

基于VS-1D CNN的玉米籽粒直收机清选损失检测系统设计与试验

邢高勇^{1,2} 葛世聪² 卢彩云¹ 赵博^{1,2} 刘阳春² 周利明²

(1. 中国农业大学工学院, 北京 100083; 2. 农业装备技术全国重点实验室, 北京 100083)

摘要:为解决传统清选损失检测传感器依靠时域特征阈值分辨籽粒冲击信号存在的阈值确定难、鲁棒性差、缺乏适应性问题,开发了一套玉米籽粒直收机清选损失检测系统,提出了一种基于变尺度一维卷积神经网络(VS-1D CNN)的籽粒冲击分类算法。首先,针对冲击信号采集、处理与传输设计了硬件电路与软件处理程序,开发了配套上位机。然后,搭建数据采集试验平台,采集、保存了不同冲击高度和角度下杂余、玉米籽粒冲击信号,构建了数据集并对VS-1D CNN籽粒冲击分类算法进行了训练,训练结果表明,该模型在测试集上准确率为94.2%。最后,对所设计的检测系统在不同工作条件下的性能及不同杂余、籽粒混合物的分类性能进行了验证,结果表明所提出的VS-1D CNN算法性能表现良好,在不同安装位置和不同籽粒流量下,检测准确率最高可达95%以上;对于不同比例杂余、籽粒混合物识别分类准确率达93%以上,表明本文所提出算法性能优异,可以在不设置固定时域特征阈值情况下准确检测籽粒损失。

关键词:玉米籽粒直收机;清选损失;传感器;1D CNN;深度学习

中图分类号:S237;S24 文献标识码:A 文章编号:1000-1298(2025)02-0206-11

OSID:



Design and Experiment of VS-1D CNN-based Clearing Loss Detection System for Corn Kernel Direct Harvester

XING Gaoyong^{1,2} GE Shicong² LU Caiyun¹ ZHAO Bo^{1,2} LIU Yangchun² ZHOU Liming²

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

2. State Key Laboratory of Agricultural Equipment Technology, Beijing 100083, China)

Abstract: Aiming to address the challenges of arduous threshold delineation, inadequate robustness, and insufficient adaptability of conventional clearing loss detection sensors that depend on temporal domain feature thresholds to distinguish kernel impact signals, a comprehensive clearing loss detection system for corn kernel direct collectors was developed, and a kernel impact classification algorithm predicated on a variable scale one-dimensional convolutional neural network (VS-1D CNN) was proposed. Initially, the hardware circuitry and software processing program were engineered for impact signal acquisition, processing, and transmission, alongside the development of the supporting host computer. Subsequently, a data acquisition testing platform was established to gather and archive the impact signals of weeds and maize kernels under varying impact heights and angles, thereby constructing a data set and training the VS-1D CNN seed impact classification algorithm, with the training outcomes indicating that the model's accuracy was 94.2% on the testing set. Ultimately, the efficacy of the devised detection system under diverse operational conditions and the classification performance of distinct stray residues and seed mixtures were validated, with results demonstrating that the proposed VS-1D CNN algorithm performed commendably, achieving detection accuracy exceeding 95% across different installation sites and varying seed flow rates; the classification accuracy for identifying different proportions of stray residues and seed mixtures surpassed 93%, signifying that the proposed algorithm exhibited exceptional performance. This

收稿日期:2024-10-26 修回日期:2024-12-27

基金项目:国家重点研发计划项目(2024YFD2001300)

作者简介:邢高勇(1993—),男,博士生,主要从事收获机械智能化与信息化研究,E-mail:982553745@qq.com

通信作者:卢彩云(1986—),女,副教授,博士生导师,主要从事保护性耕作与智能农业装备研究,E-mail:lucaiyun@cau.edu.cn

underscored that the algorithm delineated in this manuscript possessed remarkable efficacy and can accurately detect seed losses without establishing a fixed temporal domain feature threshold.

Key words: corn kernel direct harvester; clearing loss; sensor; 1D CNN; deep learning

0 引言

收获机械作业质量信息实时获取是无人农场数字化感知体系的重要组成部分^[1],也是实现无人农场生产中收获机械作业参数智能调控的关键基础。清选损失作为收获机械作业质量的关键参数,是评价收获机械作业质量、优化收获作业过程、提升收获作业效率的重要指标。因此,研发适用于玉米籽粒直收机的清选损失检测系统,实现玉米收获作业中清选损失的数字化感知,对于推动玉米无人化农场的快速发展具有重要意义。

目前,国内外检测不同谷粒损失的原理不尽相同,主要有压电、压阻、声学 and 图像 4 种不同的传感形式,其中国内外均以压电检测原理为主。损失检测的关键一方面在于对压电、压阻、声学等电信号检测电路的硬件搭建,该部分随着硬件技术的发展,已经有了大幅的改善,基本成熟;相比硬件电路,对信号的后处理分析及如何从复杂脱出物混叠冲击信号中识别出谷粒冲击和其他脱出物冲击是决定传感器性能的关键工作,在该方面国内外学者做了大量研究工作。

国外学者对损失传感器研究较早,利用压电、声学、压阻等不同传感方式开展了不同作物损失检测研究^[2-3]。国内关于谷物损失传感器研究起步较晚,但是涉及的谷物种类比较全面,水稻、小麦、玉米等均有学者研究^[4-9]。但对于籽粒计数方法的研究大多是从时域角度进行分析,方法简单易行,但是均需确定冲击时间和冲击信号电压阈值。当谷物的物理特性、传感器安装位置(不同高度和角度)以及传感器安装载体(不同类型的联合收获机)发生变化时,传感器难以实现普适性,每一种变化均需要重新确定系统的各项参数,适应性较差,难以大批量推广应用。此外,在进行玉米收获作业时,脱出物中存在较大的玉米芯轴和硬质的玉米秸秆^[10],质量与玉米籽粒相当,如果冲击高度和角度一致,将会产生与玉米籽粒类似的冲击信号,进一步增加籽粒分辨难度。因此,单纯利用冲击信号衰减时间和幅值进行分辨非常困难。

为了解决传统损失检测过程中籽粒冲击分辨率低,时域特征变化大难以确定阈值的问题,本文提出一种基于变尺度一维卷积神经网络(Variable scale 1D CNN, VS-1D CNN)的籽粒冲击识别模型,利用

多尺度卷积结构对不同时间尺度下的冲击信号特征进行有效提取,构建冲击信号的深度表征,解决传统方法中时域阈值难以确定的难题,以提高传感器适应性能,为传感器应用推广创造条件。

1 清选损失检测系统方案设计

1.1 检测原理与总体方案设计

玉米籽粒直收机清选损失检测系统利用压电薄膜作为敏感元件,通过环氧树脂将压电薄膜粘贴到带有电磁屏蔽功能的敏感板的中心位置。当不同脱出物冲击到敏感板上时,振动冲击通过敏感板传导给粘贴为一体的压电薄膜,受到冲击后,压电薄膜产生电荷,经过电荷放大电路处理后转换成电信号。不同脱出物冲击响应的电压信号幅值、频率等特征不同,系统通过算法模型进行处理后,对脱出物中籽粒和非籽粒信号进行区分,从而实现清选损失检测。

系统整体方案如图 1 所示,敏感单元在感知到物料冲击后经过电荷放大单元转换成模拟量电压信号,经过低通滤波器、高通滤波器对信号进行带通滤波,低通滤波器主要滤除工作环境中的高频电磁干扰,高通滤波器主要滤除低频机组振动干扰。信号经过滤波后,由高速高精度模拟量采集电路进行采集,然后经过控制单元进行处理、组织。由于采样频率较高,为保证信号实时、稳定传输处理,系统采用 USB 2.0 通信将高速信号传输至 PC 端,PC 端在接收到信号后一方面将信号进行可视化输出,同时送入分类算法模型进行处理,从而实现损失籽粒计数,准确获取玉米籽粒直收机清选损失。




图 1 系统总体方案设计

Fig. 1 Overall system program design

1.2 系统硬件设计

检测系统硬件设计主要针对下位机控制单元,根据系统总体设计方案,下位机控制单元主要功能需求为:①信号处理。将压电薄膜产生的电荷信号转换成模拟量电压信号,然后对信号进行程控带通滤波处理,滤除环境和机组振动干扰。②高速信号采集。利用高速高精度 AD 芯片对高速冲击信号进行采集。③数据发送。将采集到的高速冲击信号可靠、快速、稳定的发送到 PC 端。④CAN 总线通信功能。用于 PC 端对控制单元进行参数显控交互。对控制单元参数进行配置。

⑤掉电参数存储。用于掉电后下位机控制单元工作参数保存。

根据清选损失检测系统下位机控制单元功能需求,设计了如图 2 所示的硬件电路,主要包括信号调理与采集电路、参数存储电路和通信电路 3 部分。进行具体电路设计后,对损失传感器单体进行了集成,图 3 为集成敏感板、压电薄膜、金属屏蔽外壳和下位机控制单元于一体的损失传感器单体。其中,压电薄膜型号为 LDT0-028K,通过环氧树脂粘贴在敏感板中心位置,引出屏蔽线缆与下位机控制单元连接。




图 2 下位机硬件设计架构

Fig. 2 Hardware design architecture of lower computer




图 3 损失传感器单体构成

Fig. 3 Loss sensor monolithic structure composition

1. 敏感板 2. 压电薄膜 3. 下位机控制单元 4. 金属屏蔽外壳

1.3 检测系统软件设计

系统软件设计分为下位机控制单元和上位机 PC 端分类算法模型与参数设置两部分。

下位机控制单元程序主要完成物料冲击信号的采集、处理与上发,并根据 PC 端指令,通过 CAN 总线设置、发送配置信息与籽粒冲击数据相关信息到 PC 端,同时完成工作参数掉电存储等工作。具体工作流程如图 4 所示,主程序任务完成 USB、IIC、SPI、CAN、定时器、ADS127L 等模块初始化,然后根据

AT24C02 中保存的工作参数进行系统设置,同时通过 CAN 总线发送到 PC 端可视化;随后启动定时器,主程序任务进入主循环工作流程,根据自定义协议组织 CAN 消息帧定时向 PC 端发送,读取 ADS127L 高速冲击信号数据,处理分拆数据写入缓冲区并通过 USB 发送至 PC 端;读取并解析 CAN 接收缓冲区消息,根据消息指令进行系统工作参数设置与保存。与此同时,定时器任务根据设定时间对发送标志位进行置位并计算损失趋势,CAN 接收中断任务监听总线消息,判断消息帧 ID,将符合条件的消息帧写入缓冲区。PC 端分类算法模型与参数设置程序主要通过 USB 2.0 接口读取并解析高速冲击信号数据,PCAN(PEAK CAN,CAN 转 USB 通信模块)参数配置与籽粒冲击数据信息、GPS 定位数据等,完成对各类型数据的处理、分析,主要由 PC 端上位机主程序,分类算法模型、数据保存、可视化程序,参数解析配置程序和 GPS 数据解析程序等 4 部分组成。PC 端上位机主程序根据下位机控制单元的实际数量设置通道个数,完成 PCAN、USB 驱动程序的初始化等功能;分类模型、数据保存、可视化程序部分主要完

成高速冲击信号数据的接收、处理、可视化、分类以及保存等工作;参数解析配置程序完成下位机控制单元的参数解析、可视化与工作参数设置等工作;

GPS 数据解析程序主要完成 GPS 定位信息解析,获取经纬度、速度等信息,并进行可视化。PC 端上位机具体工作流程如图 5 所示。




图 4 下位机控制单元软件流程图

Fig. 4 Software program for lower control unit




图 5 PC 端上位机工作流程图

Fig. 5 Upper computer program for PC

2 数据集建立

2.1 数据采集试验平台

采用中玉 303 和先丰 98 两种玉米品种,玉米籽粒含水率约 17%,穗轴含水率约 10%,秸秆含水率约 8%。

不同物料冲击信号数据信息采集在试验台架(图 6)上进行,传送带速度通过调速器调节伺服电机转速进行目标运行速度设置,损失传感器可以通过安装机架上的高度和角度调节器调整,调整方便快捷。

数据采集前需安装好传感器,连接传感器通讯




图6 数据采集试验台架

Fig.6 Data acquisition test bench

1. 伺服电机 2. 调速器 3. 传感器安装机架 4. 传送带 5. 损失传感器 6. 高度/角度调节器

线缆到 PCAN 模块,传感器 USB 数据线直接连接到扩展坞,图 7 展示了各模块具体的连接方式。然后,打开上位机软件,设置好采集、保存参数后即可进行数据采集试验。





图7 PC 端数据采集

Fig.7 PC data collection

1. 传感器通讯与供电线缆 2. 传感器 USB 数据线 3. 扩展坞
4. PCAN 模块 5. 计算机

2.2 不同脱出物冲击数据获取

如图 8 所示,选取籽粒、穗轴和玉米秸秆等 3 种玉米籽粒直收机排杂口脱出物作为试验样品,利用前述试验平台,在传送带上间隔放置,设置传送带调速器以速度 2 cm/s 运行^[10-11],通过高度/角度调节器对传感器进行不同高度(15、25 cm)和角度(30°、40°)调节,进行交叉组合数据采集,冲击数据通过开



(a) 籽粒 (b) 穗轴 (c) 玉米秸秆

图8 不同物料冲击数据采集

Fig.8 Acquisition of different material impact data

发的上位机保存记录。其中玉米籽粒冲击每组采集 250 个样本,4 组共计 1 000 个试验样本;穗轴和秸秆冲击每组采集 100 个样本,每个类别 400 个样本。总计采集 3 种物料冲击样本 1 800 个。

2.3 数据预处理

基于对大量试验样本统计分析和系统采集特点,将信号长度统一设置为 2 000 个采样点。该长度既能完整保留碰撞信号的特征信息,又能确保采样区间覆盖完整的信号过程。实际采集中,有效信号段通常不会超出此范围,对于少数长度不足的样本,采用零填充方式进行规范化处理,以保证数据维度的一致性。

3 冲击信号分类模型构建

3.1 1D CNN 模型

一维卷积神经网络(1D convolutional neural network,1D CNN)是 CNN 的一种变体,专门用于处理一维数据^[12](如时间序列或信号)。与二维 CNN 主要用于提取图像二维特征不同,1D CNN 通过一维卷积核在输入数据的单一维度上执行卷积操作,从而提取数据局部时序特征或结构模式。1D CNN 基本结构与传统 CNN 类似,通常包括卷积层、激活函数(如 ReLU)、池化层和全连接层^[13]。这种架构保留了 CNN 局部感受野和参数共享优势,在信号处理和模式识别等多个领域得到广泛应用^[14-18]。

3.2 模型构建

图 9 中展示了比较典型的 3 种脱出物原始信号、FFT 频谱以及不同水平加噪后的信号特征。从图中可以看出:玉米籽粒冲击信号在较低频率范围内占主导,波形具有明显的尖峰特征,反映出高能量的瞬时释放。尽管主要频率低于 5 000 Hz,但信号具有短暂的高幅度脉冲;玉米穗轴冲击信号频率分布较为均匀,波形较为平滑,具有中等幅度和较长的持续时间。这表明穗轴在冲击过程中能量释放较为分散和缓慢;玉米秸秆冲击信号主要集中在较低频率,波形平滑且持续时间较长,幅度相对较小,显示出较高的柔韧性。

通过以上分析,脱出物的冲击信号较为复杂,即使在相同频率范围内,不同脱出物的信号在时域和频域内仍存在复杂的特征差异,如波形形状、能量分布和时序关系等,这些特征难以通过简单的频率滤波完全区分。此外,冲击信号不仅包含频率信息,还具有时域内动态变化和非线性特征,传统手段难以全面捕捉这些复杂特征。

基于上述信号特征分析,在 1D CNN 模型中引入了变尺度卷积层和自适应池化层,以提升模型对




图9 不同脱出物冲击原始信号、FFT分析与加噪处理后特征

Fig. 9 Raw impact signals of different corn byproducts, FFT analysis, and features after noise addition processing

复杂信号特征的提取能力。传统卷积层采用固定卷积核尺寸,限制了模型对多尺度特征的捕捉能力。通过引入变尺度卷积层,可以利用不同尺寸卷积核提取信号中的短时高幅度脉冲、平滑波形和长时间持续变化等多尺度特征,对于捕捉玉米籽粒的尖峰信号、玉米穗轴的平滑变化信号以及玉米秸秆的柔韧性信号尤为重要,可以增强模型对多样化信号特征的适应性和辨识能力。此外,固定尺寸的池化操作可能会导致重要特征丢失,特别是在信号持续时间和幅度变化较大的情况下。自适应最大池化层能够根据输入信号的特性动态调整池化区域,确保玉米籽粒信号中的尖峰特征和玉米穗轴以及秸秆信号中的平滑变化等关键特征得到有效保留,从而提升特征提取的有效性和分类准确率。

根据以上分析,本文设计了如图10所示结构的变尺度一维卷积神经网络模型(Variable scale 1D CNN, VS-1D CNN),网络结构包含多层卷积层、自适应池化层和全连接层。

模型输入长度为 T ,表示为 $x \in \mathbf{R}^{T \times 1}$,为控制单元采集的振动信号时间序列。为提取不同时间尺度上的特征,模型设计了3种卷积核大小,分别为 $k_1 = 3$ 、 $k_2 = 5$ 、 $k_3 = 7$ 。3种卷积层依次布置,每一层卷积过程可表示为

$$h^{(l)} = \sigma(W^{(l)}h^{(l-1)} + b^{(l)}) \quad (l=1,2,3) \quad (1)$$

其中 $W^{(l)}$ 和 $b^{(l)}$ 分别为卷积核权重和偏置, σ 为激活




图10 VS-1D CNN 算法模型结构

Fig. 10 VS-1D CNN algorithm model structure

函数,本模型在卷积层中采用修正线性单元(Rectified linear unit, ReLU)作为激活函数,可以有效解决梯度消失问题,并对稀疏性和模型训练速度具有正面作用^[19]。

卷积层后模型引入自适应最大池化层(Adaptive max pooling),将每层输出特征压缩为固定长度,即将 $h^{(3)}$ 压缩为 h_{pool} 。最后引入两层全连接神经网络,第1层为隐藏层,包含64个神经元,第2层为输出层,神经元个数对应于本文要处理的二元分类任务。为防止模型过拟合,在全连接层中加入Dropout正则化,丢弃率 p 设为0.3。为了对模型输出的分类概率进行优化,选择专用于分类问题的

二元交叉熵损失函数^[20] (Binary cross-entropy loss, BCE), 定义为

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \lg \hat{y}_i + (1 - y_i) \lg (1 - \hat{y}_i)] \quad (2)$$

其中, N 为训练样本数; $y_i \in \{0, 1\}$, 表示样本真实类别标签; $\hat{y}_i \in [0, 1]$, 为预测值, 表示模型预测概率。

3.3 训练数据集预处理与数据集划分

为了提高模型在实际工作环境中的抗干扰能力, 对每组数据样本添加不同信噪比的高斯白噪声, 信噪比设定在 $-30 \sim 10$ dB 之间, 随机分配给不同样本。加噪策略在一定程度上模拟了实际工作环境中可能遇到的各种噪声水平, 有利于提高模型鲁棒性。

训练前, 对数据集进行了不同比例样本分配, 总计 2 000 个训练数据样本, 包含 1 000 个籽粒冲击正样本, 1 000 个负样本。负样本除穗轴和秸秆冲击数据, 增加收获机工作时的机组振动背景噪声数据, 具体比例为 4: 3: 3, 即穗轴冲击 400 个样本、秸秆冲击 300 个样本、背景噪声 300 个样本, 加入背景噪声训练数据可以提高模型在实际应用中的准确性。基于试验数据规模和分布比例, 对训练集、验证集和测试集进行了分配 (表 1), 这种分配方式保持了各类样本在子集中的原始比例, 确保了训练和评估的可靠性。

表 1 训练数据集划分

Tab. 1 Training dataset partitioning

类别	训练集	验证集	测试集	总计
籽粒冲击	600	150	250	1 000
穗轴冲击	240	60	100	400
秸秆冲击	180	45	75	300
背景噪声	180	45	75	300
总计	1 200	300	500	2 000

3.4 模型训练

采用 PyTorch 深度学习框架训练模型, 使用 Adam 优化器优化模型参数, 加入 mini-batch 训练策略^[21], 批大小为 32, 初始学习率为 0.001。为防止过拟合, 实现了基于验证集性能的早停机制, 当验证集性能在连续 10 个轮次内没有改善时停止训练。模型在训练过程中设定最大训练轮数为 50 个轮次, 最终在验证集上取得了最佳性能的模型参数被保存用于后续测试。

图 11、12 为模型训练过程中准确率和损失值变化趋势图。从图 11 可以看出, VS-1D CNN 模型收敛性能良好。从图 12 可以看出, 在训练初期模型表现出快速学习能力, 损失值从 0.018 迅速下降至约 0.005。训练过程中, 模型呈现稳定收敛趋势, 训练精度从初始的约 56% 快速提升并最终达到接近

100%, 验证精度稳定维持在 93% ~ 95%。训练后期阶段, 训练损失持续下降而验证损失出现波动, 表明模型在一定程度上存在过拟合问题。但验证集上准确率依然维持较高水平, 表明模型泛化能力较强。虽然验证损失曲线在后期出现波动, 但验证集准确率相对稳定性, 进一步证实了 VS-1D CNN 算法模型结构设计的合理性和有效性。




图 11 训练集与验证集准确率变化曲线

Fig. 11 Trend plot of training set and validation set accuracy




图 12 训练集与验证集准确率损失值变化曲线

Fig. 12 Training set and validation set accuracy loss values

为全面评估模型分类性能, 采用准确率、精确率、召回率和 F1 分数 4 个指标进行评价。图 13 展示了 VS-1D CNN 模型在测试集中混淆矩阵结果。其中, 类别 1 表示玉米籽粒冲击, 类别 0 表示杂余冲击或无冲击背景信号。结果表明, 模型在区分籽粒与非籽粒冲击任务中性能表现良好。




图 13 VS-1D CNN 模型混淆矩阵

Fig. 13 VS-1D CNN model confusion matrix

在杂余冲击或无物料冲击识别中, 模型正确分类了 241 个样本, 仅有 11 个非籽粒冲击样本被误判为籽粒冲击; 在籽粒冲击情况识别中, 模型成功识别出 168 个籽粒冲击样本, 32 个籽粒冲击样本被误判

为非籽粒冲击。模型总体准确率达到 94.2%,精确率为 96.2%,召回率为 92%,F1 分数为 94.1%,表明所提出的 VS-1D CNN 模型能够有效区分籽粒与杂余冲击信号。

3.5 模型消融试验

为探究模型中不同组件对分类性能的影响,设计了消融试验,以评估卷积核结构和池化层设计对模型表现的影响。基准模型(VS-1D CNN)采用多尺度卷积核(3、5、7)与自适应最大池化组合,旨在捕获冲击信号不同时间尺度的特征信息。为进一步分析单一卷积核表现,设计了3种变体模型结构:SingleConv-AdaptiveMax 结构,使用单一卷积核(尺寸为5)与自适应最大池化层;SingleConv-AdaptiveAvg 结构,采用相同的单一卷积核,利用自适应平均池化替代最大池化;SingleConv-FixedMax

结构,结合单一卷积核与固定大小最大池化层(池化核大小为2)。

消融试验结果如表2所示,基准模型(VS-1D CNN)在整体性能上表现最佳。相比之下,SingleConv-AdaptiveAvg 模型结构表现接近基准模型,其测试集准确率为 94.0%,精确率为 93.3%,召回率为 94.8%,F1 分数为 94.1%,展示了稳定的分类能力。而 SingleConv-FixedMax 在召回率上达到 100%,但其精确率略低,仅为 88.7%,测试集总体准确率为 93.6%,表明其对正样本的识别能力较强,但对负样本的误判率较高。相比之下,SingleConv-AdaptiveMax 的性能相对较弱,测试集准确率为 87.8%,精确率为 94.4%,召回率为 80.4%,F1 分数为 86.8%,说明其分类能力存在一定局限性。

表 2 消融试验对比结果
Tab.2 Comparative results of ablation test %

模型结构	卷积核类型	池化层类型	准确率	精确率	召回率	F1 分数
VS-1D CNN	多尺度卷积核(3,5,7)	自适应最大池化	94.2	96.2	92.0	94.1
SingleConv-AdaptiveMax	单一卷积核(5)	自适应最大池化	87.8	94.4	80.4	86.8
SingleConv-AdaptiveAvg	单一卷积核(5)	自适应平均池化	94.0	93.3	94.8	94.1
SingleConv-FixedMax	单一卷积核(5)	固定大小最大池化	93.6	88.7	100	94.0

综上所述,通过消融试验可以发现,多尺度卷积核的设计显著提升了模型的特征提取能力,自适应最大池化策略能够有效减少信息损失,从而使基准模型在准确率、精确率、召回率和 F1 分数等指标上均表现出色。这表明基准模型(VS-1D CNN)在籽粒与杂余冲击信号分类任务中具有显著优势。

3.6 模型性能对比验证

为验证 VS-1D CNN 模型性能,本文选取了朴素贝叶斯(Naive Bayes)、多层感知机(MLP)、长短期记忆网络(LSTM)和支持向量机(SVM)作为对比,在相同的数据集上进行了性能对比测试。如图14所示,所提出的VS-1D CNN 算法模型取得了最优识别性能,总体准确率达到 94.2%,显著优于其他对比方法。在传统机器学习方法中,朴素贝叶斯模型准确率仅为 68.7%,识别性能较差。SVM 模型表现相对较好,准确率 82.1%,正样本识别精确率达到 91%。在深度学习方法中,四层全连接 MLP 网络准确率仅为 82.4%,但各项指标较为均衡。理论上更适合处理时序数据的 LSTM,在本任务中仅获得 72.5%的准确率,说明复杂循环结构并不适合本文的籽粒冲击识别任务。

相比之下,VS-1D CNN 模型在各项性能指标上均表现出明显优势。其准确率比 SVM 模型高出约 12 个百分点,精确率达到 96.2%,F1 分数达到




图 14 不同模型性能对比
Fig.14 Model performance comparison

94.1%,为所有对比模型中最优。这些结果表明,通过变尺度结构设计,VS-1D CNN 能够更有效地提取籽粒冲击信号特征。特别是在精确率方面显著提升,说明该模型在减少误判方面具有独特优势,这对实际应用具有重要意义。

4 试验验证

4.1 不同工作条件对模型检测准确率影响试验

传统检测方法通过在时域设定固定电压幅值和冲击信号衰减间隔时长来综合判断是否为籽粒冲击,本文构建了VS-1D CNN 籽粒识别分类模型,利用不同尺寸卷积核,从大量样本中提取籽粒、杂余冲击特征从而消除固定时间阈值设置难、不同机型适应性差的问题。

研究表明,籽粒流量和传感器安装位置会对时

域信号产生较大影响。单位时间内籽粒流量会影响时间间隔相关阈值的确定,而传感器不同安装位置,本文主要指安装高度和安装角度,会影响物料冲击力的大小,直接影响籽粒冲击时域信号幅值和衰减时间相关阈值的确定。因此,选定籽粒流量和传感器安装位置作为试验因素,以验证所设计模型相对于传统方法的性能优越性。

研究表明,玉米籽粒直收机损失流量在 20 ~ 40 粒/s 之间^[11],设置 20、30、40 粒/s 共 3 个水平;安装位置结合实际要求并参考现有研究^[22],取安装高度为 15、25、30 cm,安装角度为 30°、40°、45°。此处安装高度指从传送带平面到传感器敏感板中心的垂直距离。根据籽粒流量和安装位置设计了三因素三水平试验(表 3),试验采用前述数据采集获取试验平台开展,每组试验重复 3 次,取平均值作为每组最终结果。

表 3 试验设置			
Tab.3 Test setups			
水平	因素		
	流量/(粒·s ⁻¹)	安装高度/cm	安装角度/(°)
1	20	15	30
2	30	25	40
3	40	30	45

4.2 模型综合分类性能试验

玉米籽粒直收机实际田间作业时,排杂口脱出物包含有玉米籽粒、穗轴和秸秆,三者混杂在一起。为进一步验证所设计算法模型分类识别能力,本文




图 15 不同籽粒流量和安装位置对模型检测准确率的影响

Fig. 15 Effect of different seed flow rates and mounting locations on model detection accuracy

籽粒流量是影响检测准确率的重要因素。图 16 为将不同籽粒流量下各安装高度不同安装角度下检测准确率取平均后的折线图。从图 16 可以明显观察出,随着籽粒流量不断增大,检测准确率整体呈现下降趋势,在安装高度 15 cm 和 20 cm 下,下降趋势不明显,尤其是安装高度 15 cm 下,籽粒流量在 30 粒/s 时反而比 20 粒/s 时检测准确率略高一些,这也从侧面反映出 VS-1D CNN 模型在不同工作条件下的鲁棒性。图中在安装高

设计了不同比例的物料混合物,随机均匀地散落在传送带上,在安装高度 25 cm 和安装角度 40°下开展试验,每组重复进行 3 次,取平均值作为每组最终结果。物料比例设置如表 4 所示,其中穗轴和秸秆按照约 3:1 分配,在称量好籽粒质量后,人工对籽粒个数进行计数,试验完成后,与模型检测籽粒数进行对比,以此评价模型准确性。

表 4 物料混合比例设置				
Tab.4 Material mixing ratio setting				
序号	籽粒	穗轴	秸秆	总计
1	25	360	115	500
2	50	340	110	500
3	75	320	105	500

4.3 试验结果与分析

(1)不同工作条件

图 15 展示了不同籽粒流量、不同安装高度和安装角度下各组试验检测准确率。从图 15 可以看出,当籽粒流速在 20、30 粒/s 时,模型在不同安装位置的性能表现比较稳定,20 粒/s 时检测平均准确率较高,30 粒/s 时在安装高度 15 cm 和 25 cm 下,各安装角度下,检测准确率依然比较稳定,虽然在安装高度 30 cm 下,模型检测准确率有所下降,但依然保持较高的检测准确率,表明模型对安装位置具有一定的鲁棒性,对不同安装位置情况下的籽粒冲击特征可以精准识别。此外,从图中还可以看出,不同安装高度和籽粒流量下,传感器安装角度为 40°时在各组保持了较高的检测准确率,优于其他两种安装角度。

度 30 cm 下,检测准确率随着籽粒流量增大直线下降,表明高安装高度和大籽粒流量两方面因素叠加对检测准确率有较大影响。一方面安装高度增大导致籽粒冲击强度变高,信号衰减时间变长;另一方面籽粒流量增大,会造成籽粒冲击特征叠加,即前一个冲击特征信号还没有衰减结束,下一个冲击信号已经到来,叠加较高安装高度的影响,算法模型会出现将两个或两个以上籽粒冲击识别成一个或少于实际个数的情况,从而降低检测准确

率。因此,实际安装时应该根据联合收获机喂入量来确定传感器安装位置。




图 16 各籽粒流量下各安装高度平均检测准确率

Fig. 16 Mean detection accuracy for each installation height at each seed flow rate

(2) 不同比例物料混合条件

不同比例物料混合条件下传感器检测准确率结果如图 17 所示。从图 17 可以看出,在 500 g 物料总质量,25、50、75 g 玉米籽粒混合比例范围内,传感器综合分辨能力最高达 95% 左右,可以满足实际工作要求。




图 17 500 g 物料总质量、不同比例混合物料下检测准确率

Fig. 17 Detection accuracy with different ratios of mixtures

从图 17 可以看出,不同混合比例下,传感器检测准确率不一,50 g 籽粒质量、500 g 物料总质量混合比例下损失检测准确率最高。存在以下可能原因:在 25 g 混合比例下,可能存在较多质量体积较大的秸秆和穗轴,一方面可能会夹杂籽粒导致其不能正常冲击敏感板造成漏识别,另一方面,较多杂余冲击敏感板可能会产生与籽粒冲击特征类似以致于模型不能分辨的特征信号,造成误识别率升高降低检测准确率。而 75 g 籽粒质量、500 g 物料总质量混

合比例下,由于籽粒较多,造成连续冲击籽粒个数上升,如果冲击间隔较小,造成信号混叠,也会造成漏识别的情况发生,从而降低检测准确率。虽然在这两种混合比例下传感器检测准确率相比 50 g 籽粒质量、500 g 物料总质量混合比例低,但仍然可以满足实际作业要求。

通过台架试验验证了传感器在不同工作条件、不同安装位置以及不同比例混合物料下的检测准确率,分析了检测准确率的影响因素,为田间作业安装提供了理论依据。台架试验结果表明,所提出的 VS-1D CNN 籽粒冲击识别分类算法模型对不同工作条件具有一定的鲁棒性,同时该模型也存在籽粒流量过大、安装高度不合理、杂余混杂比例过大情况下识别准确率下降的问题,但综合来讲,该系统可以满足实际作业时损失检测的要求。

5 结论

(1) 针对籽粒冲击信号特征,设计了信号采集、处理与传输电路、参数存储和数据通信电路。开发了数据信号处理下位机程序,设计了数据采集、参数设置上位机程序,实现了检测系统数据采集、处理、可视化与损失检测功能,所设计的软硬件系统满足物料高速冲击信号的采集与处理要求。

(2) 分析了传统损失检测方法特点,提出了一种基于 VS-1D CNN 的损失检测分类算法。将该模型与 MLP、SVM、LSTM、Naive Bayes 等常见的分类模型进行了对比。对比结果表明,VS-1D CNN 模型对玉米损失检测分类性能远优于其他模型,验证了所提出算法的正确性。

(3) 分析了影响损失检测准确率的主要因素,设计了籽粒流量、传感器安装高度和角度三水平三因素试验,开展了不同工作条件下损失检测准确率影响试验,试验结果表明,所设计的 VS-1D CNN 算法对不同工况具有一定的鲁棒性,检测准确率最高可达到 95% 以上。

(4) 开展了不同比例籽粒、穗轴和秸秆物料混合条件下系统综合分类性能试验,试验结果表明,所设计的基于 VS-1D CNN 的损失检测模型准确率在 95% 左右,可以满足实际损失检测要求。

参 考 文 献

[1] 李道亮,李震. 无人农场系统分析与发展展望[J]. 农业机械学报,2020,51(7):1-12.
LI Daoliang, LI Zhen. System analysis and development prospect of unmanned farming[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(7):1-12. (in Chinese)

[2] ELDREDGE K W, CLARE B R. Grain loss indicator: AUS, US044909640[P]. 1985-01-01.

[3] YILMAZ D, SAGIROGLU H C. Development of measurement system for grain loss of some chickpea varieties [J]. Measurement, 2015, 66: 73-79.

- [4] 梁振伟, 李耀明, 赵湛, 等. 籽粒损失监测传感器敏感板局部约束阻尼设计[J]. 农业机械学报, 2014, 45(8): 106 – 111, 79.
LIANG Zhenwei, LI Yaoming, ZHAO Zhan, et al. Partial constrained damping design of sensitive plate for grain loss monitoring sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(8): 106 – 111, 79. (in Chinese)
- [5] 梁振伟. 多风道清选装置设计方法及清选损失监测与控制技术研究[D]. 镇江: 江苏大学, 2018.
LIANG Zhenwei. Study on designing method of multi-ductair-and-screen cleaning unit and grain sieve loss monitoring and controlling technology[D]. Zhenjiang: Jiangsu University, 2018. (in Chinese)
- [6] 孙莹. 基于 PVDF 压电薄膜的双层十字交叉型颗粒碰撞传感器的基本特性研究[D]. 杭州: 浙江大学, 2018.
SUN Ying. The basic characteristics of grain impactsensor utilizing two crossed PVDF films [D]. Hangzhou: Zhejiang University, 2018. (in Chinese)
- [7] 曹蕊. 基于 DSP 的多通道 PVDF 压电薄膜谷物损失传感器信号处理系统研究[D]. 杭州: 浙江大学, 2020.
CAO Rui. Research on signal processing system of multi-channel PVDE piezoelectric thin film grain loss sensor based on DSP [D]. Hangzhou: Zhejiang University, 2020. (in Chinese)
- [8] 聂鑫. 稻麦联合收割机收获损失在线检测软件系统的设计与实现[D]. 杭州: 浙江大学, 2021.
NIE Xin. Design and implementation of online detection software system for harvesting loss of rice and wheat combine harvester [D]. Hangzhou: Zhejiang University, 2021. (in Chinese)
- [9] DONG J, ZHANG D, YANG L, et al. Design and experiment of maize kernel loss monitoring system based on signal interval duration[J]. Computers and Electronics in Agriculture, 2023, 213: 108230.
- [10] 王卓, 车东, 白晓平, 等. 玉米联合收获机清选损失监测装置设计与试验[J]. 农业机械学报, 2018, 49(12): 100 – 108.
WANG Zhuo, CHE Dong, BAI Xiaoping, et al. Improvement and experiment of cleaning loss rate monitoring device for corn combine harvester[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 100 – 108. (in Chinese)
- [11] 刘阳春, 李明辉, 王吉中, 等. 玉米籽粒直收机夹带损失检测系统设计与试验[J]. 农业机械学报, 2023, 54(5): 140 – 149.
LIU Yangchun, LI Minghui, WANG Jizhong, et al. Design and test of entrainment loss detection system for corn kernel direct harvester[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 140 – 149. (in Chinese)
- [12] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey[J]. Mechanical Systems and Signal Processing, 2021, 151: 107398.
- [13] CACCIARI I, RANFAGNI A. Hands-on fundamentals of 1D convolutional neural networks—a tutorial for beginner users[J]. Applied Sciences, 2023, 14(18): 8500.
- [14] 吴俊, 管鲁阳, 鲍明, 等. 基于多尺度一维卷积神经网络的光纤振动事件识别[J]. 光电工程, 2019, 46(5): 79 – 86.
WU Jun, GUAN Luyang, BAO Ming, et al. Vibration events recognition of optical fiber based on multi-scale 1D CNN[J]. Opto-Electronic Engineering, 2019, 46(5): 79 – 86. (in Chinese)
- [15] WANG X, MAO D, LI X. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D CNN network [J]. Measurement, 2021, 173: 108518.
- [16] 周锐, 康英伟. 基于 CNN – LSTM 的燃气轮机燃烧室故障预警[J]. 热能动力工程, 2024, 39(1): 191 – 197, 215.
ZHOU Rui, KANG Yingwei. Fault warning of gas turbine combustor based on CNN – LSTM[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(1): 191 – 197, 215. (in Chinese)
- [17] HE J, LI X, CHEN Y, et al. Deep transfer learning method based on 1D – CNN for bearing fault diagnosis[J]. Shock and Vibration, 2021, 2021(1): 6687331.
- [18] LIN X, JIANG Q, SHEN Y, et al. Multiscale pooled convolutional domain adaptation network for intelligent diagnosis of rolling bearing under variable conditions[J]. IEEE Sensors Journal, 2023, 23(21): 26163 – 26176.
- [19] LOSS L H, HARA K, SAITO D, et al. Analysis of function of rectified linear unit used in deep learning [C] // 2015 International Joint Conference on Neural Networks (IJCNN), 2015: 1 – 8.
- [20] ZHOU Y, WANG X, ZHANG M, et al. MPCE: a maximum probability based cross entropy loss function for neural network classification[J]. IEEE Access, 2019, 7: 146331 – 146341.
- [21] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[J]. arXiv preprint arXiv: 1502.03167, 2015.
- [22] WEI D, WU C, JIANG L, et al. Design and test of sensor for monitoring corn cleaning loss[J]. Agriculture, 2024, 13(3): 663.