

DOI: 10.19650/j.cnki.cjsi.J2107866

面向无人化取料机的毫米波雷达感知技术*

孔德明, 张 钰, 曹 帅, 王立成
(燕山大学电气工程学院 秦皇岛 066000)

摘 要:针对散料港口无人化取料机往复取料效率低,毫米波雷达感知数据集噪声多、波动频繁、数据不平衡导致现有机器学习分类模型效果欠佳等问题,提出了一种基于改进模糊孪生支持向量机结合 1-近邻算法的孪生重叠敏感边界分类器的料堆边界感知方法。首先,利用毫米波雷达获取料堆边界扫描数据并进行预处理,依据空间分布以及作业特点设计提取点云的 10 维特征,组成料堆点云样本数据集;其次,引入改进模糊隶属度函数的模糊孪生支持向量机,将料堆点云样本数据集划分为重叠与非重叠区域;然后,采用模糊孪生支持向量机决策边界、1-近邻算法分别对非重叠与重叠区域样本进行分类,以提高对不平衡数据集的分类能力;最后,将得到的分类结果加入感知环节,达到料堆边界感知目的。在人工作业雷达采集的数据集上的实验表明,所提出感知方法有效提高了对少数类的识别能力。现场实验表明,改进后的感知方法更接近操作员的判断,斗轮空转时间占比减少 15.1%,提高了无人化取料机的作业效率,对无人化散料港口的建设具有参考意义。

关键词:毫米波雷达点云;不平衡数据集;模糊支持向量机;孪生支持向量机;智慧港口

中图分类号: TH89 TN958 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Millimeter-wave radar sensing technology for unmanned reclaimer

Kong Deming, Zhang Yu, Cao Shuai, Wang Licheng

(Institute of Electrical Engineering, Yanshan University, Qinhuangdao 066000, China)

Abstract: Unmanned reclaimers in bulk materials ports has the problems of low reciprocating reclaiming efficiency. Meanwhile, the existing machine learning classification models are not effective because of high noise, frequent fluctuations, and unbalanced data of millimeter-wave radar sensing datasets. In this paper, a stack boundary sensing method based on improved fuzzy twin support vector machine combined with 1-Nearest Neighbor algorithm is proposed. Firstly, the millimeter-wave radar is used to obtain the stack boundary scan data and preprocess it. According to the spatial distribution and operation characteristics, the 10-dimensional features of the point cloud are extracted to form the stack point cloud sample dataset; secondly, the improved fuzzy membership function is introduced. The fuzzy twin support vector machine divides the pile point cloud sample dataset into overlapping and non-overlapping regions. Then, the fuzzy twin support vector machine decision boundary and 1-nearest neighbor algorithm are used to classify the non-overlapping and overlapping region samples respectively to improve the classification ability of unbalanced datasets. Finally, the classification results obtained are added to the perception link to achieve the purpose of sensing the boundary of the pile. Experiments on the dataset collected by manual operation radar show that the proposed perception method effectively improves the ability to recognize minority categories. Field experiments show that the improved perception method is closer to the operator's judgment, the idle time of the bucket wheel is reduced by 15.1%, which improves the operating efficiency of the unmanned reclaimer and has reference significance for the construction of unmanned bulk materials ports.

Keywords: millimeter wave point cloud; imbalanced data; fuzzy support vector machines; twin support vector machines; smart port

收稿日期:2021-04-29 Received Date: 2021-04-29

* 基金项目:航空科学基金(20200016099002)项目资助

0 引言

智慧港口是国家倡导的重点发展方向之一,也是现代物流向“智能化、绿色化、高效化”转型升级的重要环节。其中散料港口无人化改造是智慧港口建设不可或缺的一部分,取料机作为散料港口中数量最多、使用率最高的机械设备,其单机作业效率对港口效益的影响最为显著。无人化运行取料机需要环境感知、智能决策、自动执行3个环节支撑,环境感知作为整个系统与外界信息交互的关键,能够提高自身状态和作业环境的理解能力^[1],确保无人化系统安全高效运行。由于目前环境感知对料堆边界识别效果差,取料机在料堆边界减速时斗轮空转时间长,导致取料效率低。因此,优化取料机感知环节对提高港口经济效益、无人化程度以及助力智慧港口建设有重要意义^[2]。

由于环境感知环节中缺乏全面的料堆边界感知手段,无法根据料堆轮廓进行减速位置预判,从而严重影响了取料机作业效率。近年来,超声波雷达、激光雷达、毫米波雷达等传感器以及机器学习算法在自动驾驶领域的广泛应用为无人化取料机系统的环境感知提供了重要参考,使取料机感知系统可以获取料堆轮廓的点云数据,通过机器学习分类算法对人工作业时正常取料过程(“垛中”)和料堆边界减速过程(“垛外”)两类点云数据学习,从而在无人作业时能够预判取料机回转减速位置。然而,在料堆轮廓点云数据的分类问题中,“垛外”样本占样本总数较少,且根据操作员的个人经验标注样本存在错误标注的问题。取料机作业时伴随的机械振动和尘雾水雾也会增加雷达扫描数据的噪声。因此,料堆轮廓点云数据存在样本数量不平衡、样本重叠以及存在噪声样本的问题。

上述问题在机器学习领域中被归类为不平衡数据集问题,其主要包含两类:类间样本数量不平衡问题和类间样本重叠问题。由于传统分类算法大多基于正确率(accuracy)最大化和样本分布平衡建立模型,当训练数据集不平衡时预测结果会出现偏斜性^[3-4],对少数类的分类性能明显降低。目前针对不平衡数据集的解决方法主要有两种,前者基于数据集的改造,通过重采样平衡样本数据集。如Chawla等^[5]提出基于合成新数据的SMOTE过采样算法,通过增加少数类样本平衡数据集。Lin等^[6]提出基于聚类的降采样算法,剔除部分多数类样本平衡数据集,以及Georgios等^[7]提出k-means聚类结合SMOTE的重采样算法,提高了合成数据的可靠性。后者则从机器学习算法改进出发,如Batuwita等^[8]提出了FSVM和改变类间惩罚成本结合的方法(FSVM-CIL),对噪声鲁棒并改善了数据集预测

结果的偏斜性。Zhu等^[9]提出了基于熵的矩阵学习机,并在实际应用中验证了方法的有效性。Batista等^[10]指出类间样本重叠是造成分类算法性能下降的主要原因,而重采样方法对解决样本重叠问题帮助十分有限。现有方法仅对样本不平衡和样本重叠单独进行分析,在实际应用中两类问题同时存在时处理结果不够理想^[11]。综合来看,虽然数据重采样处理不平衡数据集通用性比较好,但存在引入噪声、损失关键信息、容易过拟合、对样本重叠的数据集分类结果改善不明显等问题^[12],所以算法改进更加适合解决实际问题。

本文基于机器学习分类算法对取料机感知系统进行优化,提出通过学习人工作业采集的雷达点云数据特征,来模拟操作员对料堆边界的感知方式。针对传统方法对不平衡数据集处理能力较差的问题,提出了孪生重叠敏感边距(twin overlap-sensitive margin, TOSM)分类模型。对毫米波雷达点云进行预处理并提取特征组成样本数据集后,使用改进的孪生模糊支持向量机(fuzzy twin support vector machines, FTSVM)将数据集分割为非重叠和重叠区域,并对非重叠区域样本分类。在限制重叠区域样本占总体比例的前提下,使用1-NN算法进行重叠样本分类。点云的数据集分类实验证明,所提出分类器性能优于传统分类方法。加入TOSM方法的感知环节能预测出合理减速位置,较斗轮功率和距离预测的方法更接近人工作业,显著减小了取料机在回转边界的斗轮空转时间。

1 料堆边界感知方法

取料作业可分为以下4个过程:接受任务、走行对位、往复取料、到量停止。如图1所示,在接收中控室下发的作业任务后,取料机走行到指定料堆附近完成对位;继而进入往复取料过程:悬臂向左侧回转取料,直至斗轮到达料堆左侧边界,回转减速并向前进车,再向右侧回转取料;当取料量累积到任务额度,则抬升取料机悬臂,停止取料。可见,料堆边界的感知信号参与了往复取料过程的控制,决定斗轮的回转方向。因此,快速、准确的检测料堆边界对提高取料机的作业效率有重要作用。

投运的无人化散料港口中,料堆边界的感知手段有测量料堆切剖面与斗轮距离、斗轮负载功率、料堆模型计算。前两种通过设定阈值判断当前位置能否进车,但无法获知理想进车位置。第3种方法受限于料堆模型误差和数据更新滞后,实际效果不理想。现有边界感知方法均会在边界导致斗轮空转,降低取料效率。因此提出基于毫米波雷达的改进方式,通过雷达点云挖掘料堆轮廓特征,引入机器学习算法识别操作员对料堆形状的预判,模拟人工对料堆边界的处理。

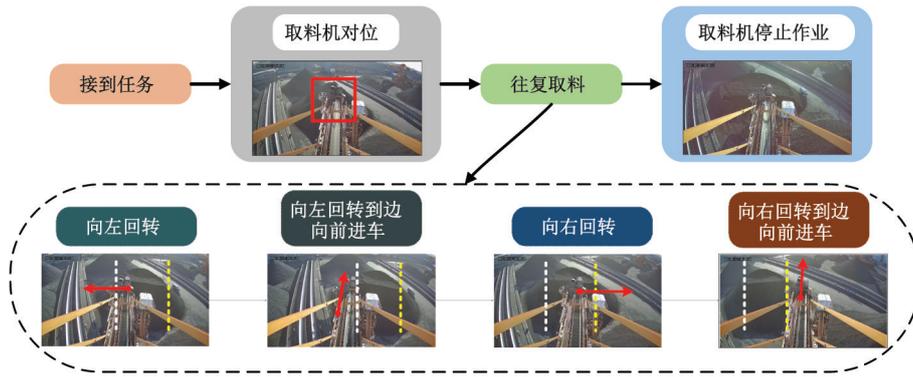


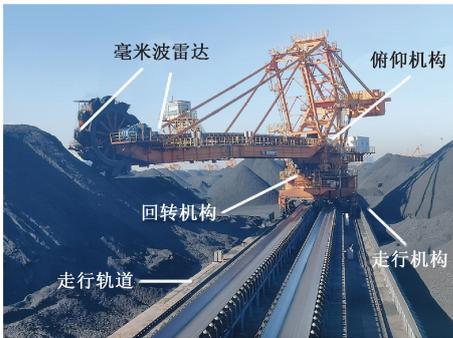
图 1 无人化取料机工作流程

Fig. 1 Workflow of the unmanned reclaimer

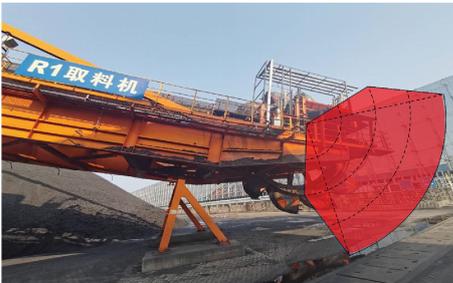
2 基于点云的料堆边界感知

2.1 料堆点云的获取

目前,大场景点云获取方式主要有双目视觉、激光雷达和毫米波雷达,相比前两者,毫米波雷达探测范围大,对雨、雾、烟、尘的穿透能力强^[13],适合大雾天气多、盐雾浓度高、扬尘污染严重的散料港口。基于现有条件在取料机斗轮左右两侧各安装一台毫米波雷达,采集作业中料堆轮廓点云,选用大陆集团 ARS408 毫米波雷达,安装位置如图 2 所示。



(a) 取料机动作机构位置
(a) Location diagram of key mechanism of reclaimer



(b) 毫米波雷达扫描范围
(b) Scanning range of millimeter wave radar

图 2 搭载毫米波雷达的无人化取料机

Fig. 2 Unmanned reclaimer with millimeter wave radar

图 2(a) 所示为典型的悬臂式斗轮取料机,其常用于散料港口连续取料,取料机沿着走行轨道行进,悬臂具有回转和俯仰两个自由度,毫米波雷达安装在斗轮两侧的悬臂上。图 2(b) 所示为右侧雷达安装示意图,雷达扫描平面与地面垂直且与斗轮平行,取料过程中能够获得料堆切削面点云。雷达在 0~20 m 内扫描范围 ±60°, 20~70 m 内扫描范围 ±40°,每 75 ms 返回一次二维平面内物体位置信息。取料机回转时雷达运动轨迹为圆弧,其半径等于雷达与回转中心的距离,圆心角等于取料机回转角。为分析料堆点云特征,根据雷达运动轨迹将二维点云 (x_i, y_i) 拼接成三维点云 (X_i, Y_i, Z_i) 。计算方法如式(1)所示,点云拼接前后如图 3 所示。

$$\begin{cases} X_i = (d_c + x_i) \times \cos(r_i - r_0) \\ Y_i = (d_c + x_i) \times \sin(r_i - r_0) \\ Z_i = y_i \end{cases} \quad (1)$$

式中: d_c 为雷达与回转中心距离; r_i 为获取第 i 帧点云时的取料机回转角, $i = 1, 2, \dots, N$; r_0 表示初始回转角。

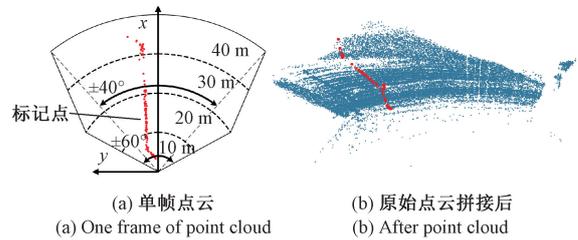


图 3 雷达获取与原始点云拼接后

Fig. 3 After radar acquisition and original point cloud stitching

图 3(a) 所示为雷达扫描范围内的单帧点云。图 3(b) 所示为取料机对底层料堆作业时获取二维点云的拼接结果,其中包括图 3(a) 中的 1 帧点云(标记点)。可以发现原始点云包含了部分无关物体的点云和离群点。

2.2 料堆点云的预处理

扫描过程由于设备振动和环境变化将产生离群点,干扰后续算法应用。利用直通滤波与统计滤波算法进行预处理,确定兴趣区域,滤除无效点,减少对数据分析的影响。

直通滤波通过限制数据范围剔除无效数据^[14],为避免扫描到相邻料堆影响后续点云分析,定义圆锥形料堆的兴趣区域为圆形作业平台范围。根据相似三角形和休止角原理,在已知料堆堆积高度的情况下可计算出当前斗轮作业平台的直径。设料堆高度 L_h ,斗轮下沿高度 D_h ,煤炭休止角 A_r ,可得当前作业平台直径 $L_d = 2(L_h - D_h) / \tan A_r$ 。料堆高度和斗轮下沿高度均可从数据库中获取。为扫描区域尽可能全面覆盖料堆轮廓,雷达 y 轴方向不设置周界参数。同时为避免相邻料堆的干扰,向 x 轴范围添加等于堆场规定的料堆最小间距的冗余,再减去累计进车距离 L_a 得到雷达 x 轴的坐标限制,滤除 $x_i > L_d - L_a + 5$ 的点云。

去除周界参数外点云后,采用统计滤波对范围内的稀疏离群点进一步处理。具体是对每个观测点的邻域进行统计分析,将和整体分布偏离较大的点作为离群点予以剔除。预处理过程通过多次实验确定统计滤波参数,定义距离观测点欧式距离最小,数量等于点云总数的20%的点为邻域点,并取1倍标准差为阈值。图3(b)中原始点云的预处理结果如图4所示,右侧兴趣区域外点云和边缘的离群点云已被滤除。

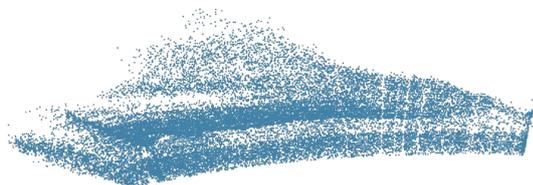


图4 点云预处理效果

Fig. 4 Point cloud preprocessing results

2.3 基于机器学习的边界感知方法

工业智能化是工业生产转型升级的重要趋势,基于人工智能的建模、预测、诊断、优化、决策在工业领域不断展现优势。因此选择机器学习算法识别取料过程点云特征,优化料堆边界感知问题。

操作员通过视觉感知可以预判料堆边界提前减速,斗轮在料堆边界空转时间较短。通过标注好的点云数据样本对机器学习模型训练,将人工操作的取料机回转减速过程点云和其他状态点云进行区分,模拟人工作业对料堆边界的判断。取料过程中获取的点云如图5所示。

图5中标注的“垛外”点云是操作员向右回转开始减速时获取的点云,“垛中”点云是回转取料过程获取的点云。分析人工作业时两类点云特点,设计提取点云特征训练分类算法。



图5 向右回转过程右侧雷达扫描点云

Fig. 5 Right side radar scanning point cloud during turning right

2.4 点云样本标注和特征提取

料堆边界感知的理想效果是模仿人类通过视觉预判减速位置,使取料机回转减速至静止时,斗轮处于料堆边界附近,既具备进车条件又不会在垛边残留过多散料。在点云标注中,将人工操作时取料机在料堆边界的停止回转角 Δ 作为理想值。取料机通过变频器控制回转电机,减速时可在 1.6° 回转角内减速至静止,结合设备操作规程和人工操作经验,设置回转制动裕量 2.5° 满足减速需求,回转到边过程中将点云数据以 Δ 前 2.5° 为界,分别标注为“垛中”和“垛外”。

样本标注完成后需提取点云特征进行学习^[15],在数据分类问题中,样本特征的选取直接关系到模型分类性能。显然,较少的点云数据是不利于分析其特征的,但是自动执行环节要求料堆边界感知信号频率至少为1 Hz,因此考虑数据采集和运算过程的时间,每次将雷达0.5 s内采集的数据合并处理,依靠取料机搭载的工控机运算能力能够满足要求。虽然预处理时按雷达轨迹对毫米波雷达二维点云进行拼接,但雷达在短时间内的移动距离极小,料堆点云的局部特征区别不明显。因此,采用法向量、曲率、FPFH作为分类特征并不理想。

根据雷达返回点云数据特性以及取料机作业规律,选择点云的几何分布和斗轮功率两方面特征,设计了10项数据作为样本特征向量如表1所示。由于取料机边界减速时间在作业中占比低,且存在操作人员误判、设备震动等情况。对机器学习方法而言,包含了样本重叠、数量不平衡、混杂噪声样本的问题,属于典型不平衡数据集的分类问题。

3 重叠敏感边距分类器

3.1 模糊孪生支持向量机

标准的模糊支持向量机(fuzzy support vector machines, FSVM)、孪生支持向量机(twin support vector machines, TSVM)算法虽然考虑了数量不平衡的问题,但

表 1 提取的点云样本特征
Table 1 The extracted point cloud sample features

符号	特征描述
x_{\max}	x 坐标最大值
x_{mean}	x 坐标平均值
x_{\min}	x 坐标最小值
y_{\max}	y 坐标最大值
y_{mean}	y 坐标平均值
y_{\min}	y 坐标最小值
q_{num}	点云数量
q_{deg}	极坐标下点云角度平均值
Q_s	点云栅格占用率
P_w	斗轮功率

支持向量仍集中在样本重叠区域,导致非重叠区域的分类正确率较差。针对此问题提出了孪生重叠敏感边距分类器(twin overlap sensitive margin, TOSM)的不平衡数据集处理算法。

假定样本数据为 $S = \{(x_i, s_i, y_i)\}, i = 1, 2, 3, \dots, N$, 其中 $x_i \in R^N$ 是输入的样本点。每个样本点的隶属度值 $\sigma \leq s_i \leq 1$ (σ 为足够小正数), 各样本点拥有一个标签 $y_i \in \{-1, 1\}$ 。FTSVM 旨在寻找两个非平行决策平面:

$$K(x_+^T, S^T)w_+ + b_+ = 0, K(x_-^T, S^T)w_- + b_- = 0 \quad (2)$$

在样本分类过程中需要考虑到边际最大化和泛化误差最小化之间的平衡,在 FTSVM 中向两个决策平面函数分别添加 $1/\|w_+\|^2$ 和 $1/\|w_-\|^2$ 作为距离度量项,通过增加两个平面之间的间隔,使模型结构风险最小化,有利于减小模型泛化误差。最终得到 FTSVM 的二次规划问题如式(3)和(4)所示。

$$\min_{w_+, b_+, \xi_-} \frac{1}{2}C_1 \|w_+\|^2 + \frac{1}{2} \|K(A, S^T)w_+ + e_+ b_+\|^2 + C_3 s^- \xi_-$$

$$\text{s. t. } -(K(B, S^T)w_+ + e_- b_+) \geq e_- - \xi_-, \xi_- \geq 0 \quad (3)$$

$$\min_{w_-, b_-, \xi_+} \frac{1}{2}C_2 \|w_-\|^2 + \frac{1}{2} \|K(B, S^T)w_- + e_- b_-\|^2 + C_4 s^+ \xi_+$$

$$\text{s. t. } -(K(A, S^T)w_- + e_+ b_-) \geq e_+ - \xi_+, \xi_+ \geq 0 \quad (4)$$

式中: K 表示核函数; A 表示正类样本; B 表示负类样本; $S = [A; B]$ 表示所有训练样本; w_+ 和 w_- 表示正类和负类超平面的法向量; e_+ 和 e_- 表示单位向量; b_+ 和 b_- 表示正类和负类超平面的偏置项; s^+ 和 s^- 表示正类和负类的模糊隶属度参数, $C_1 = C_3, C_2 = C_4$ 表示惩罚参数。

根据库恩塔克条件可以得到式(3)和(4)的对偶问题,求解后得到两个非平行决策超平面,最终转化为决策函数如式(5)所示。

$$f(x) = \operatorname{argmin}_{\pm} \frac{|K(x, S^T)w_{\pm}^T + b_{\pm}|}{\sqrt{w_{\pm}^T K(S, S^T)w_{\pm}}} \quad (5)$$

3.2 重叠敏感模糊隶属度函数

FTSVM 算法需要根据每个样本对分类模型的不同重要性赋予隶属度,目前仍无建立模糊隶属度函数的标准方法。针对不平衡数据集问题,重点考虑样本重叠区域对分类性能的影响,提出一种基于样本重叠程度的模糊隶属度函数定义方法,如式(6)所示。

$$\begin{cases} s_i^+ = p(x_i^+)r^+ \\ s_i^- = p(x_i^-)r^- \end{cases} \quad (6)$$

式中: s_i^+ 和 s_i^- 是正类和负类的模糊隶属度参数; x_i^+ 和 x_i^- 是正类和负类的特征向量; $p(x_i)$ 是定义的代表样本 x_i 类间重叠程度的系数; r^+ 和 r^- 是平衡类间数量的系数,利用文献[11]中的 DEC 方法,令 $r^+ = 1, r^-$ 等于正类和负类的样本数量之比。为避免 $s_i = 0$,放缩 s_i 至 $[\varepsilon, 1]$ (ε 为极小正数)。

所提出的重叠敏感分类器关注样本是否处于重叠区域,结合 K 最近邻(K-NN)思想,定义系数 $p(x_i)$ 描述观测样本的重叠程度。具体描述如下:假设有一正类样本 x_i^+ ,根据距离最近的 K 个样本中与观测样本同属正类的比例计算 $p(x_i^+)$,负类样本同理。显然 $p(x_i) = 1$ 时,认为样本处于没有类间样本重叠的区域;当 $p(x_i)$ 减小时认为观测样本靠近重叠区域;当 $p(x_i)$ 接近于 0 时认为是噪声样本。为减小不同数据集样本分布差异对模型的影响,使用柔性 KNN 算法^[16]计算不同 K 近邻时的样本观测结果均值,计算方法如式(7)所示。

$$p(x_i) = \frac{1}{q} \sum_{k=1}^q \frac{N_k^{\pm}}{K}, \quad x_i = x^{\pm} \quad (7)$$

式中: $K = 3, 5, \dots, \sqrt{N}$; q 表示所用 K 值的数量; N 是所有样本的数量(\sqrt{N} 向下取整); N_k^{\pm} 是在 K 最近点中正类或负类的数量。

3.3 类间样本重叠区域处理方法

在 TOSM 分类器中 FTSVM 求解超平面的重点作用是通过两个非平行超平面划分数据集为重叠与非重叠部分,构造出一个对样本数量不平衡和类间重叠不敏感的分类超平面。TOSM 认为非重叠区域的样本更加重要,错误分类成本更高,分类效果如图 6 所示。

图 6 中三角形和圆形分别代表正类和负类样本,其大小表示不同重叠敏感权重。虚线①、虚线②表示 FTSVM 的决策超平面,虚线③上的点与两决策平面距离相同。因为样本属于距离最近的决策平面类别,所以虚线将样本空间划分为两个部分。对于 FTSVM 而言样本越靠近虚线③说明处于重叠越严重的区域,越难以被正确分类。在 TOSM 中通过定义重叠敏感边距 margin,向

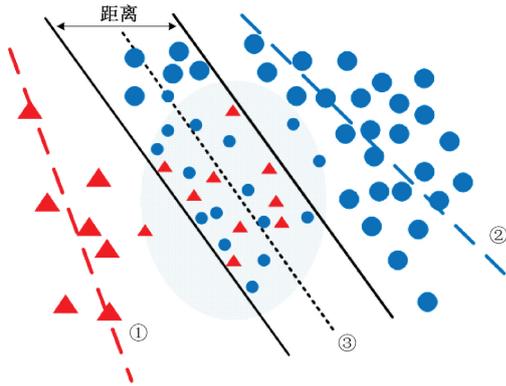


图6 TOSM分类器线性分类示意图

Fig. 6 TOSM classifier schematic diagram of linear classification

①、②决策平面分别平移形成两条实线,两条实线中间为划分出的样本重叠区域。重叠区域外样本通过FTSVM分类,区域内样本使用1-NN分类。为避免泛化误差过大,对重叠区域样本数量和支持向量机的两个超参数加以限制^[17]。

$$\begin{cases} HO(\theta) = \frac{Ob(x)_{overlap}}{N} \\ SV(\theta) = \frac{Ob(x)_{sv}}{2N} \end{cases} \quad (8)$$

式中: θ 是模型的超参数组合如式(9)所示; $Ob(x)_{overlap}$ 表示重叠样本数量; $Ob(x)_{sv}$ 表示支持向量总数; N 表示样本总数。将 $s_i < 0.5$ 定义为 $Ob(x)_{overlap}$ 计算 $HO(\theta)$, $margin$ 等于重叠样本中与FTSVM两个决策平面距离差的最大值,样本与两个决策平面距离差小于 $margin$ 即处于重叠区域,大于则处于非重叠区域。

$$\theta = \arg \text{Min} \left(\frac{1}{\frac{\beta}{HO(\theta)} + \frac{1-\beta}{SV(\theta)}} \right) \quad (9)$$

式中: β 为大小在 $[0, 1]$ 内的权重系数,对TOSM所用的径向基核函数,代表惩罚因子和 $gamma$ 值,令其最小化有利于减小分类算法泛化误差。

综合前文所述,本文提出的基于TOSM分类器对无人化取料机感知环节优化过程如下:

1) 对人工作业时获取的毫米波雷达点云数据进行预处理,构建往复取料过程中“垛中”、“垛外”两种情况的点云特征样本库。

2) 利用标注样本训练和测试TOSM分类器,使TOSM在无人作业获取新的点云样本时能预测归属“垛外”或“垛中”中一类。

3) 将TOSM加入感知环节,当满足进车条件且TOSM对点云数据预测为“垛外”时,取料机悬臂回转 2.5° 后到达料堆边界,边界感知任务完成。

4 实验与结论分析

为验证本文提出的感知方法和TOSM分类性能,分别进行了数据集测试和现场应用验证。基于MATLAB软件,在雷达点云数据集上进行了分类性能测试。通过部署训练模型的C++动态链接库将识别方法加入感知环节,在取料机无人化重载调试过程进行了现场验证,证明了该方法的可行性。

4.1 模型评价指标的选择

数据集不平衡的分类问题,个别典型评价指标会给出误导性的分类能力评价,因此实验中选择了正确率 Acc 、查准率 Pre 、 $G-mean$ 以及 $F1-score$ 4个指标衡量模型性能。计算方法如式(10)~(13)所示

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \quad (10)$$

$$Pre = \frac{TP}{TP + FP} \quad (11)$$

$$G-mean = \sqrt{Sen \times Spe} \quad (12)$$

$$F1-score = \frac{2 \times Pre \times Recall}{Pre + Recall} \quad (13)$$

式中:召回率 $Recall = TP/(TP + FN)$;敏感性 $Sen = TP/(TP + FN)$;特异性 $Spe = TN/(TN + FP)$; TP 是真阳性; TN 是真阴性; FP 是假阳性; FN 是假阴性。

4.2 TOSM分类实验结果分析

采用TOSM分类器对不平衡数据集进行分类试验,实验数据采用2020年10月~2021年1月曹妃甸某港口取料机人工作业和自动作业过程中,在操作员严格按照规章作业的条件下采集的点云数据。实验以操作员在边界的回转角作为理想值(标准值)。样本数量的选取依据统计学习理论中泛化误差界概念,在不引入噪声的前提下尽量扩大训练样本数以降低泛化误差^[18]。

表2中6组数据为人工作业时,对一垛高17 m共8 400吨的圆锥形料堆,三层梯取过程中采集的点云。数据L和R分别表示左侧和右侧雷达;数字表示取料机在料堆第1、2、3层作业。针对6组数据进行10次10折交叉验证实验,并对比了传统不平衡数据分类算法。

表2 雷达点云数据集基本信息

Table 2 Basic information of radar point cloud dataset

数据来源	样本总数	不平衡比例	多数类数量	少数类数量	多数类平均重叠程度	少数类平均重叠程度
数据 L-1	3 189	3.90:1	2 538	651	0.893 5	0.744 1
数据 R-1	3 111	3.15:1	2 362	749	0.899 9	0.790 1
数据 L-2	8 400	4.21:1	6 788	1 612	0.930 3	0.845 1
数据 R-2	8 376	7.15:1	7 204	1 172	0.935 0	0.836 2
数据 L-3	2 471	5.59:1	2 096	375	0.906 9	0.806 7
数据 R-3	2 451	5.55:1	2 077	374	0.888 2	0.711 8

表 3、4 分别展示了实验中 6 种算法的 4 个评价指标, Under-SVM 测试结果比 SVM 的查准率更高, 但正确率却小于 SVM, 而且代表不平衡数据处理能力的 *GM* 和 *F1-score* 不稳定, 说明数据降采样会损失一定信息。TSVM 相较于前两种分类方法更适合处理不平衡数据集问题, 但其引入模糊权重反而使分类性能明显下降, 说明基于类中心距离定义的模糊隶属度定义方法对本数据集并不适用。TOSM 分类器基于 FTSVM 与 1-NN 算法结合, 处理不平衡数据能力超过两者。其中 *F1-score* 较

FTSVM 算法提升 5.09%, 1-NN 虽然适合处理重叠区域分类, 但对噪声鲁棒性差, 因此较其提升 10.14%。表 5 展示了不同算法的训练及预测时间数据。由于 TOSM 计算步骤更复杂, 求解模糊隶属度函数也需要较长时间, 所以在 6 种算法中耗时最久, 但样本的预测时间和其他算法持平。综上所述, TOSM 发挥了 FTSVM 和 1-NN 的优势, 对不平衡数据集分类能力提高明显, 虽然在样本量较大时训练时长增加, 但样本预测所用时间能够满足现场感知信号应用需求。

表 3 雷达点云数据集不同算法的 *Acc*、*Pre* 比较

Table 3 Comparison of *Acc* and *Pre* of different algorithms of radar point cloud datasets

分类方法	SVM		Under-SVM		TSVM		FTSVM _{cen}		1-NN		TOSM	
	<i>Acc</i>	<i>Pre</i>	<i>Acc</i>	<i>Pre</i>	<i>Acc</i>	<i>Pre</i>	<i>Acc</i>	<i>Pre</i>	<i>Acc</i>	<i>Pre</i>	<i>Acc</i>	<i>Pre</i>
数据来源												
数据 L-1	94.29	90.25	95.66	95.35	95.99	96.82	94.46	96.11	92.36	79.92	96.39	94.92
数据 R-1	96.97	93.95	93.73	99.16	96.69	93.64	95.96	97.57	96.10	91.07	97.94	95.76
数据 L-2	97.38	91.41	91.77	99.33	97.88	96.44	96.54	98.27	96.21	89.43	98.29	95.35
数据 R-2	98.46	95.35	93.03	99.24	98.24	96.06	96.51	96.75	96.82	88.92	98.45	95.78
数据 L-3	97.70	89.49	91.57	97.65	97.52	91.03	96.01	91.30	93.41	79.32	97.74	91.43
数据 R-3	96.10	86.30	89.40	97.49	96.90	90.05	94.57	84.19	90.82	69.32	97.23	88.97
平均值	96.82	91.13	92.53	98.04	97.20	94.01	95.68	94.03	94.29	83.00	97.67	93.70

表 4 雷达点云数据集不同算法的 *G-mean*、*F1-score* 比较

Table 4 Comparison of *G-mean* and *F1-score* of different algorithms in radar point cloud datasets

分类方法	SVM		Under-SVM		TSVM		FTSVM _{cen}		1-NN		TOSM	
	<i>GM</i>	<i>F1</i>	<i>GM</i>	<i>F1</i>	<i>GM</i>	<i>F1</i>	<i>GM</i>	<i>F1</i>	<i>GM</i>	<i>F1</i>	<i>GM</i>	<i>F1</i>
数据来源												
数据 L-1	92.73	86.61	95.64	95.65	96.28	90.08	95.06	87.68	87.35	81.03	95.83	91.51
数据 R-1	95.09	93.69	95.50	88.30	95.61	93.11	96.50	92.05	94.30	91.76	97.17	95.68
数据 L-2	95.69	92.24	94.54	82.28	97.13	94.61	97.20	91.62	93.52	90.06	97.15	95.54
数据 R-2	97.13	94.50	95.56	79.96	97.01	93.86	96.60	88.58	93.39	88.66	97.06	94.50
数据 L-3	94.21	92.11	93.99	77.85	94.73	91.67	93.99	87.34	87.15	78.36	95.04	92.39
数据 R-3	91.98	91.61	92.58	73.72	93.51	89.79	90.04	82.45	80.91	69.57	93.67	90.65
平均值	94.47	91.79	94.64	82.96	95.71	92.19	94.90	88.29	89.44	83.24	95.99	93.38

表 5 不同算法训练时间及预测时间比较

Table 5 Comparison of training time and prediction time of different algorithms

分类方法	SVM		Under-SVM		TSVM		FTSVM _{cen}		1-NN		TOSM	
	训练时间/s	预测时间/s	训练时间/s	预测时间/s	训练时间/s	预测时间/s	训练时间/s	预测时间/s	训练时间/s	预测时间/s	训练时间/s	预测时间/s
数据来源												
数据 L-1	0.177 2	0.006 4	0.084 3	0.001 6	6.115 5	0.009 6	4.019 3	0.009 4	0.093 4	0.002 1	19.772 1	0.010 1
数据 R-1	0.259 4	0.002 6	0.078 1	0.001 2	4.644 5	0.008 2	4.092 3	0.008 3	0.088 0	0.002 2	17.326 0	0.009 5
数据 L-2	0.493 6	0.010 7	0.049 0	0.002 2	64.679 2	0.055 2	22.703	0.058 9	0.162 0	0.003 8	224.740 3	0.054 7
数据 R-2	0.410 3	0.006 3	0.044 3	0.003 0	57.431 1	0.049 7	30.226 1	0.058 3	0.155 2	0.004 0	187.332 9	0.063 3
数据 L-3	0.044 7	0.001 9	0.012 0	0.001 3	1.734 3	0.005 1	1.668 8	0.0047	0.008 0	0.001 8	9.351 0	0.005 0
数据 R-3	0.057 2	0.002 3	0.014 0	0.001 4	1.699 3	0.005 2	17.565	0.0054	0.008 1	0.001 8	9.058 6	0.006 5

4.3 现场应用验证

为进一步证明所提方法对感知环节的改善效果,在雷达测量剖面面和斗轮的距离基础上,向感知系统加入 TOSM 判断信号。当满足条件 1) 斗轮中心半径 5 m 没有障碍物,允许取料机进车;满足条件 2) TOSM 输出“垛外”信号,认定悬臂回转 2.5°后为理想进车位置,回转电机根据此时回转速度在 2.5°后减速至静止。为避免基于点云的感知信号失效,保留回转减速条件 3) 斗轮功率连续 2 s 等于空转功率时回转减速。

为验证优化后感知算法,选择和训练模型时取料条件相似的人工作业点云数据进行离线验证。以感知系统优化前、后的预测回转角与理想回转角 Δ 的误差 E 作为描述边界控制精确度的量化指标,对算法改进后的预测回转角定量描述。对作业中第 2 层连续取料 2 000 吨过程中,共 38 次到边回转的左、右雷达点云共 10 051 组样本进行离线测试,算法重复性良好,不存在无法得到结果的无效值,正确率达到 91.37%。根据所述展示的感知流程可知,即使 TOSM 模型输出错误信号,依靠距离和斗轮功率信号仍可避免取料机发生垛中进车或出垛不减速的问题。图 7 中展示的为改进后加入 TOSM 预测和改进前仅通过条件 1)、3) 预测的回转角与 Δ 的角度差。

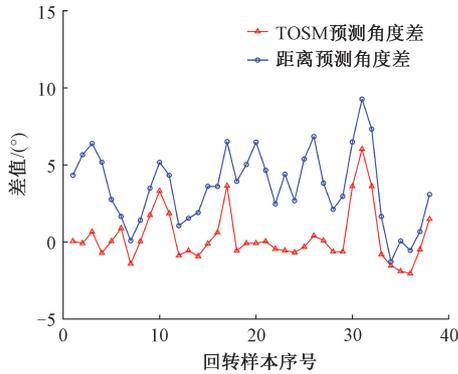


图 7 TOSM 加入前后回转角预测值与真值误差对比

Fig. 7 Comparison of the predicted value and the true value error of the rotation angle before and after TOSM

图 7 中当 $E=0$ 时说明预测角度等于理想回转角,最符合人工作业对料堆边界的判断,加入 TOSM 算法后所预测的回转角更接近人工作业的理想回转角 Δ ,平均角度误差为 1.14°,较优化前平均减小了 2.54°。

在利用人工作业数据离线验证了感知方法的有效性后,将 TOSM 算法加入取料机感知系统,并在取料机无人化重载调试中,对圆锥形料堆的中层进行取料测试。斗轮处于空转功率的时间越长,单位时间内的有效作业时间越短、作业效率越低。对使用斗轮功率和加入 TOSM 的感知方法各进行两轮往复取料,对比其相同时间内斗

轮空转时间的变化。为确保实验的安全性,加入 TOSM 测试开始阶段设置了较小的进尺深度,因此后者实验时斗轮功率峰值低于前者。两方法的斗轮功率对比如图 8 所示。

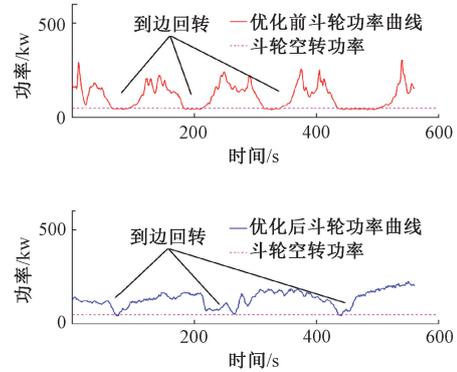


图 8 优化前后斗轮功率对比图

Fig. 8 Comparison chart of bucket wheel power before and after optimization

由图 8 可见,利用斗轮功率感知的优化前方法在料堆边界时斗轮空转时间更长,导致取料效率的下降。优化前斗轮功率下降陡峭,说明取料机到达料堆边界时的回转速度依然很高。这是由于无法预判减速位置,一直以较大回转速度取料,直到满足斗轮功率的边界感知阈值开始减速,大加速度的加减速控制会影响设备使用寿命、浪费电力资源、引起取料流量的波动。加入条件 1) 和 2) 后的感知系统,3 次回转过程中斗轮空转时间分别减少 17 s、15 s 和 14 s。

图 9 展示了作业条件相同的取料机自动作业斗轮功率数据,图 9(a)、图 9(b) 分别是斗轮功率判断回转边界的自动作业和 TOSM 加入感知系统后的自动作业两种状态下的斗轮功率数据。

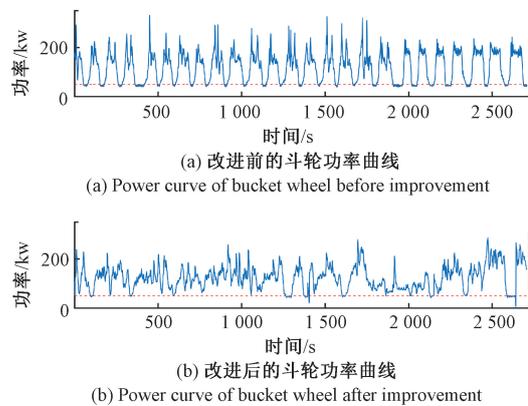


图 9 两种感知方式的自动作业斗轮功率曲线对比

Fig. 9 Comparison of automatic operation bucket wheel power curves of two sensing methods

为合理对比不同方法的取料效率,图9中两次作业流量均控制在2 800 t/h。由图9(a)可知斗轮功率判断回转方式无法预判回转角,斗轮空转状态持续时间明显较长。由图9(b)可知感知系统改进后能对边界回转角预测,使取料机在料堆边界附近回转减速至零。斗轮出边界减速和向前进车的两个过程衔接紧密,边界位置功率骤降阶段更少,斗轮功率能维持在较高水平。两次作业取料及回转数据详细对比如表6所示。

表6 两次作业过程中取料及回转数据比较

Table 6 Comparison of automatic operation bucket wheel power curves of two sensing methods

对比指标	自动作业的边界判断方式	
	斗轮功率判断边界	加入 TOSM 判断边界
边界回转次数	25	25
平均空转时间/s	22.53	6.18
空转时间占比/%	20.81	5.71
平均斗轮功率/kw	120.21	126.57
平均瞬时流量/(t/h)	2 270	2 683
累积取料流量/t	1 660	1 844

基于斗轮功率自动作业的平均瞬时流量远低于控制流量2 800 t/h,说明作业中斗轮空转时间占比太长,降低了单位时间取料效率导致累积取料流量较低,难以完成既定作业目标,影响港口装船作业计划。在增加毫米波雷达和TOSM判断后,相较斗轮功率判断方式,斗轮空转时间占比下降了15.1%,平均每次边界回转的斗轮空转时间减少了16.35 s。相同的作业时长和取料流量控制下,以两者累积取料流量的比值对比取料效率,改进后取料效率提高11.08%。

5 结 论

本文针对无人化取料机的毫米波感知技术进行研究,利用机器学习模型分析人工作业时雷达点云数据特征,针对点云数据集的不平衡性导致分类难度增加的问题,提出一种基于重叠敏感成本的孪生模糊支持向量机(TOSM),相比其他传统方法更适合处理不平衡数据集。基于TOSM改进感知系统后,实现了取料机作业中预判减速位置的功能。重载实验表明本文提出的感知技术比改进前增加了取料效率,降低了斗轮空载时间。在后续工作中,重点考虑建立案例库的方式进一步优化感知系统。通过记录料堆煤种、数量、堆积方式、堆积位置以及整个作业过程的点云数据,训练边界感知模型。对新作业料堆,通过“身份信息”,选用案例库中最相似的模型识别到边减速位置。目前正在开展

黄骅某矿石码头取料机改造工作,推广时需根据现场作业规范收集数据训练模型。综上所述,基于机器学习优化感知系统的方法具有可行性与实用价值,为散料港口中无人化取料机的感知技术研究提供了探索经验。

参考文献

- [1] 柴天佑. 工业人工智能发展方向[J]. 自动化学报, 2020, 46(10): 2005-2012.
CHAI T Y. Development directions of industrial artificial intelligence [J]. Acta Automatica Sinica, 2020, 46(10): 2005-2012.
- [2] 陈致远. 黄骅港智能堆场研究[J]. 起重运输机械, 2019(2): 46-51.
CHEN ZH Y. Research on intelligent storage yard of huanghua port[J]. Hoisting and Conveying Machinery, 2019(2): 46-51.
- [3] VUTTIPITAYAMONGKOL P, ELYAN E, PETROVSKI A. On the class overlap problem in imbalanced data classification [J]. Knowledge-Based Systems, 2021, 212: 1-17.
- [4] PROVOST F, FAWCETT T. Robust classification for imprecise environments [J]. Machine Learning, 2001, 42(3): 203-231.
- [5] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321-357.
- [6] LIN W C, TSAI C F, HU Y H, et al. Clustering-based undersampling in class-imbalanced data sciencedirect[J]. Information Sciences, 2017, 409: 17-26.
- [7] GEORGIOS D, FERNANDO B, FELIX L. Improving imbalanced learning through a heuristic oversampling method based on k-means and SMOTE[J]. Information Sciences, 2018, 465: 1-20.
- [8] BATUWITA R, PALADE V. FSVM-CIL: Fuzzy support vector machines for class imbalance learning[J]. IEEE Transactions on Fuzzy System, 2010, 18(3): 558-571.
- [9] ZHU C, WANG Z. Entropy-based matrix learning machine for imbalanced data sets [J]. Pattern Recognition Letters, 2017, 88: 72-80.
- [10] BATUWITA R, PALADE V. FSVM-CIL: Fuzzy support vector machines for class imbalance learning[J]. IEEE Transactions on Fuzzy Systems, 2010, 18(3): 558-571.
- [11] TANG Y, ZHANG Y Q, CHAWLA N V, et al. SVMs modeling for highly imbalanced classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2009, 39(1): 281-288.
- [12] HE H, GARCIA E A. Learning from imbalanced data[J].

- IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9): 1263-1284.
- [13] 袁敏, 施佳, 许致火. 基于维纳滤波的汽车毫米波雷达干扰自适应抑制[J]. 电子测量与仪器学报, 2021, 35(2): 194-201.
YUAN M, SHI Q, XU ZH H. Wiener filter based automotive millimeter wave radar interference adaptive reduction [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 194-201.
- [14] 郭保青, 余祖俊, 张楠, 等. 铁路场景三维点云分割与分类识别算法[J]. 仪器仪表学报, 2017, 38(9): 2103-2111.
GUO B Q, YU Z J, ZHANG N, et al. 3D point cloud segmentation, classification and recognition algorithm of railway scene [J]. Chinese Journal of Scientific Instrument, 2017, 38(9): 2103-2111.
- [15] 洪翠, 杨华锋, 卢国仪, 等. 基于振动信号 SVM 分类的配变故障识别方法[J]. 仪器仪表学报, 2016, 37(6): 1299-1308.
HONG C, YANG H F, LU G Y, et al. Fault identification method for distribution transformer based on SVM classification of vibration signal [J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1299-1308.
- [16] GARCIA V, MOLLINEDA R A, SANCHEZ J S. On the k-NN performance in a challenging scenario of imbalance and overlapping[J]. Pattern Analysis and Applications, 2008, 11(3): 269-280.
- [17] LEE H K, KIM S B. An overlap-sensitive margin classifier for imbalanced and overlapping data[J]. Expert Systems With Applications, 2018, 98(5): 72-83.
- [18] 王一鹏, 陈学振, 李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(2): 59-64.
WANG Y P, CHEN X ZH, LI L Y. Research on fault diagnosis of machine spindle bearing based on wavelet packet mixing feature and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 59-64.

作者简介



孔德明(通信作者), 2006年于燕山大学获得学士学位, 2010年于燕山大学获得硕士学位, 2015年于北京航空航天大学获得博士学位, 现为燕山大学副教授, 主要研究方向为高精度三维测量技术。

E-mail: demingkong@ysu.edu.cn

Kong Deming (Corresponding author) received his B. Sc. degree and M. Sc. degree both from Yanshan University in 2006 and 2010, and received his Ph. D. degree in 2015 from Beihang University. He is currently an associate professor at Yanshan University. His main research interests include high precision 3D surveying technology.