

基于 WRN_x 的电动拖拉机犁耕作业牵引负载等级 辨识模型

仝一锟¹ 鄢玉林² 李明生² 温昌凯^{1,3} 谢斌^{1,3} 宋正河^{1,3}

(1. 中国农业大学工学院, 北京 100083; 2. 西南大学工程技术学院, 重庆 400716;

3. 智能农业动力装备全国重点实验室, 北京 100083)

摘要: 针对电动拖拉机犁耕作业牵引负载辨识不准确、训练过程依赖海量标记数据的问题, 提出了基于半监督学习算法的电动拖拉机犁耕作业多工况参数融合训练框架, 构建了基于宽残差网络和扩展长短时记忆网络 (WideResNet-xLSTM, WRN_x) 的电动拖拉机牵引负载等级辨识模型。其中, 半监督学习框架使用有、无标签数据进行辨识模型的迭代训练, 并应用 C-means 模糊聚类分析模型的线性输出; 基于 WRN_x 组合模型, 通过 WideResNet 的特征表达能力深入提取载荷数据的有效特征, 通过 xLSTM 网络处理时序关系, 最终通过分类器对载荷序列实现分类预测。构建了电动拖拉机犁耕机组多传感器载荷参数测试系统, 并开展了犁耕作业田间试验。结果表明, 所提出的半监督学习框架可减少 25.4% 的标记数据训练样本, 优于传统的监督学习训练框架, 所构建模型辨识电动拖拉机犁耕作业牵引等级的准确率和 F1 值分别为 94.35% 和 94.27%。研究结果为电动拖拉机犁耕作业负载半监督学习辨识提供了新的解决方案。

关键词: 电动拖拉机; 牵引负载; 智能辨识; 半监督学习; 深度学习; WRN_x

中图分类号: S24; S219.1 文献标识码: A 文章编号: 1000-1298(2025)06-0286-10

OSID:



Traction Load Grade Identification Model for Plowing Operations of Electric Tractors Based on WRN_x

TONG Yikun¹ YAN Yulin² LI Mingsheng² WEN Changkai^{1,3} XIE Bin^{1,3} SONG Zhenghe^{1,3}

(1. College of Engineering, China Agricultural University, Beijing 100083, China

2. College of Engineering and Technology, Southwest University, Chongqing 400716, China

3. National Key Laboratory of Intelligent Agricultural Power Equipment, Beijing 100083, China)

Abstract: Aiming at the problems of inaccurate traction load recognition in electric tractor plowing and cultivating operation and the dependence of the training process on massive labeled data, a training framework based on semi-supervised learning algorithm for fusion of multiple working condition parameters in electric tractor plowing and cultivating operation was proposed, and a model for electric tractor traction load grade recognition based on wide residual network and extended long and short-term memory network (WideResNet-xLSTM, WRN_x) was constructed. Among them, the semi-supervised learning framework used two kinds of data, labeled and unlabeled, for the iterative training of the discriminative model, and applied C-means fuzzy clustering to analyze the linear output of the model; based on the WRN_x combinatorial model, the effective features of the load data were deeply extracted through the feature expression capability of WideResNet, and the temporal relationship was processed through the xLSTM network, and finally, the load sequence was realized by the classifier for classification prediction. A multi-sensor load parameter testing system for electric tractor plowing and tilling units was constructed and field tests for plowing and tilling operations were carried out. The results indicated that the semi-supervised learning framework proposed can reduce the training sample requirement of labeled data by 25.4%, which was better than the traditional supervised learning training framework, and the accuracy

收稿日期: 2025-03-20 修回日期: 2025-04-18

基金项目: 国家自然科学基金项目(32301719)和重庆市技术创新与应用发展专项重点项目(cstc2021jscx-gksb0003)

作者简介: 仝一锟(1997—),男,博士生,主要从事新能源农机装备智能化研究,E-mail: tyk18438607957@163.com

通信作者: 温昌凯(1994—),男,副教授,博士,主要从事新能源农机装备智能化研究,E-mail: changkai.wen@cau.edu.cn

and F1-score of the model constructed for recognizing the hauling class of electric tractor plowing and cultivating operation were 94.35% and 94.27%, respectively. The research result can provide a solution for semi-supervised learning to recognize the load of electric tractor plowing operation.

Key words: electric tractor; traction load; intelligent recognition; semi-supervised learning; deep learning; WRN_x

0 引言

近年来,我国不断加大新能源技术研发投入,新能源农机装备应用逐步得到深化,市场规模有望实现爆发式增长^[1-2]。农业农村部印发的《全国农业科技创新重点领域(2024—2028年)》明确聚焦研发新能源拖拉机等大型高端智能农机^[3]。电动拖拉机作为高效智能环保农业动力机械的典型代表,在备受研究者、制造厂家和农业从业人员关注的同时,也伴随着随机农业环境激励下的整机工况适应性和作业效率发挥等问题,制约其进一步实现产业化应用^[4-10]。

田间作业时,电动拖拉机需挂载各类农具完成必需的耕作作业,其中,犁耕是耕整地作业中典型的重负载工况,需要电动拖拉机提供足够的驱动力^[11]。牵引性能是评价电动拖拉机牵引作业过程动力性的核心指标,主要包括标定牵引力、标定牵引功率和牵引效率等参数^[12]。现阶段,传统方法无法准确捕捉这些参数,导致控制策略不精准,影响作业质量和效率。监督学习需使用大量标记数据来训练模型,模型泛化能力差。针对电动拖拉机犁耕作业牵引负载辨识不准确、训练过程依赖海量标记数据的问题,本文研究的牵引负载等级辨识方法用于电动拖拉机牵引性能与作业负荷分析,将电动拖拉机犁耕作业的牵引负载可视化,并评估其实时作业可靠性,有助于优化电动拖拉机关键结构和控制系统,从而提升田间犁耕作业的质量与效益^[13-14]。电动拖拉机犁耕机组在田间作业时,受土壤条件、农业要求等因素限制,作业机组牵引负载呈现大幅值、宽频域以及非稳态等特点,直接影响机组动力输出特性和能量传递效率。并且,牵引负载时变特性会通过作业机组的机体运行、悬挂牵引以及驱动传动等系统的工况参数直接体现^[15-16]。因此,多参数(通道)实测工况数据中包含了大量可描述不同牵引负载等级下的载荷特性与整机特征,通过挖掘和分析典型特征可有效地对当前所处的牵引负载等级进行分类辨识^[17-18]。

在农机装备领域,基于多源数据,结合机器学习或者深度学习理论,对机器牵引负载、作业性能以及耕作质量的分析、辨识、预测研究尚在起步阶段。温

昌凯等^[19]为了解决拖拉机田间试验数据不足、机组作业质量无法实时评估与准确预测的问题,提出了基于BP神经网络与遗传算法的旋耕作业质量预测模型,预测精度96.77%。李淑艳等^[20]为准确识别旋耕作业质量,基于拖拉机多传感器的实测载荷数据,构建了格拉姆角场和深度卷积神经网络融合的智能辨识模型,旋耕作业试验的预测准确率达到96.186%。WEN等^[21]基于多头注意力机制和长短时记忆网络,提出了一种拖拉机载荷谱高工作强度负载段辨识模型,准确率达到97.69%。LI等^[22]为了辨识拖拉机旋耕作业质量等级,基于自注意力机制和反向卷积长短时记忆网络,提出了一种拖拉机旋耕作业等级辨识模型,准确率达到97.40%。上述研究证明多源异构传感器的数据融合可实现研究对象某一参数或者某一性能的准确分析^[23]。但以上研究大多以旋耕作业工况为对象,对于电动拖拉机犁耕作业典型时变非稳态特性的适用性与泛化性能仍有待研究。

本文提出基于半监督学习算法的电动拖拉机犁耕作业多工况参数融合训练框架,构建基于WideResNet-xLSTM(WRN_x)的电动拖拉机牵引负载等级辨识模型,构建电动拖拉机犁耕机组多传感器载荷参数测试系统,并开展犁耕作业田间试验进行综合性能验证。通过半监督学习框架对有、无标签数据进行辨识模型迭代训练,使用WideResNet深入提取载荷数据的局部特征和时序特征。最终,依据犁耕作业牵引负载分级标准,通过分类器对载荷序列进行分类预测。依据评价指标对该模型的预测效果进行验证,分析评价半监督学习有标签数据数量对分类准确性等指标的影响,并与WideResNet、xLSTM、CNN-xLSTM等进行对比,综合评估不同算法的预测性能,以期电动拖拉机犁耕作业负载分析提供参考。

1 电动拖拉机犁耕测试与负载等级

1.1 电动拖拉机田间犁耕测试

为获取电动拖拉机的实测工况载荷数据,设计传感器的选型方案,根据该方案构建基于CAN总线的电动拖拉机犁耕机组多传感器综合测试系统,实现对多源作业工况参数的自动化采集和实时监控。

测试参数共计 11 项(表 1),测试系统传感器布置如图 1 所示。

表 1 系统测试参数和传感器选型

Tab.1 System test parameters and sensor selection

测试对象	测量参数	传感器
车辆运行状态	车速	多普勒测速仪
	车轮转速	旋转编码器
悬挂系统状态	耕深	拉绳位移传感器
	上拉杆拉压力	拉压力传感器
	左下拉杆牵引力	轴销式拉力传感器
	右下拉杆牵引力	轴销式拉力传感器
	上拉杆角度	IMU 姿态传感器
	左下拉杆角度	IMU 姿态传感器
驱动系统状态	驱动转矩	ECU 控制器
	驱动转速	ECU 控制器



图 1 多源工况参数测试系统传感器布置图

Fig.1 Sensor layout of multi-source working condition parameter test system

电动拖拉机犁耕机组作业工况载荷测试试验地点为北京市昌平区小汤山试验田,试验时间为 2024 年 7—8 月,土质为黏土,含水率为 10%~15%。该土壤条件对电动拖拉机犁耕试验具有一定影响,但不是本文研究重点。选用的试验样机为 15 kW 电动拖拉机,挂载机具为某品牌犁耕机,挂接方式为三点悬挂,由 2 个单体铧式犁组成,铧式犁幅宽为 200 mm,耕作深度为 180~200 mm。实际作业速度为 3~5 km/h(误差在 ± 0.3 km/h 范围内),耕作幅宽为 400 mm,作业速度按照犁耕作业标准手动控制调节。根据实际农艺需求,3 种耕深(93、133、173 mm)分别对应 3 种不同农艺(保护性耕作、常规增产耕作、土壤改良耕作),同时为探究不同速度下

牵引阻力变化情况,分别开展 9 组不同速度和耕深下的电动拖拉机犁耕作业试验。为确保试验准确性,拉绳位移传感器检测耕作深度并通过整机控制器反馈控制,同时限深轮限制耕作深度,提升耕深稳定性。电动拖拉机犁耕作业参数设置如表 2 所示。

表 2 电动拖拉机犁耕作业参数设置

Tab.2 Plowing operation parameter setting of electric tractor

作业速度/($\text{km}\cdot\text{h}^{-1}$)	作业深度/mm	作业次数
3 ± 0.3	93	3
3 ± 0.3	133	3
3 ± 0.3	173	3
4 ± 0.3	93	3
4 ± 0.3	133	3
4 ± 0.3	173	3
5 ± 0.3	93	3
5 ± 0.3	133	3
5 ± 0.3	173	3

1.2 牵引负载等级

为从载荷特征中提取出能够表征电动拖拉机作业状态的有效信息,负载等级辨识模型需要同时辨识多个工况载荷数据。根据《农业拖拉机 试验规程 第 9 部分 牵引功率试验》和《皮带传动拖拉机 牵引效率限值及确定方法 第 1 部分 轮式拖拉机》^[24-25],纯电动拖拉机牵引性能指标由标定牵引力、标定牵引功率和牵引效率构成。

为准确评估电动拖拉机牵引性能,选取 9 组载荷数据部分片段,读取每个数据片段左右牵引阻力、车轮滑转率、电机转速和电机转矩等载荷数据,综合分析电动拖拉机犁耕作业所需的牵引功率与载荷数据之间的关联。

电动拖拉机行走电机功率是一个关键的技术参数,其直接影响拖拉机的性能和工作效率,行走电机功率计算方法为

$$P_m = T\omega \quad (1)$$

式中 P_m ——行走电机功率, kW

T ——电机转矩, $\text{N}\cdot\text{m}$

ω ——角速度, rad/s

驱动轮滑转率是拖拉机在行驶过程中驱动轮的滑转程度,一般表示为车轮理论速度和实际速度差值与理论速度比值,即

$$S = \frac{v_t - v}{v_t} \times 100\% \quad (2)$$

$$\eta_s = 1 - S \quad (3)$$

式中 S ——滑转率, %

η_s ——滑转效率, %

v_t ——车轮理论行驶速度, m/s

v ——车轮实际行驶速度, m/s

定义拖拉机对外输出有效力与驱动力之比为滚动效率 η_f , 反映由地面对滚动车轮产生的滚动阻力所引起的功率损失, 表示为

$$\eta_f = \left(1 - \frac{F_r}{F_i}\right) \times 100\% \quad (4)$$

式中 F_r ——滚动阻力, kN

F_i ——总驱动力, kN

综合式(1)~(4), 可得牵引功率与滑转率、传动效率以及滚动效率间的关系式为

$$P_F = P_m \eta_c \eta_s \eta_f \quad (5)$$

式中 P_F ——牵引功率, kW

η_c ——传动效率, %

选取9组载荷数据部分片段, 提取数据片段中的车速、左右侧牵引力、耕深和驱动轮滑移率等载荷数据, 基于上述电动拖拉机牵引性能指标, 对标准化后的载荷数据进行FCM(Fuzzy cluster means)模糊聚类分析, 通过肘部法则计算不同 C 值下的模糊隶属度平方和, 选择拐点对应的 C 值, 确定在 $C=3$ 时具有明显拐点。同时, 为了检验模糊 C -means分析所选定的 C 值是否合理, 通过轮廓系数分析不同簇类的聚类效果, 确定最佳聚类簇数 $C=3$ 。最终基于模糊聚类结果和犁耕负载特征的定义确定犁耕牵引负载等级评价指标如表3所示, 确定低、中、高3个牵引负载等级, 根据聚类分析设定4个评价指标以及参考范围, 并以这4项评价指标作为牵引负载等级分类依据。

表3 犁耕牵引负载等级评价指标

Tab. 3 Ploughing traction load grade evaluation index

评价指标	参考范围	定义
牵引功率/kW	<5(低)、 5~10(中)、 >10(高)	反映牵引负载水平, 区分低、中、高负载
功率标准差/kW	<1(稳定)、 ≥1(波动)	表征负载波动性, 高值表示不稳定工况
耕深/mm	<90(低)、 90~150(中)、 ≥150(高)	直接关联作业强度, 耕深越大负载越高
滑转率/%	<20(优)、 20~30(中)、 >30(高)	稳定工况下轮式拖拉机滑转率不超过20%

2 牵引负载等级辨识方法

2.1 多传感器核心处理思想

由于电动拖拉机牵引负载多变且载荷参数较多, 传统统计分析方法仅能辨识出少量典型工况片段, 造成分级标注困难。一方面, 由于实测载荷数据

量十分庞大, 若采用传统监督学习方法, 需耗费大量经过标记处理的载荷数据, 另一方面, 人为将负载等级确定为低、中、高作业负载, 并严格匹配低、中、高作业工况的负载标签, 据此来学习载荷数据与负载等级标签的映射关系, 只能识别典型的负载等级, 不能全面表征电动拖拉机牵引性能^[26]。

为此, 本文基于半监督学习的思想, 提出一种基于WRN_x的牵引负载等级辨识模型, 该模型以3种犁耕牵引负载等级下的多传感器实测载荷数据作为训练输入, 依据犁耕作业牵引负载分级标准, 基于WRN_x组合模型通过WideResNet的特征表达能力深入提取载荷数据的有效特征, 通过xLSTM网络处理时序关系。最终通过分类器对载荷序列实现分类预测。

在半监督学习算法下对辨识网络进行迭代训练。如图2所示, 使用少量有标签数据预训练WRN_x辨识模型。通过预训练的模型提取无标签数据特征, 应用 C -means模糊聚类分析模型的线性输出, 初步确定无标签数据对应的伪标签最佳簇数, 设置停止条件使网络重复生成伪标签, 将伪标签和有标签结合加入到训练集中迭代网络直至生成的伪标签达到稳定, 训练过程生成的伪标签同样使用 C -means模糊聚类确定最佳簇数并进行分析验证。使用稳定的伪标签通过分类器划分犁耕牵引负载等级^[27]。

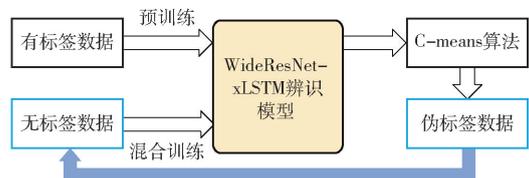


图2 基于自训练的半监督学习框架

Fig. 2 Semi-supervised learning framework based on self-training

半监督学习算法原理如下:

(1) 初始模型预训练: 使用少量有标签数据预训练网络, 得到少样本预训练模型, 过程中使用监督学习交叉熵损失, 表达式为

$$L_{sup} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} \lg P_{ik} \quad (6)$$

式中 L_{sup} ——监督损失(有标签数据交叉熵损失)

N ——有标签样本数量

K ——类别总数

y_{ik} ——真实标签的 one-hot 编程

P_{ik} ——模型预测概率

(2) 伪标签生成: 使用无标签数据对网络进行测试并生成无标签数据的伪标签, 结合预训练模型的特征提取, 对输出特征结果使用 C -means聚类得

到,最小化熵损失迫使网络对无标签数据做出高置信度的预测,置信度过滤确定最终伪标签。熵最小化原则遵循

$$L_{\text{entropy}} = -\frac{1}{M} \sum_{j=1}^M \sum_{k=1}^K P_{jk} \lg P_{jk} \quad (7)$$

式中 M ——无标签样本数量

P_{jk} ——模型对第 j 个无标签样本属于第 k 类的预测概率

(3)混合数据训练:使用动态加权损失平衡有标签和无标签数据,WRN_x 融合模型结合 WideResNet 提取一维序列数据中的特征,xLSTM 则处理时序预测负载变化趋势,训练过程中使用混合损失函数跟踪模型迭代过程中的损失值变化,由

$$L = \lambda L_{\text{sup}} + (1 - \lambda) L_{\text{unsup}} \quad (8)$$

式中 L ——总体损失值

λ ——监督损失权重

L_{unsup} ——无监督损失(伪标签数据交叉熵损失)

可知, λ 越大,监督信号对总损失的影响越强,初始值 $\lambda = 0.7$,随训练逐步衰减。通过一致性正则化约束模型对增强前后的输入产生相似的输出。

(4)收敛判断与模型更新:通过新旧标签的变化率计算统计伪标签的更新比例,设置早停机制判断训练结束周期,量化伪标签稳定性,当连续3次变化率小于5%时停止训练,同时更新预训练模型参数,计算式为

$$\frac{1}{M} \sum_{i=1}^M \mathbb{I}(\hat{y}_i^{(t)} \neq \hat{y}_i^{(t-1)}) < \tau \quad (9)$$

式中 $\hat{y}_i^{(t)}$ ——第 i 个样本在 t 次迭代生成的伪标签
 $\hat{y}_i^{(t-1)}$ ——第 i 个样本在 $t-1$ 次迭代生成的伪标签

$\mathbb{I}(\cdot)$ ——指示函数,当条件为真时取1,否则取0

τ ——阈值,表示变化容忍度

2.2 基于 WRN_x 的半监督牵引负载等级辨识模型

为解决数据集难标记、牵引负载等级辨识困难的问题,基于半监督学习的思想,提出了基于 WRN_x 的牵引负载辨识网络。在宽残差网络的基础上引入扩展长短时记忆网络层用于提取数据时序特征,通过其独特的指数门控机制和多头注意力机制以改善 WRN 在长序列数据处理上的稳定性和准确性。同时,在半监督方法下充分利用无标签数据的隐藏特征,高效训练辨识网络,实现对犁耕牵引负载等级的准确辨识。

(1)宽残差网络

WideResNet(WRN)网络在 ResNet 的基础上保

留残差块和批量归一化算法加速的特点,减少网络深度和增加残差网络宽度,同时引入 dropout 避免增大网络宽度导致的过拟合。WRN 整体结构如图3所示,其位于网络前端,接收输入网络的一维序列数据。WRN 由一维卷积层(Conv1)和3个残差块组成,通道数为2,总深度为28层。其中残差块1用于通道扩展,序列长度保持不变,残差块2用于下采样(长度减半),残差块3用于下采样(长度减半),每个残差块包含4个基础网络块,每个基础网络块包含2个卷积层,1个批标准化层。为了接收时序数据,残差块中的卷积核尺寸都为 3×1 ,且步长为1或2。其中,非线性组合函数由批标准化(Batch normalization, BN)、线性修正单元(Rectified linear unit, ReLU)和 3×1 卷积层(Convolution, Conv)组成。

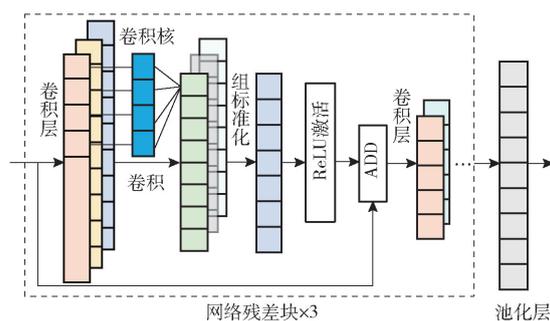


图3 宽残差网络结构图

Fig. 3 Structural diagram of wide residual network

(2)扩展长短时记忆网络

xLSTM 作为一种扩展的长短期记忆网络架构,通过引入 sLSTM 和 mLSTM 2 种新型变体,解决传统 LSTM 在信息存储机制僵化及长序列并行处理效率低下的核心问题^[28]。

混合架构(图4)采用残差连接框架,其核心模块依次包含批归一化层、双分支上投影层(Output-left/right)、GeLU 激活函数及线性下投影层。图中 i 表示输入门, f 表示遗忘门, z 表示记忆单元, o 表示输出门。具体地,归一化特征经双线性变换后通过门控交互生成多尺度表征,最终通过降维投影与原始输入残差融合。

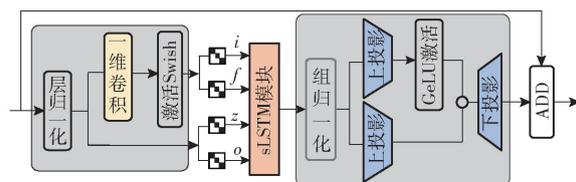


图4 xLSTM 网络框架

Fig. 4 xLSTM network framework

WRN 作为宽残差卷积网络,与 xLSTM 扩展长短时记忆网络串联构成 WRN_x 模块。在 WRN_x 模块基础上,为改善传统监督学习中数据标记困难,分级不准确的问题,通过半监督学习算法,以较少的有

标签典型工况片段样本作为支持集,训练一个负载等级分类模型。使用该分类模型对无标签数据等级进行辨识生成伪标签,通过新旧标签变化率计算统计伪标签的更新比例,当连续3次变化率均小于

5%时停止训练,同时更新预训练模型参数。在减少人为标记数据使用的同时提升了分类预测精度。最终将WRN_x网络与半监督学习算法有效融合,组成WRN_x半监督辨识模型,整体结构如图5所示。

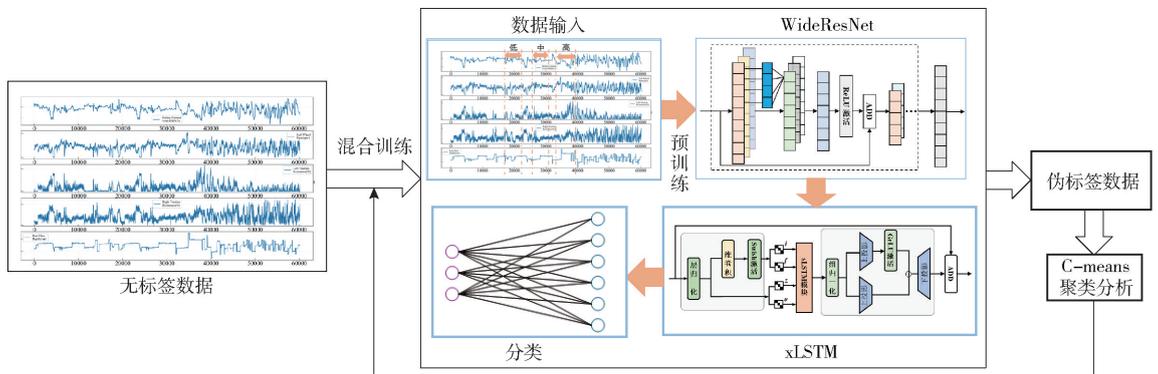


图5 基于WRN_x的牵引负载等级半监督辨识网络

Fig. 5 WRN_x-based semi-supervised discrimination network for traction load grade

WRN_x半监督模型由半监督学习算法、WRN_x和分类器3个模块组成。半监督学习算法将输入模型的多通道载荷序列数据基于牵引负载等级分类标准,获得有标签数据对WRN_x模型进行预训练,通过预训练模型提取无标签数据特征,在特征空间应用K-means聚类分析,重复生成伪标签,将伪标签加入训练集中训练WRN_x模型直至满足停止条件。其中,WRN_x半监督模型结合WideResNet的空间特征提取能力和xLSTM的时序建模,用于处理一维时序数据。WideResNet提取的空间特征与xLSTM提取的时序特征经过融合拼接后的输出即为特征序列。

WRN_x模块输出的特征进入分类器后,进入2层全连接层网络中,全连接层1用于降维和GeLU激活,全连接层2使用Softmax分类器输出牵引负载等级分类预测结果。WRN_x模型参数配置如表4所示。

3 犁耕作业牵引负载等级识别

3.1 数据预处理

基于制定的犁耕牵引负载等级评价指标,分别进行9组不同速度和耕深下的电动拖拉机犁耕作业试验,每组试验作业3次,对实测的9组载荷数据进行清洗和处理,去除驻车、转向、掉头等状态下的数据片段,为有效划分牵引负载等级,将采集的载荷数据进行了归一化和标准化。经过处理后的载荷数据范围被压缩至[0,1],以统一不同参数序列尺度。获得3种耕作深度下的数据量均为20000,数据通道数为11,保留数据样本共180000个,原始数据集尺寸为(180000,11)。

表4 WRN_x模型参数

Tab. 4 Parameters of WRN_x model

网络层	输出尺寸	WRN _x 网络结构	参数量
输入层	(64,11,20)		0
卷积层	(64,16,20)	3 × 1 Conv, stride 2	624
残差块1	(64,32,20)	$\begin{bmatrix} 3 \times 1, 16 \times 2 \\ 3 \times 1, 16 \times 2 \end{bmatrix} \times 2$ 1 × 1 Conv, stride 1	19 456
残差块2	(64,64,10)	$\begin{bmatrix} 3 \times 1, 32 \times 2 \\ 3 \times 1, 32 \times 2 \end{bmatrix} \times 2$ 1 × 1 Conv, stride 2	76 800
残差块3	(64,128,5)	$\begin{bmatrix} 3 \times 1, 64 \times 2 \\ 3 \times 1, 64 \times 2 \end{bmatrix} \times 2$ 1 × 1 Conv, stride 2	305 152
池化层	(64,128,5)	Kernel 为 5	0
因果卷积层	(64,128)	1 × 1 × 4 Conv	65 664
sLSTM	(64,128)	门控计算,记忆单元更新	249 024
上投影	(64,256)	门控激活	99 840
下投影	(64,128)	256/2,恢复输出维度	197 376
分类层	(64,3)	全连接,Softmax	33 283

在数据预处理阶段,由于数据收集时的遗漏、传感器故障等原因导致数据集中经常出现缺失值和异常值,首先去除连续缺失值的数据片段,通过线性插值,在未检测到的数据缺失局部位置使用线性函数来估计缺失值。在异常值处理前,去除大部分集中的异常数据,对稀疏异常值通过Z-score法基于标准正态分布概念检测并使用均值替换。确保程序正常运行的同时降低线性插值和异常值对训练过程和训练结果的影响。

此外,为扩展数据量,防止模型过拟合,对原始数据集进行低通滤波去噪处理,将处理后数据集和原始数据集混合后数据量由180000个扩展到360000个,数据集尺寸变为(360000,11)。

设定时间步长为 120 的滑动窗口,将载荷数据按窗口尺寸分为多个等长的数据切片,最终获得 3 005 个数据切片,提取每个数据切片内各时刻载荷数据,对 3 种负载等级分类标签进行 One-hot 编码,得到数据集尺寸为(3 005,120,11)。

在训练模型过程中,按照 70%、15%、15% 将数据划分为训练集、验证集以及测试集。在半监督训练方法下,将少部分训练集数据切片进行标记,结合交叉熵损失、一致性正则化和熵最小化损失,用于分类模型预训练,并基于训练数据和测试数据迭代网络验证辨识效果。网络训练过程中,批次大小设为 64,初始学习率设为 1×10^{-4} ,梯度下降算法使用 Adam。

3.2 辨识模型训练结果

构建的模型基于 Pytorch 深度学习框架实现,操作系统为 Windows 11,硬件环境为 NVIDIA RTX 4050GPU,使用 Python 3.11、Pytorch 1.3.1 和 CUDA 11.7。在此基础上依据制定的犁耕牵引负载等级评价指标对数据集片段进行标注,得到对应数据片段标签集合,经过数据预处理将数据分为训练集、验证集和测试集,将训练集输入负载辨识模型中训练模型。

以数据预处理后的训练集作为输入,在训练 WRN_x 网络的过程中,在 100 次循环周期后,取遍历未标记数据加载器,获得模型的输出特征结果,并对其进行 C-means 聚类,聚类数范围为(2,8),得到轮廓系数随聚类数的变化趋势如图 6 所示。由图 6 可以看出,轮廓系数转折点对应的 C 值即为聚类数 $C=3$,与模糊聚类分析结果相符。

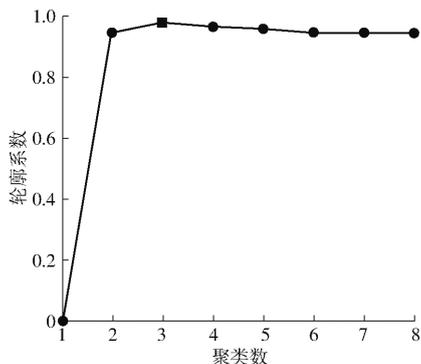


图 6 聚类分析验证结果

Fig. 6 Results of cluster analysis verification

基于半监督的电动拖拉机机组犁耕牵引负载等级辨识模型的训练,图 7 为 WRN_x、CNN-xLSTM、xLSTM 和 WideResNet 4 个负载等级分类模型结果,其中 WideResNet-xLSTM 模型收敛最快,误差也最小。辨识模型在第 450 个周期时开始收敛,这表明预测结果和实际标签间的误差达到最低。

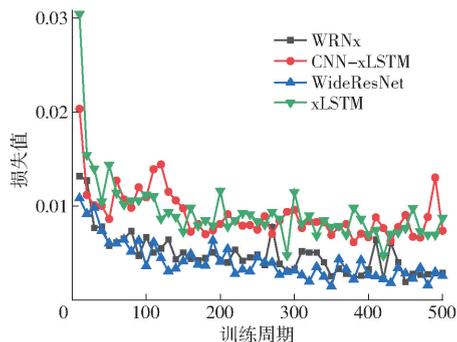


图 7 基于半监督学习的辨识模型交叉熵损失函数变化曲线

Fig. 7 Change curves of cross entropy loss function of identification model based on SSL

3.3 牵引负载等级辨识结果

负载等级辨识模型辨识效果评价指标包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 值 (F1-score)。混淆矩阵将预测结果与真实标签按类别对应,在一个矩阵中显示出来便于直观地评估结果。

对于多分类问题,可拆分为多个二分类任务,分别计算其准确率、精确率、召回率和 F1 值,预测正确样本占总样本比例。获取多个二分类任务评价指标后得到多分类任务的混淆矩阵。基于电动拖拉机犁耕机组的 15 kW 电动拖拉机负载等级分类指标,验证不同数量标记数据对辨识模型评估精度的影响。此外,通过模糊聚类分析可知将牵引负载等级分为低、中、高 3 类是最佳分类指标,因此进行了负载辨识对比试验,得到 3 个负载等级下 WRN_x、CNN-xLSTM、xLSTM 和 WideResNet 4 个负载等级分类模型的辨识结果混淆矩阵。

在不同数量标签下进行了负载等级辨识试验,分别使用两组不同标签数量的训练集进行 WRN_x 模型训练和评估,其中第 1 组训练集有 1 790 个,第 2 组训练集有 2 093 个。其中,两组数据验证集与测试集都相同,验证集有 206 个数据切片,408 个数据切片作为测试集进行模型评估。

通过系统评估半监督训练方法在不同标注数据规模下对 WRN_x 分类模型的性能影响,如图 8 所示,当采用 1 790 个带标签样本进行训练时,模型在测试集上负载等级辨识准确率为 91.91%;而将标注数据量提升至 2 093 个时,准确率显著提高至 94.35%。该结果表明,当标注数据规模扩展至临界阈值时,半监督策略能够充分挖掘未标注样本的隐式特征关联,使模型性能产生质变性提升。

分析图 9 可知,在犁耕牵引负载等级辨识场景中,半监督学习框架具有显著的数据效率优势。当采用 1 790 个标注样本结合半监督学习时,WRN_x 模

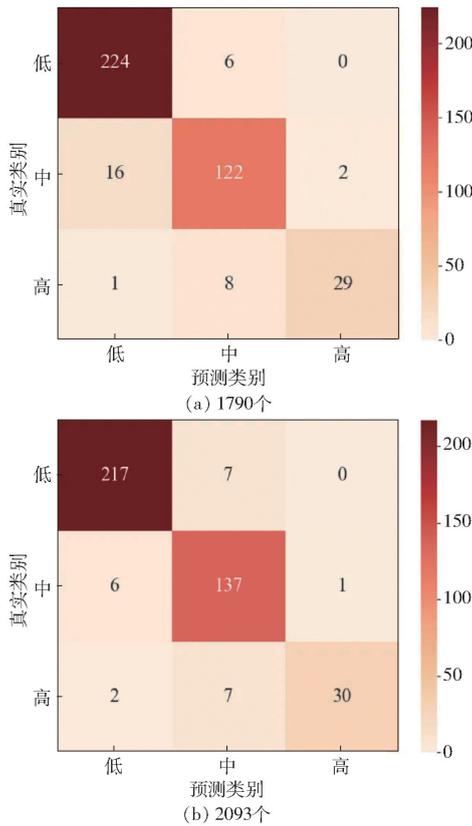


图 8 不同数量标签数据训练下负载等级辨识结果
Fig. 8 Identification results of load grade under different numbers of tags data training

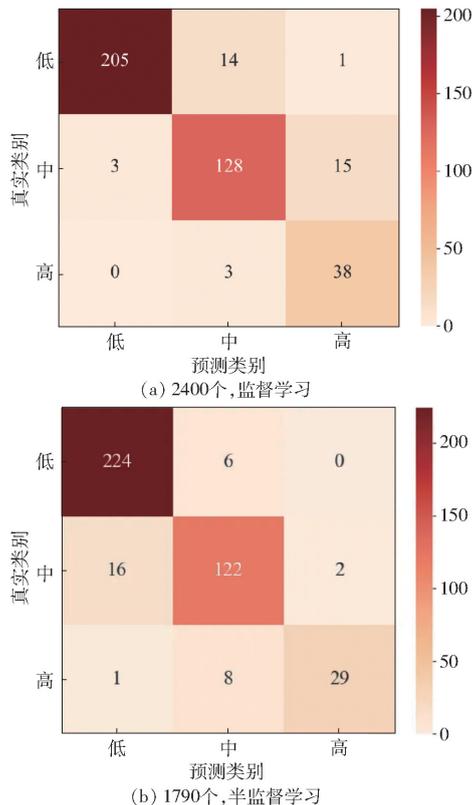


图 9 监督学习与半监督学习混淆矩阵对比
Fig. 9 Confusion matrix comparison of supervised vs semi-supervised learning

型牵引负载辨识准确率达到 91.91% ;而在纯监督学习模式下,即便使用 2 400 个标注样本进行训练,其辨识准确率仅为 91.15%。试验结果表明,2 种方法在性能指标上未呈现显著差异,但半监督策略成功将标注数据降低 25.4% (即减少 610 个标注样本)。这一实证数据与半监督学习理论中关于标注数据可缩减 20% ~ 25% 的预测高度吻合,不仅验证了该理论的有效性,更重要的是在农业机械智能感知与深度学习领域完成了实践验证。

分析图 10a 可知,大部分负载标签都集中在低、中负载区域,辨识模型的低、中负载标签识别效果较好,准确率均超过 90%。但高负载区域的负载标签较少,辨识模型高负载标签识别效果较差,准确率为 85% 左右。

由表 5 可知,WRN_x 模型在不同负载等级下的分类性能均最为优异,其辨识准确率在 3 个负载等级辨识任务中达到 94.35%,较其他分类模型高 1.95、3.69、4.92 个百分点。这一结果表明,WRN_x 模型在复杂机械状态下的负载等级分类任务中展现了显著的优势。

因此,基于 WRN_x 的半监督牵引负载等级辨识模型在少量已标记数据的前提下具有较高的准确率,当已标记数据增大时,辨识模型准确率也随之提高。将牵引负载等级划分为 3 类作为电动拖拉机负载辨识的评定指标,不仅能提高辨识准确性,也保证辨识效果的稳定性和可靠性。

4 结论

(1)为实现基于多传感器实测载荷数据的电动拖拉机牵引负载等级准确辨识,提出了一种半监督学习框架,构建了一种基于 WRN_x 网络的牵引负载等级辨识模型。半监督学习算法通过有标签和无标签数据迭代网络直至生成的伪标签达到稳定。基于 WRN_x 组合模型通过 WideResNet 的特征表达能力深入提取载荷数据的有效特征,通过 xLSTM 网络处理时序关系。

(2)针对某 15 kW 电动拖拉机犁耕工况,设计并构建了电动拖拉机多传感器综合测试系统。依据所制定的牵引负载等级评价指标开展了 9 组田间犁耕试验,获取了不同条件下的多传感器实测载荷数据。

(3)针对所提出的基于 WRN_x 的半监督辨识模型,进行了犁耕作业牵引负载等级辨识分析。结果表明,所提出的半监督学习框架可减少 25.4% 的标记数据训练样本,优于传统的监督学习训练框架,采

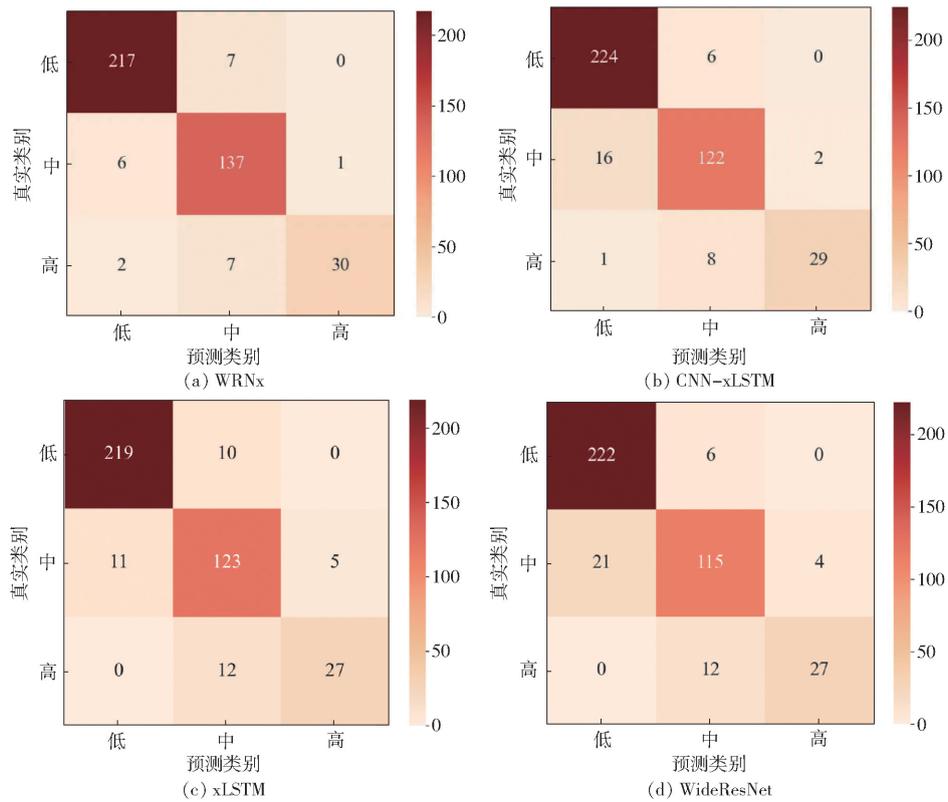


图10 牵引负载等级混淆矩阵

Fig. 10 Confusion matrix for traction load grade

表5 牵引负载等级辨识结果综合评价

Tab. 5 Comprehensive evaluation of traction load grade identification results

分类模型	准确率	精确率	召回率	F1 值	%
WRNx(本文模型)	94.35	94.48	94.15	94.27	
CNN-xLSTM	92.40	92.57	92.26	92.36	
xLSTM	90.66	90.63	90.37	90.56	
WideResNet	89.43	89.27	89.13	89.18	

用基于3个负载等级划分的评定指标时,基于实测数据的WRNx负模型准确率和F1值分别达到94.35%和94.27%。将半监督学习引入智能农业机械领域,尽可能充分挖掘多传感器工况参数负载信息,减少有标记数据的需求,综合评估了不同算法的预测性能,为电动拖拉机犁耕作业负载分析提供了新的参考。

参 考 文 献

- [1] 欧阳安,崔涛,林立. 智能农机装备产业现状及发展建议[J]. 科技导报,2022,40(11):55-66.
OUYANG An, CUI Tao, LIN Li. Development status and countermeasures of intelligent agricultural machinery equipment industry[J]. Science & Technology Review, 2022, 40(11): 55-66. (in Chinese)
- [2] 刘浩鲁,沈成,胡良龙,等. 电动农业装备研究进展与发展趋势[J]. 农业工程学报,2024,40(23):39-51.
LIU HaoLu, SHEN Cheng, HU LiangLong, et al. Research progress and development trend of electric agricultural equipments[J]. Transactions of the CSAE, 2024, 40(23): 39-51. (in Chinese)
- [3] 中国农业机械化信息网. 关于印发《全国农业科技创新重点领域(2024—2028年)》的通知[EB/OL]. (2025-02-17) [2025-03-08]. <http://www.amic.agri.cn/secondLevelPage/info/43/198245>.
- [4] 谢斌,武仲斌,毛恩荣. 农业拖拉机关键技术发展现状与展望[J]. 农业机械学报,2018,49(8):1-17.
XIE Bin, WU Zhongbin, MAO Enrong. Development and prospect of key technologies on agricultural tractor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(8): 1-17. (in Chinese)
- [5] 孟志军,王昊,付卫强,等. 农业装备自动驾驶技术研究现状与展望[J]. 农业机械学报,2023,54(10):1-24.
MENG Zhijun, WANG Hao, FU Weiqiang, et al. Research status and prospects of agricultural machinery autonomous driving[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 1-24. (in Chinese)
- [6] 徐立友,张俊江,闫祥海,等. 农业装备电动化技术研究综述[J]. 农业机械学报,2023,54(9):1-12.
XU Liyou, ZHANG Junjiang, YAN Xianghai, et al. Review of research for agricultural equipment electrification technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(9): 1-12. (in Chinese)
- [7] ZHANG S, REN W, XIE B, et al. A combined control method of traction and ballast for an electric tractor in ploughing based on load transfer[J]. Computers and Electronics in Agriculture, 2023, 207: 107750.
- [8] WEN C, ZHANG S, XIE B, et al. Design and verification innovative approach of dual-motor power coupling drive systems for electric tractors[J]. Energy, 2022, 247: 123538.

- [9] ZHANG S, WEN C, REN W, et al. A joint control method considering travel speed and slip for reducing energy consumption of rear wheel independent drive electric tractor in ploughing[J]. *Energy*, 2023, 263:126008.
- [10] WEN C, REN W, ZHU Q, et al. Reducing operation emissions and improving work efficiency using a pure electric wheel drive tractor[J]. *Engineering*, 2024, 37:230–245.
- [11] 李贤哲, 张明柱, 刘孟楠, 等. 基于多岛遗传算法的电动拖拉机分布式驱动系统优化设计与试验[J]. *农业机械学报*, 2024, 55(3):401–411.
LI Xianzhe, ZHANG Mingzhu, LIU Mengnan, et al. Optimized design and validation of distributed drive system for electric tractor based on multi-island genetic algorithm[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(3):401–411. (in Chinese)
- [12] 赵静慧, 刘孟楠, 徐立友, 等. 四轮驱动拖拉机牵引性能预测模型建立与试验[J]. *农业机械学报*, 2023, 54(9):439–447.
ZHAO Jinghui, LIU Mengnan, XU Liyou, et al. Prediction model and experiment on tractive performance of four-wheel drive tractor[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(9):439–447. (in Chinese)
- [13] 贾方, 侯宇豪, 韩建刚, 等. 基于电驱动系统的农业车辆牵引负荷车设计与试验[J]. *农业机械学报*, 2023, 54(8):394–401, 410.
JIA Fang, HOU Yuhao, HAN Jian'gang, et al. Design and test of agricultural vehicle traction load vehicle based on electric drive system[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(8):394–401, 410. (in Chinese)
- [14] 陈仲举, 谢斌, 罗振豪, 等. 无人驾驶电动拖拉机犁耕机组路径跟踪与耕深模糊控制策略研究[J]. *农业机械学报*, 2024, 55(12):491–504.
CHEN Zhongju, XIE Bin, LUO Zhenhao, et al. Fuzzy control strategy for path tracking-tillage depth of unmanned electric tractor ploughing unit[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(12):491–504. (in Chinese)
- [15] WANG Q, WANG X, WANG W, et al. Joint control method based on speed and slip rate switching in plowing operation of wheeled electric tractor equipped with sliding battery pack[J]. *Computers and Electronics in Agriculture*, 2023, 215:108426.
- [16] LUO Z, XIE B, TONG Y, et al. Energy-saving drive control strategy for electric tractors based on terrain parameter identification[J]. *Applied Energy*, 2024, 376:124230.
- [17] 程淮, 鲁植雄. 拖拉机液压传动系统特性模型修正与参数辨识[J]. *农业工程学报*, 2022, 38(19):33–41.
CHENG Zhun, LU Zhixiong. Model modification and parameter identification of tractor hydraulic transmission system characteristics[J]. *Transactions of the CSAE*, 2022, 38(19):33–41. (in Chinese)
- [18] 王宏伟, 温昌凯, 刘孟楠, 等. 拖拉机作业工况参数检测系统研究[J]. *农业机械学报*, 2023, 54(增刊2):409–416.
WANG Hongwei, WEN Changkai, LIU Mengnan, et al. Tractor operating condition parameter testing system[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(Supp. 2):409–416. (in Chinese)
- [19] 温昌凯, 谢斌, 李若晨, 等. 拖拉机作业载荷数据平台设计与旋耕作业质量预测[J]. *农业机械学报*, 2020, 51(8):372–381.
WEN Changkai, XIE Bin, LI Ruochen, et al. Construction of tractor working load data platform and prediction of rotary tillage quality[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(8):372–381. (in Chinese)
- [20] 李淑艳, 李若晨, 温昌凯, 等. 基于GAF-DenseNet的旋耕作业质量等级识别模型[J]. *农业机械学报*, 2022, 53(11):441–449.
LI Shuyan, LI Ruochen, WEN Changkai, et al. Quality identification model of tractor rotary tillage based on GAF-DenseNet[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(11):441–449. (in Chinese)
- [21] WEN C, LI R, ZHAO C, et al. An improved LSTM-based model for identifying high working intensity load segments of the tractor load spectrum[J]. *Computers and Electronics in Agriculture*, 2023, 210:107879.
- [22] LI R, WEN C, LI S, et al. Quality prediction of tractor rotary tillage based on BiConvLSTM with self-attention[J]. *Computers and Electronics in Agriculture*, 2023, 206:107643.
- [23] 马若飞, 伟利国, 赵博, 等. 基于多传感器数据融合的旋耕耕深检测系统研究[J]. *农业机械学报*, 2024, 55(9):52–64.
MA Ruofei, WEI Liguoguo, ZHAO Bo, et al. Rotary tillage depth detection based on multi-sensor data fusion[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(9):52–64. (in Chinese)
- [24] 全国拖拉机标准化技术委员会. 农业拖拉机 试验规程 第9部分 牵引功率试验:GB/T 3871.9—2006[S]. 北京:中国标准出版社, 2006.
- [25] 全国拖拉机标准化技术委员会. 皮带传动拖拉机 牵引效率限值及确定方法 第1部分 轮式拖拉机:GB/T 25682.1—2010[S]. 北京:中国标准出版社, 2010.
- [26] 王凯, 赵刚, 龚晓成, 等. 面向电力调度知识建模的半监督实体识别方法[J]. *电网技术*, 2023, 47(9):3855–3864.
WANG Kai, ZHAO Gang, GONG Xiaocheng, et al. Semi-supervised entity recognition for power dispatching knowledge modeling[J]. *Power System Technology*, 2023, 47(9):3855–3864. (in Chinese)
- [27] 邢晓松, 郭伟. 基于改进半监督生成对抗网络的少量标签轴承智能诊断方法[J]. *振动与冲击*, 2022, 41(22):184–192.
XING Xiaosong, GUO Wei. Intelligent diagnosis method for bearings with few labelled samples based on an improved semi-supervised learning-based generative adversarial network[J]. *Journal of Vibration and Shock*, 2022, 41(22):184–192. (in Chinese)
- [28] BECK M, PÖPPEL K, SPANRING M, et al. XLSTM: extended long short-term memory[J]. *arXiv Preprint arXiv:2405.04517*, 2024.