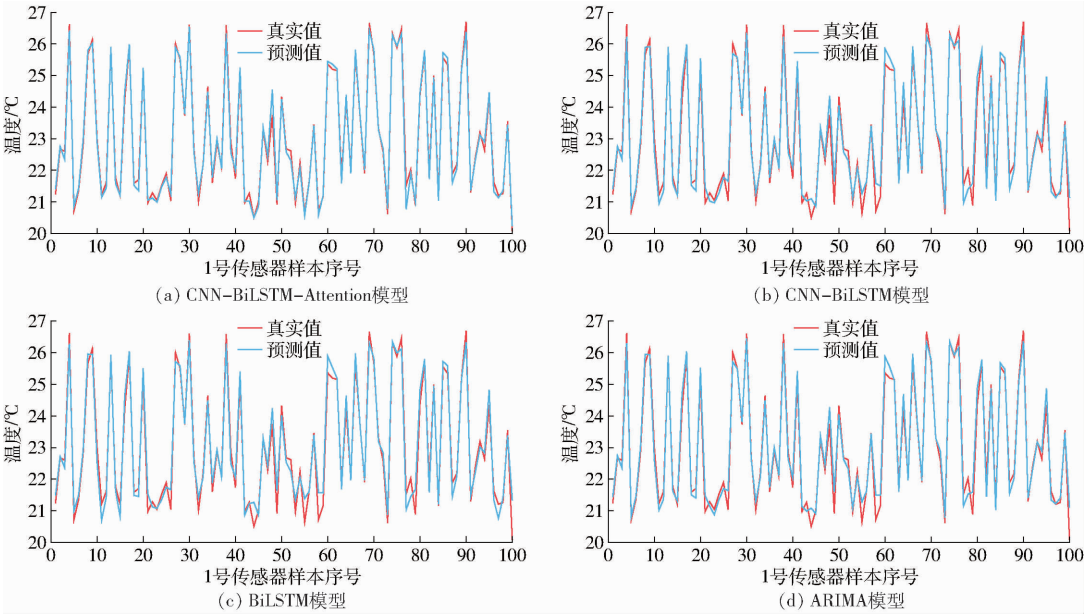

图 9　10 月模型预测对比效果

Fig. 9　Comparison of model prediction effects in October

作机制，实现了断网后系统依然能够持续提供数据，保障了断网情况下的数据完整性。模拟实验表明，自适应心跳机制在降低通信量 98% 情况下，网络恶化时将延迟时间降至 3.2 s；采用早停法与 Adam 优化器结合 ReduceLROnPlateau 调度器，实现了模型参数的动态调整，同时使模型迭代次数减少。

(3)为了提高数据预测模型性能，融合 CNN - BiLSTM - Attention 能力构建的组合模型展现出卓越的预测能力。对比实验表明，该模型在 RMSE(温度 0.183℃)和 MAE(温度 0.126℃)等其他环境参数指标上均优于 CNN - BiLSTM、BiLSTM 和 ARIMA 模型，实现温度(误差为 0.02℃)、相对湿度(误差为 0.07%)、大气压强(误差为 0.01 kPa)等环境参数的高精度预测，各项指标的 R^2 均保持在 0.95 以上，预测准确率保持 98.5% 以上。

参　考　文　献

[1] 沈明霞，刘龙申，闫丽，等. 畜禽养殖个体信息监测技术研究进展[J]. 农业机械学报，2014，45(10)：245 - 251.
Shen Mingxia，Liu Longshen，Yan Li，et al. Review of monitoring technology for animal individual in animal husbandry[J]. Transactions of the Chinese Society for Agricultural Machinery，2014，45(10)：245 - 251.（in Chinese）

[2] 李龙. 基于高速铁路场景的无线通信网络质量评估与建设模式比较[D]. 南昌：南昌大学，2019.
Li Long. Quality evaluation and comparison of construction modes of wireless communication network based on high-speed railway scenario[D]. Nanchang：Nanchang University，2019.（in Chinese）

[3] 孟超英，王佳，陈红茜，等. 基于分布式对象的蛋鸡舍设施养殖数字化智能监测系统[J]. 农业机械学报，2017，48(10)：292 - 299.
Meng Chaoying，Wang Jia，Chen Hongqian，et al. Intelligent monitoring system based on distributed object for layer house[J]. Transactions of the Chinese Society for Agricultural Machinery，2017，48(10)：292 - 299.（in Chinese）

[4] 李保明，王阳，郑炜超. 我国规模化养鸡环境控制技术的最新进展[J]. 中国家禽，2019，41(9)：1 - 7.
Li Baoming，Wang Yang，Zheng Weichao. Advances in environment control technology of poultry in China[J]. China Poultry，2019，41(9)：1 - 7.（in Chinese）

[5] Cui X，Ma Z. Dynamic heartbeat detection algorithm based on RBFNN[J]. Journal of Engineering，2019，2019(20)：6426 - 6428.

[6] 刘军，柳雷. 一种基于 BP 神经网络的 MQTT 自适应心跳机制分析[J]. 电子技术，2024，53(6)：1 - 4.
Liu Jun，Liu Lei. Design of an adaptive heartbeat mechanism for MQTT based on BP neural network[J]. Electronic Technology，2024，53(6)：1 - 4.（in Chinese）

[7] Ma W. The study of computer network fault diagnosis and maintenance[J]. Electronic Science and Technology，2010，23(12)：84 - 85.

[8] 栗永胜，崔佳冬，秦会斌. 一种自适应心跳间隔保活 TCP 连接的方法[J]. 计算机应用与软件，2018，35(1)：149 - 153.
Li Yongsheng，Cui Jiadong，Qin Huibin. A method of adaptive hear beat interval to keep TCP connection alive[J]. Computer Applications and Software，2018，35(1)：149 - 153.（in Chinese）

[9] Klotz D F，Ribeiro R，Enembreck F，et al. Estimating and tuning adaptive action plans for the control of smart interconnected

poultry condominiums[J]. Expert Systems with Applications, 2022,187: 115876.
[10] 郭祥云, 连京华, 李慧敏, 等. 基于双阶段注意力机制和 LSTM 的鸡舍氨气浓度预测算法[J]. 中国农业大学学报, 2021,26(6): 187 - 195.
Guo Xiangyun, Lian Jinghua, Li Huimin, et al. Ammonia concentration forecasting algorithm in layer housebased on two stage attention mechanism and LSTM[J]. Journal of China Agricultural University, 2021,26(6): 187 - 195. (in Chinese)
[11] 王聆汐, 李丽华, 贾宇琛, 等. 基于 SSA - CNN - LSTM 的蛋鸡舍二氧化碳排放量预测研究[J]. 中国家禽, 2025, 47(6): 88 - 98.
Wang Lingxi, Li Lihua, Jia Yuchen, et al. Based on SSA - CNN - LSTM method for predicting CO_2 emissions in layer house [J]. China Poultry, 2025,47(6): 88 - 98. (in Chinese)
[12] 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)
[13] Sang S, Li L. A stock prediction method based on heterogeneous bidirectional LSTM[J]. Applied Sciences, 2024,14(20): 9158.
[14] 王子航, 常晗, 张瑶, 等. 基于 CNN - LSTM 的苹果树种植区域提取[J]. 农业机械学报, 2024,55(增刊 2): 277 - 285.
Wang Zihang, Chang Han, Zhang Yao, et al. Apple planting area extraction based on improved CNN - LSTM model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(S2): 277 - 285. (in Chinese)
[15] 王家乐, 张耀, 林帆, 等. 基于自注意力特征提取的光伏功率组合概率预测[J]. 太阳能学报,2024,45(12): 123 - 131.
Wang Jiale, Zhang Yao, Lin Fan, et al. Combining probabilistic prediction of PV power based on self-attention feature extraction mechanism[J]. Acta Energiae Solaris Sinica, 2024,45(12): 123 - 131. (in Chinese)
[16] 邹一波, 周泽政, 陈明, 等. 基于注意力机制的植物三维点云语义分割方法[J]. 农业机械学报, 2025,56(3): 129 - 139.
Zou Yibo, Zhou Zezheng, Cheng Ming, et al. 3D plant point cloud semantic segmentation method APSegNET based on attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(3): 129 - 139. (in Chinese)
[17] 曾志雄, 董冰, 吕恩利, 等. 猪舍环境无线多点多源远程监测系统设计与试验[J]. 农业机械学报, 2020,51(2): 332 - 340.
Zeng Zhixiong, Dong Bing, Lü Enli, et al. Design and experiment of wireless multi-pointand multi-source remote monitoring system for pig house environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(2): 332 - 340. (in Chinese)
[18] 温彬民. 一种基于自适应心跳机制的 MQTT 通信协议的研究与应用[D]. 广州: 华南理工大学, 2015.
Wen Binmin. A research and application of MQTT protocol base on adaptive heartbeat mechanism[D]. Guangzhou: South China University of Technology, 2015. (in Chinese)
[19] 彭玉兰, 代琪怡, 李佳芮, 等. 基于 GNS3 + Wireshark 的网络协议分析实验教学改革[J]. 现代信息科技, 2022, 6(18): 185 - 187.
Peng Yulan, Dai Qiyi, Li Jiarui, et al. Experimental teaching reform of network protocol analysis based on GNS3 + Wireshark [J]. Modern Information Technology, 2022,6(18): 185 - 187. (in Chinese)
[20] 孟宏宇, 张建良, 蔡兆龙, 等. 基于 CNN - BiLSTM - Attention 的直流微电网故障诊断研究[J]. 中国电机工程学报, 2025,45(4): 1369 - 1381
Meng Hongyu, Zhang Jianliang, Cai Zhaolong, et al. Research on DC microgrid fault diagnosis based on CNN - BiLSTM - Attention[J]. Proceedings of the CSEE, 2025,45(4): 1369 - 1381. (in Chinese)
[21] 牛冲. 不同窗口下中值滤波与加权滤波方法效果分析[J]. 测绘科学, 2021,46(8): 21 - 27.
Niu Chong. Effect analysis of median filtering and weighted filtering under different windows[J]. Science of Surveying and Mapping, 2021, 46(8): 21 - 27. (in Chinese)
[22] 桂彦, 叶文倩, 王建新, 等. 基于 CNN 和尺度自适应 Transformer 融合网络的路面裂缝分割方法[J]. 中国公路学报, 2024,37(12): 418 - 432.
Gui Yan, Ye Wenqian, Wang Jianxin, et al. CNN and scale adaptive Transformer fusion network for pavement crack segmentation[J]. China Journal of Highway and Transport, 2024,37(12): 418 - 432. (in Chinese)
[23] Zhang W, Niu L, Zhang D, et al. HW - ADAM: FPGA - Based accelerator for adaptive moment estimation[J]. Electronics (Basel), 2023,12(2): 263.
[24] Mahesh T R, Thakur A, Gupta M, et al. Transformative breast cancer diagnosis using CNNs with optimized reduce on plateau and early stopping enhancements[J]. International Journal of Computational Intelligence Systems, 2024,17(1): 1 - 18.
[25] Miseta T, Fodor A, Vathy-Fogarassy Á. Surpassing early stopping: a novel correlation-based stopping criterion for neural networks[J]. Neurocomputing, 2024,567: 127028.
[26] 袁海航, 李海花, 晏婷, 等. 冬季鸡舍环境因子对蛋鸡生产性能、蛋品质及血液指标的影响研究[J]. 中国家禽, 2023, 45(3): 71 - 78.
Yuan Haihang, Li Haihua, Yan Ting, et al. Effects of environmental factors in chicken house in winter on production performance, egg quality and blood indexes of laying hens[J]. China Poultry, 2023,45(3): 71 - 78. (in Chinese)