

基于 GAF - DenseNet 的旋耕作业质量等级识别模型

李淑艳^{1,2} 李若晨^{1,2} 温昌凯^{1,2} 万科科^{1,2} 宋正河^{1,2} 刘江辉³

(1. 中国农业大学工学院, 北京 100083;
2. 中国农业大学现代农业装备优化设计北京市重点实验室, 北京 100083;
3. 洛阳西苑车辆与动力检验所有限公司, 洛阳 471003)

摘要:为实现基于拖拉机多传感器实测载荷数据的旋耕作业质量准确识别,提出一种基于 GAF - DenseNet 的拖拉机旋耕作业质量等级识别模型,设计旋耕作业质量等级分级标准,开展旋耕作业田间试验,并进行模型准确性验证和性能分析。该模型通过格拉姆角场(Gramian angular field, GAF)算法,在保留原始载荷序列的时间依赖性的前提下,对时间序列数据进行唯一编码。DenseNet 网络对图像阵列中内含的载荷信息进行深层挖掘,通过特征重用、模型压缩等技术环节,在保证特征提取深度的同时,显著提升该网络的运算效率。分析结果表明:过大或过小的重采样滑动窗口大小均会降低模型性能,且格拉姆角差场(Gramian angular difference field, GADF)实验效果强于格拉姆角和场(Gramian angular summation field, GASF),实验数据显示在重采样滑动窗口大小为 250 且选用格拉姆角差场的条件下,模型性能达到最优。增长率 k 与模型整体性能呈正相关的趋势,但过大的 k 值会降低模型的实时性能且对于准确性提升有限,实验场景下将增长率 k 设为 24 更能符合实际需求。GAF - DenseNet 模型准确率和 F1 值分别达到 96.816% 和 96.136%,并且在实时性能上具有良好表现,推理时长可低至 16 s。在与其他智能算法对比分析中,该模型整体性能均优于对照组实验结果。

关键词:旋耕; 作业质量; 分类识别; 格拉姆角场; 卷积神经网络

中图分类号: S24; S219.1 文献标识码: A 文章编号: 1000-1298(2022)11-0441-09

OSID:



Quality Indentification Model of Tractor Rotary Tillage Based on GAF - DenseNet

LI Shuyan^{1,2} LI Ruochen^{1,2} WEN Changkai^{1,2} WAN Keke^{1,2} SONG Zhenghe^{1,2} LIU Jianghui³

(1. College of Engineering, China Agricultural University, Beijing 100083, China
2. Beijing Key Laboratory of Optimized Design for Modern Agricultural Equipment, China Agricultural University, Beijing 100083, China
3. Luoyang Xiyuan Vehicle and Power Inspection Institute Co., Ltd., Luoyang 471003, China)

Abstract: To achieve accurate prediction of rotary tillage quality based on tractor multi-sensor load data, a tractor rotary tillage quality identification model based on GAF - DenseNet was proposed, rotary tillage quality grading standard was designed, and field tests of rotary tillage were carried out, and model accuracy verification and performance analysis were conducted. The Gramian angular field (GAF) algorithm uniquely encoded the time series data while preserving the time dependence of the original load sequence. The DenseNet network deeply mined the load information embedded in the image array, and significantly improved the computing efficiency of this network while ensuring the depth of feature extraction through feature reuse, model compression, and other technical aspects. The analysis results showed that the model performance was reduced by either too large or too small a resampling sliding window size and the experimental effect of Gramian angular difference field (GADF) was stronger than Gramian angular summation field (GASF), and the experimental data showed that the model performance was optimal when the resampling sliding window size was 250 and the GADF algorithm was selected. The growth rate k tended to be positively correlated with the overall performance of the model, but too large a

value of k reduced the real-time performance of the model and had limited improvement in accuracy, and the growth rate k was set to 24 in the experimental scenario to better meet the actual demand. The GAF – DenseNet model achieved accuracy and F1 value of 96.816% and 96.136%, respectively. It had good performance in real-time capability, and the inference time can be as low as 16 s. The overall performance of this model was better than the control group analysis results in the comparison tests with other intelligent algorithms.

Key words: rotary tillage; operation quality; classification; Gramian angular field; convolutional neural network

0 引言

作为田间农业生产的重要环节,拖拉机旋耕工况的作业质量对农作物全周期生长水平与生产过程具有重要影响^[1-2]。现阶段,对旋耕作业质量的分析和评估主要依靠人工方式进行,评价方法和效果极大程度上受拖拉机操作人员的视野和经验的影响,缺乏准确、客观的评判标准作为参考;并且,在田间作业过程中,作业质量的评判易受主观和外界环境等因素干扰,难以保证评判效果的稳定和统一^[3-6]。

拖拉机开展田间旋耕作业时,由于受到土地-机器-植物复杂非线性系统中存在的频繁变化的相互作用力,拖拉机和旋耕机的连接机构(即液悬挂系统与 PTO 加载系统)常承受复杂多变的非对称循环载荷^[7-10],多通道实测载荷数据中包含了大量可描述作业质量工况的载荷特性与整机特征,通过挖掘和分析典型特征可以有效地对当前所处的作业质量等级进行分类预测^[11-13]。

因此,为实现拖拉机田间旋耕作业质量等级的准确、高效识别,本研究提出一种基于 GAF – DenseNet 的拖拉机旋耕作业质量深度学习分类识别模型,并开展旋耕作业田间试验进行综合性验证。该模型以 3 种旋耕作业质量等级下的多传感器实测载荷数据作为训练输入,通过 GAF 编码将多通道载荷序列编码为二维灰度图像阵列;通过 DenseNet 优化特征传递机制和学习效率,深层挖掘数据中内含的载荷特征。最终,依照旋耕作业质量分级标准,通过分类器对瞬态载荷序列进行分类预测。

本研究依据多项评价指标对该模型的预测效果进行验证,分析评价两种 GAF 编码方式和不同重采样滑动窗口大小对分类准确性等指标的不同影响,并与支持向量机(Support vector machines, SVM)、深度卷积神经网络(Deep convolutional neural network, DCNN)和深度残差网络(Deep residual network, ResNet)进行对比,综合评估不同算法的预测性能,以期为农业机械作业质量预测研究提供参考。

1 拖拉机旋耕作业载荷测试

1.1 旋耕作业质量分级标准

参考国家标准《旋耕机》和《农业机械试验条件测定方法的一般规定》^[14-15],将旋耕作业质量划分为优、中、差 3 个评价等级,分别对应综合评分中的 80 ~ 100 分、60 ~ 80 分和 0 ~ 60 分。选取耕深、耕深稳定性系数、碎土率、驱动轮滑转率等 4 项参数作为旋耕作业质量的评价指标,并为该 4 项评价指标分别赋予权重系数以计算各指标所达到的质量评价分数,最终以 100 分为满分计算得出综合评分^[16]。

每项评价指标均根据表 1 所示计分方法进行计分,计算得出综合评分,计算式为

$$S = \sum_{i=1}^4 W_i s_i$$

(1)

式中 S ——综合评分
 s_i ——各评价指标 i 的评分
 W_i ——各评价指标 i 的权重系数

表 1 旋耕作业质量评价指标和计分方法
Tab. 1 Quality evaluation metrics and scoring methods for rotary tillage

评价指标	权重系数	计分方法
耕深	0.30	以大于等于 180 mm 为 100 分,耕深均值每减少 10 mm,得分减少 10 分
耕深稳定性系数	0.25	以大于等于 85% 为 100 分,80% ~ 85% 为 90 分,以此间隔类推
碎土率	0.20	以大于等于 60% 为 100 分,55% ~ 60% 为 90 分,以此间隔类推
驱动轮滑转率	0.25	以 15% ~ 17% 为 100 分,每增大或减小 1%,得分减 10 分

1.2 拖拉机旋耕作业载荷测试

为获取基于拖拉机关键部件的实测载荷数据,确保数据集的真实性和可靠性,本文以 NI – cDAQ 9035 为核心搭建了拖拉机多传感器综合测试系统,采用分布式架构对多测点、多类型参数进行实时、同步测试,测试参数共计 10 项(表 2),测试系统传感器布置和测试系统架构如图 1、2 所示。其中,驱动轮滑转率由实际车速和驱动轮转速换算得出。针对

试验场景基于 LabVIEW 开发测试系统上位机软件，实现对载荷数据的自动化采集和实时监控。

表 2 拖拉机多传感器综合测试系统测试参数与
配套传感器

Tab.2 Test parameters and supporting sensors of
tractor multi-sensor integrated test system

测试对象	测试参数	传感器
拖拉机行驶参数	实际车速	GNSS 定位模块
	驱动轮滑转率	
动力输出轴参数	PTO 扭矩	法兰式扭矩转速传感器
	PTO 转速	
电液悬挂参数	上拉杆倾角	两轴动态角姿态传感器
	左悬挂点销轴倾角	
	右悬挂点销轴倾角	
	上拉杆拉压力	拉压力传感器
	左悬挂点销轴力	
	右悬挂点销轴力	轴销力传感器

本文所开展的试验工况为旋耕作业,试验样机选用某品牌 52 kW 四轮驱动拖拉机,农机具选用某品牌 ICQN - 180A 型旋耕机。试验用地位于河南省洛阳市新安县磁涧镇赵洼村,试验时间为 2021 年 7 月,耕

作土质为黏土,含水率介于 20% ~ 35% 之间。在实际的田间作业过程中,耕作幅宽为1 800 mm,耕作速度约为 5 km/h,耕作深度根据作业质量划分情况进行人工调节。最后,根据奈奎斯特采样定理,结合实际工程经验,设定采样频率为1 000 Hz^[17]。拖拉机田间作业试验现场如图 3 所示(下方 3 幅图像为耕深测量现场,测量结果分别为 13.6、19.1、21.5 cm)。



图 1 拖拉机多传感器综合测试系统传感器布置图

Fig.1 Overall layout of tractor multi-sensor integrated
test system




图 2 拖拉机多传感器综合测试系统架构

Fig.2 Structure of tractor multi-sensor integrated test system



图 3 拖拉机田间作业试验现场

Fig.3 Tractor field test site

2 基于 GAF - DenseNet 的识别模型

2.1 GAF 图像编码

基于坐标变换的思想,格拉姆角场 (Gramian angular field, GAF) 可在保留数据时间依赖性的前

提下,将一维时间序列编码为二维灰度图像^[18]。

对于本文中的实测载荷数据,可将其表示为包含 n 个元素的时间序列 $X = \{x_1, x_2, \dots, x_n\}$ 。首先,将该时间序列缩放至 $[-1, 1]$ 范围内,计算式为

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (2)$$

式中 $\tilde{x}_i$ ——缩放后时间序列 $\tilde{X}$ 中的元素
随后,将相应值编码为角余弦 $\cos\varphi$,将其时间戳编码为半径 r ,缩放后的时间序列 $\tilde{X}$ 即可表示为极坐标形式,计算式为

$$\begin{cases} \varphi = \arccos \tilde{x}_i & (-1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X}) \\ r = \frac{t_i}{N} & (t \in \mathbf{N}) \end{cases} \quad (3)$$

式中 t_i ——时间戳
 N ——用于正则化极坐标系跨度的常数
由于式(3)中 $\varphi \in [0, \pi]$, 在该区间内 $\cos(\varphi)$ 单调, 所以缩放后的时间序列 $\tilde{X}$ 与其极坐标形式互为双射, 确保了该编码方式的唯一性^[19-20]。
计算每个点之间的三角和/差, 通过两种不同的方式来识别数据点在不同时间间隔内的时间相关性。对应地, GAF 算法可分为格拉姆角和场 (Gramian angular summation field, GASF) 和格拉姆角差场 (Gramian angular difference field, GADF), 其计算方法分别为

$$\mathbf{G}_s = [\cos(\varphi_i + \varphi_j)] = \tilde{\mathbf{X}}^T \tilde{\mathbf{X}} - \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^{T2}} \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2}$$

(4)

$$\mathbf{G}_d = [\sin(\varphi_i - \varphi_j)] = \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^{T2}} \tilde{\mathbf{X}} - \tilde{\mathbf{X}}^T \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2}$$

(5)

式中 $\mathbf{G}_s$ ——GASF 矩阵 $\mathbf{G}_d$ ——GADF 矩阵
 $\mathbf{I}$ ——单位行向量
 $\tilde{\mathbf{X}}^T$ —— $\tilde{\mathbf{X}}$ 的转置向量
 i, j ——行、列索引, $i, j \in \mathbf{N}$ 且 $1 \leq (i, j) \leq n$
在 GAF 矩阵中, 随着位置从左上角移动到右下角, 其对应的时间戳也随之增加, 因此, 原时间序列




图5 密集块结构
Fig.5 Structure of dense block

设密集块网络包含 N 层, 每层卷积后均输出 k 个特征图, k 作为超参数被定义为增长率, 假定输入密集块的特征图通道数为 k_0 , 则第 n 层输入的通道数为 $k_0 + k(n - 1)$ 。各层输出的特征图大小一致, 特征图在通道维度上进行拼接, 即第 n 层的输出 x_n 由前面所有层拼接而得, 即

$$x_n = H_n([x_0, x_1, \cdots, x_{n-1}])$$

(6)

式中 x_n ——第 n 层输出
 H_n ——非线性组合函数
其中, 非线性组合函数由批标准化 (Batch normalization, BN) 层、线性修正单元 (Rectified linear unit, ReLU) 和 3×3 卷积 (Convolution, Conv) 层组成。
密集块结构作为基本单元, 与过渡层 (Transition layer) 交替串联构成 DenseNet 模块。在 DenseNet 模块的基础上, 为改善特征图信息密度不足的问题, 通

的时间依赖性得以保留。此外, 矩阵主对角线包含了原始值和角度信息, 可有效表示原时间序列的时间相关性^[21-22]。优作业质量工况下某数据段的 GAF 编码效果如图 4 所示。




图4 某实测载荷数据段 GAF 编码示意图
Fig.4 Schematic of GAF encoding for a segment of measured load data

2.2 GAF - DenseNet 模型

DenseNet 网络模型沿用 ResNet 中短路连接的基本思想^[23-24], 在此基础上强化了前层与后层之间的密集连接, 通过通道间的拼接以实现特征重用^[25]。作为其核心模块, 密集块 (Dense block) 的结构如图 5 所示。
过 GAF 编码算法在时间、幅值两个维度上对原始载荷序列进行解构, 将一维时间序列重组为二维灰度图像矩阵, 既实现了特征信息密度的有效扩充, 又使得特征信息在二维图像空间中排列规则化, 从数据层面间接提升了分类预测精度。最终, 将 GAF 编码算法和 DenseNet 网络有效融合, 形成了 GAF - DenseNet 识别模型, 整体结构如图 6 所示。

GAF - DenseNet 模型由 GAF 编码器、DenseNet 和分类器共 3 个模块组成。GAF 编码器将输入模型的多通道载荷序列编码为二维灰度图像阵列, DenseNet 模块依靠卷积层提取二维灰度图像阵列为特征图, 并在通道维度上对特征图进行特征重用和密集连接, 以优化特征的传递机制和利用效率。其中, 为提高网络紧凑性, 引入过渡层以缩减特征图大小。过渡层包含批标准化层、 1×1 卷积层和 2×2 平均池化层, 对于密集块所输出的 m 个特征图, 经




图 6 GAF - DenseNet 模型整体结构

Fig. 6 Overall structure of GAF - DenseNet model

过渡层转换后可产生 θm 个特征,其中 $\theta \in (0,1]$ 为压缩系数。

DenseNet 模块输出的特征进入分类器后,经过全局平均池化进入 3 层全连接网络。其中,最后一个全连接层使用 Softmax 分类器输出分类预测结果。GAF - DenseNet 模型参数配置如表 3 所示。

表 3 GAF - DenseNet 模型参数

Tab. 3 Parameters of GAF - DenseNet model			
网络层	输出尺寸	GAF - DenseNet	参数数量
GAF 编码	(200, 200, 10)		0
卷积层	(200, 200, 24)	2×2 Conv, stride 2	1 080
密集块(1)	(200, 200, 168)	$\begin{bmatrix} 1 \times 1 \text{ Conv} \\ 3 \times 3 \text{ Conv} \end{bmatrix} \times 12$	121 392
过渡层(1)	(100, 100, 84)	1×1 Conv, stride 1 2×2 Avg Pooling, stride 2	14 868
密集块(2)	(100, 100, 228)	$\begin{bmatrix} 1 \times 1 \text{ Conv} \\ 3 \times 3 \text{ Conv} \end{bmatrix} \times 12$	158 832
过渡层(2)	(50, 50, 114)	1×1 Conv, stride 1 2×2 Avg Pooling, stride 2	27 018
密集块(3)	(50, 50, 258)	$\begin{bmatrix} 1 \times 1 \text{ Conv} \\ 3 \times 3 \text{ Conv} \end{bmatrix} \times 12$	177 522
分类器	(3,)	7×7 GAvg Pooling 1000D 全连接, Softmax	1 809

3 旋耕作业质量等级识别分析

3.1 数据预处理

基于本文所制定的旋耕作业质量分级标准,在实际田间地块中分别开展 3 种作业质量工况下的拖拉机旋耕作业试验,总作业面积约为 2 hm²。在实测数据中去除驻车、转向、掉头等行驶状态相关的数据段,获得 3 种作业质量下的数据量均为 40 000,数据通道数为 10(表 2 中所述测试参数),保留数据样本共 120 000 个,生成原始数据集尺寸为 (120 000,

10)。

首先,为扩展数据量,防止过拟合等现象发生,本文采取 3 种方法对原始数据集进行联合处理:①为保留原始数据集中所包含的随机环境噪声,对原始数据集不作任何处理。②采用最小二乘法拟合原始数据集中的非线性趋势项并将其消除,设计 8 阶巴特沃斯滤波器对数据进行低通滤波,依据课题组项目经验,将截止频率设为 48 Hz。③在方法 2 处理后的数据中叠加高斯噪声。

合并经 3 种方法处理后的数据样本,数据量由 120 000 扩展为 360 000,数据集尺寸变为 (360 000, 10)。

为确保数据集尺度的统一性和统计分布的合理性,对数据集进行归一化和标准化处理,处理后载荷序列的统计直方图分别如图 7 和图 8 所示。

分析可知,经过归一化处理,不同维度的载荷序列在尺度上统一缩放至 $[-1,1]$ 内;进一步对载荷序列做标准化处理,处理后的载荷序列在统计分布上趋于高斯分布,其平均值趋近于 0,标准差趋近于 1。

设定时间步长为 250 的滑动窗口,采用半重叠时间窗 (Semi non-overlapping temporal window, SNOW) 将载荷序列分割为 2 871 个样本,窗口重叠率为 50%。对重采样后的数据进行 GAF 图像编码,如图 9 和图 10 所示,并对 3 种作业质量分类标签进行 One-hot 编码,得到的数据集尺寸为 (2 871, 250, 250, 10)。

本文的预测分析基于 TensorFlow 2.7 深度学习框架实现,操作系统选用 Ubuntu 18.04,硬件环境为 NVIDIA Tesla K80 GPU, Intel Xeon 8369 CPU。

在训练网络过程中,采用 5 折交叉验证方法和 mini-batch 技术,批次大小设为 64,模型训练按照




图7 优作业质量下载荷序列的归一化处理结果

Fig. 7 Normalization of load sequences under high quality of rotary tillage




图8 优作业质量下载荷序列的标准化处理结果

Fig. 8 Standardization of load sequences under high quality of rotary tillage




图9 经 GASF 编码后的优作业质量下某样本二维图像阵列

Fig. 9 2D image arrays in high quality of rotary tillage after GASF encoding




图10 经 GADF 编码后的优作业质量下某样本二维图像阵列

Fig. 10 2D image arrays in high quality of rotary tillage after GADF encoding

固定步长迭代 100 轮。选用交叉熵损失函数跟踪模型迭代过程中的损失值变化,选用 Adam 算法对网络参数进行自适应优化迭代,初始学习率设为 1×10^{-3} 。

3.2 编码效果分析

为探究不同数据集尺寸和编码方式对 DenseNet 模型训练效果的影响,设定滑动窗口大小为 200、250 和 300,选用 GASF 和 GADF 两种编码方式对预处理后的数据集分别编码,随后将编码后的二维灰度图像阵列输入至 DenseNet 模型中进行训练,测试集准确率和损失值变化曲线分别如图 11 和图 12 所示。其中,DenseNet 模型增长率 k 设为 24,压缩系数设为 0.5。




图 11 经不同滑动窗口大小和编码方式处理后的测试集准确率变化曲线

Fig. 11 Trends in accuracy of test sets processed by different window sizes and encoding methods




图 12 经 GADF 编码后的测试集损失值变化曲线

Fig. 12 Trends in loss of test sets processed by different window sizes and encoding methods

随着滑动窗口大小的增大,每个样本中包含的图像信息随之增多,其中表征旋耕作业工况的特征信息也更加丰富。分析图 11 和图 12 可知,当窗口大小由 200 提升至 250 时,测试集准确率有明显提升,损失值收敛更加彻底。然而,当窗口大小由 250 提升至 300 之后,测试集准确率和损失值反而降低,在迭代 40 轮之后出现了无法收敛的情况。分析现象可知,在针对时间序列数据的滑动窗口重采样时,

更大的窗口大小并不一定总利于特征的获取,而可能会引入噪声或无用特征,从而影响数据集的整体质量。

在编码方式方面,GASF 和 GADF 两种编码方式均能较好地保留和提取样本中的特征信息。分析图 11 和图 12 可知,经两种方法编码后的数据集在准确率和损失值上均有良好的表现。其中,GADF 编码后的数据在迭代过程中变化态势更加平顺,在准确率和损失值两项性能指标上均有小幅提升。

3.3 模型参数分析

为探究增长率 k 对于模型性能的影响,针对 DenseNet 关键超参数增长率 k 的选取,本文最终确定 k 为 12、24、32、40。其中,基于控制变量的思想,本试验所选用的数据集经过半重叠时间窗进行数据重采样(窗口大小设为 250),并采用 GADF 方法进行图像编码。试验结果如表 4 所示。

表 4 在不同增长率 k 下的 DenseNet 模型测试集分析结果

Tab. 4 Analysis results of test sets at different growth rates k of DenseNet model				
增长率 k	参数量/MB	准确率/%	损失值	推理时长/s
12	5.00×10^5	93.724	1.90×10^{-2}	11
24	9.60×10^6	96.816	4.11×10^{-3}	16
32	1.33×10^7	97.234	1.72×10^{-3}	25
40	1.61×10^7	97.598	9.83×10^{-4}	38

由表 4 可知,随着模型增长率 k 的增大,预测的准确率也随之增加,表明增长率 k 与模型的整体性能呈正相关的趋势。然而,增长率 k 的增大也带来了模型复杂度的提升,具体体现在参数量会随之迅速增长,从而增加了算力负担,模型的实时性受到明显影响。增长率 k 由 24 增长到 40 的过程中,准确率仅提升 0.782 个百分点,而推理时长增长约 2.4 倍。因此,综合考虑模型性能和实时性两个因素,增长率 k 设为 24 更能满足实际应用需求。

3.4 模型综合性能分析

本研究选取测试集的准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 值(F1-score)等指标来综合评价模型性能。首先将本文中的三分类任务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。

在获取多个二分类任务评价指标后,得到三分类任务的混淆矩阵,采用 Macro 规则计算得出最终的综合评价指标。

结合上述模型评价指标,对 GAF - DenseNet 模型进行识别综合性能分析,并选取 SVM、DCNN、

ResNet 等模型进行对比分析,计算得出的各项模型评价指标如表 5 所示。需要特别说明的是,以上网络深度大体接近,其模型参数均分别经过优化调整,且输入数据均经过 GADF 编码为二维灰度图像。

表 5 基于不同模型分析结果的评价指标
Tab.5 Evaluation metrics based on analysis results of different models

模型	准确率/%	损失值	精确率/%	召回率/%	F1 值/%	推理时长/s
GAF-SVM	86.331	2.95×10^{-1}	87.782	84.957	86.337	40
GAF-DCNN	93.705	1.83×10^{-2}	94.772	91.272	92.975	32
GAF-ResNet	95.863	1.31×10^{-2}	96.637	95.139	95.877	25
GAF-DenseNet	96.816	4.11×10^{-3}	96.396	95.881	96.136	16

分析表 5 可知,在准确率和损失值两项指标的表现上,GAF-ResNet 与 GAF-DenseNet 大体接近(后者较前者有小幅提升)且高于其余两种模型,其中 GAF-SVM 模型的准确率水平显著低于其他模型。F1 值是对精确率和召回率两项指标的调和平均,不受样本不平衡等因素影响。相较于其余 3 种模型,GAF-DenseNet 模型在精确率、召回率和 F1 值上均有较大幅度提升,其中 F1 值可达到 96.136%,这表明了该模型在整体性能上明显优于其余模型。在推理速度方面,归结于过渡层在 DenseNet 网络结构中压缩特征方面的重要作用,GAF-DenseNet 模型所用的推理时长最短,较 GAF-ResNet 模型缩短 36%。进一步地,该模型在小批次测试数据的测试条件下,可达到更优越的实时性能。

4 结论

(1)为实现基于多传感器实测数据的拖拉机旋耕作业质量等级准确识别,提出了一种结合 GAF 编码算法和 DenseNet 网络的 GAF-DenseNet 识别模

型。GAF 算法在保留原始载荷序列的时间依赖性的前提下,对时间序列数据进行唯一编码。DenseNet 网络深层挖掘图像阵列中的载荷信息,通过特征重用、模型压缩等技术环节保证特征提取深度,并显著提升运算效率。

(2)针对某 52 kW 拖拉机旋耕作业工况,设计并搭建了拖拉机多传感器综合测试系统。依据本文所制定的旋耕作业质量分级标准,开展了田间旋耕试验,获取了不同分级标准下的多传感器实测载荷数据。

(3)针对本文所提出的 GAF-DenseNet 识别模型,进行了旋耕作业质量等级识别分析。分析结果表明,在重采样滑动窗口大小为 250、编码方式采用 GADF 算法时,模型在准确性、平滑性和收敛效果等方面效果最佳。基于实测数据的 GAF-DenseNet 模型准确率和 F1 值分别达到 96.816% 和 96.136%,并且在实时性能上具有良好的表现,推理时长可低至 16 s。进一步将该模型与其余模型进行对比分析,整体性能均优于对照组模型预测结果。

参 考 文 献

[1] 秦宽,丁为民,方志超,等.犁翻旋耕复式作业耕整机的设计与试验[J].农业工程学报,2016,32(16):7-16.
QIN Kuan, DING Weimin, FANG Zhichao, et al. Design and experiment of plowing and rotary tillage combined machine[J]. Transactions of the CSAE,2016,32(16):7-16. (in Chinese)

[2] MATTETTI M, MOLARI G, SEDONI E S. Methodology for the realisation of accelerated structural tests on tractors[J]. Biosystems Engineering, 2012, 113(3):266-271.

[3] LI L, CHEN S, YANG C, et al. Prediction of plant transpiration from environmental parameters and relative leaf area index using the random forest regression algorithm[J]. Journal of Cleaner Production, 2020, 261:121136.

[4] 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)

[5] WEN C, XIE B, LI Z, et al. Power density based fatigue load spectrum editing for accelerated durability testing for tractor front axles[J]. Biosystems Engineering, 2020, 200:73-88.

[6] WEN C, XIE B, SONG Z, et al. Methodology for designing tractor accelerated structure tests for an indoor drum-type test bench[J]. Biosystems Engineering, 2021, 205:1-26.

[7] 承鉴,迟瑞娟,毛恩荣.悬挂农具对电液悬挂系统拖拉机振动的影响[J].农业工程学报,2015,31(7):24-32.
CHENG Jian, CHI Ruijuan, MAO Enrong. Influence of hanging farm implement on vibration of tractor with electro-hydraulic hitch system[J]. Transactions of the CSAE, 2015, 31(7):24-32. (in Chinese)

[8] 刘长卿,华博,杜岳峰,等.拖拉机电液悬挂系统动压反馈校正方法研究[J].农业机械学报,2020,51(增刊1):535-541.
LIU Changqing, HUA Bo, DU Yuefeng, et al. Dynamic pressure feedback correction method for tractor electro hydraulic hitch[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp.1):535-541. (in Chinese)

[9] 杨子涵,宋正河,尹宜勇,等.基于 POT 模型的大功率拖拉机传动轴载荷时域外推方法[J].农业工程学报,2019,

- 35(15):40-47.
- YANG Zihan, SONG Zhenghe, YIN Yiyong, et al. Time domain extrapolation method for load of drive shaft of high-power tractor based on POT model[J]. Transactions of the CSAE, 2019, 35(15):40-47. (in Chinese)
- [10] HENSH S, TEWARI V K, UPADHYAY G. An instrumentation system to measure the loads acting on the tractor PTO bearing during rotary tillage[J]. Journal of Terramechanics, 2021, 96:1-10.
- [11] 夏俊芳, 李栋, 刘国阳, 等. 基于角度检测的拖拉机悬挂耕深电液监控系统研究[J]. 农业机械学报, 2021, 52(8):386-395.
- XIA Junfang, LI Dong, LIU Guoyang, et al. Design and test of electro-hydraulic monitoring device for hitch tillage depth based on measurement of tractor pitch angle[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8):386-395. (in Chinese)
- [12] 杜新武, 杨绪龙, 庞靖, 等. 悬挂式旋耕机耕深监测系统设计与试验[J]. 农业机械学报, 2019, 50(8):43-51.
- DU Xinwu, YANG Xulong, PANG Jing, et al. Design and test of tillage depth monitoring system for suspended rotary tiller[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8):43-51. (in Chinese)
- [13] 尹彦鑫, 王成, 孟志军, 等. 悬挂式深松机耕整地耕深检测方法研究[J]. 农业机械学报, 2018, 49(4):68-74.
- YIN Yanxin, WANG Cheng, MENG Zhijun, et al. Operation quality measurement method for tilling depth of suspended subsoiler[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4):68-74. (in Chinese)
- [14] 全国农业机械标准化技术委员会. 旋耕机: GB/T 5668—2017[S]. 北京: 中国标准出版社, 2017.
- [15] 全国农业机械标准化技术委员会. 农业机械试验条件 测定方法的一般规定: GB/T 5262—2008[S]. 北京: 中国标准出版社, 2008.
- [16] 顾文威, 崔小冬, 韩晨. 履带式拖拉机和轮式拖拉机旋耕作业质量对比测试流程和评价方法[J]. 南方农机, 2020, 51(24):26-27.
- [17] 赵雪彦, 张青岳, 温昌凯, 等. 基于田间实测载荷的拖拉机转向驱动桥壳疲劳寿命分析[J]. 农业机械学报, 2021, 52(3):373-381.
- ZHAO Xueyan, ZHANG Qingyue, WEN Changkai, et al. Fatigue life analysis of tractor steering drive axle housing based on field measured loads[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3):373-381. (in Chinese)
- [18] ZHANG G, SI Y, WANG D, et al. Automated detection of myocardial infarction using a Gramian angular field and principal component analysis network[J]. IEEE Access, 2019, 7(99):171570-171583.
- [19] WANG Z, OATES T. Imaging time-series to improve classification and imputation[C]//Twenty-Fourth International Joint Conference on Artificial Intelligence, 2015.
- [20] WANG Z, YAN W, OATES T. Time series classification from scratch with deep neural networks: a strong baseline[C]//2017 International Joint Conference on Neural Networks (IJCNN), IEEE, 2017:1578-1585.
- [21] 庞新宇, 仝钰, 魏子涵. 一种 GAF-CNN 行星齿轮箱故障诊断方法[J]. 北京理工大学学报, 2020, 40(11):1161-1167.
- PANG Xinyu, TONG Yu, WEI Zihan. A fault diagnosis method for planetary gearbox based on GAF-CNN[J]. Transactions of Beijing Institute of Technology, 2020, 40(11):1161-1167. (in Chinese)
- [22] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11):97-104.
- ZHENG Wei, LIN Ruiquan, WANG Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11):97-104. (in Chinese)
- [23] HUANG G, LIU Z, VAN D M, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:4700-4708.
- [24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [25] 赵奇慧, 李莉, 张森, 等. 基于迁移学习的温室番茄叶片水分胁迫诊断方法[J]. 农业机械学报, 2020, 51(增刊1):340-347, 356.
- ZHAO Qihui, LI Li, ZHANG Miao, et al. Water stress diagnosis algorithm of greenhouse tomato based on fine-tuning learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1):340-347, 356. (in Chinese)