



移动扫码阅读

付元, 雷智丰, 崔东锋, 等. 基于矾花图像识别的混凝剂智能投加系统研究[J]. 能源环境保护, 2023, 37(4): 83-90.

FU Yuan, LEI Zhifeng, CUI Dongfeng, et al. Research on an intelligent coagulant dosing system based on alum floc image recognition[J]. Energy Environmental Protection, 2023, 37(4): 83-90.

基于矾花图像识别的混凝剂智能投加系统研究

付 元¹, 雷智丰², 崔东锋¹, 郭中权¹, 蔡博涵^{3,*}, 肖 艳¹, 周爱姣^{3,*}

(1. 中煤科工集团杭州研究院有限公司, 浙江 杭州 311201; 2. 武汉市水务集团有限公司, 湖北 武汉 430019; 3. 华中科技大学 环境科学与工程学院, 湖北 武汉 430074)

摘要:目前国内水厂大多采用经验法进行混凝剂投加控制,为实现水厂混凝剂投加智能化,本研究搭建了基于矾花图像识别的智能投药系统。该系统结合了 YOLOv5 矾花识别算法和 Linear Regression 加药决策算法,并在此基础上添加了一个 7 维的全连接 BP 神经网络,通过 (563, 7) 的样本集 (563 条包含矾花数量、矾花平均等效直径、进水流量等 7 项参数的样本的集合) 进行训练,计算确定每一层的最佳权重,得到最低损失值为 0.018 的线性回归模型。生产试验表明,矾花目标检测准确率为 83.5%,预测投药量相比原有经验值降低 11.0%。与传统控制方法相比,该系统时延性更低,可靠性更强,药耗更低,有效降低了水厂加药生产和管理成本。

关键词: 矾花; 图像识别; 混凝剂; 智能投药

中图分类号: X703

文献标识码: A

文章编号: 1006-8759(2023)04-0083-08

Research on an intelligent coagulant dosing system based on alum floc image recognition

FU Yuan¹, LEI Zhifeng², CUI Dongfeng¹, GUO Zhongquan¹, CAI Bohan^{3,*},
XIAO Yan¹, ZHOU Aijiao^{3,*}

(1. CCTEG Hangzhou Research Institute Co., Ltd., Hangzhou 311201, China;

2. Wuhan Water Group Co., Ltd., Wuhan 430019, China; 3. School of Environmental Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: At present, most domestic water plants use empirical methods for coagulant dosing control. In order to realize the intelligent dosing of coagulant in water plants, this research has built an intelligent dosing system based on alum floc image recognition. The system combines the YOLOv5 alum floc recognition algorithm and the Linear Regression dosing decision algorithm. And on this basis, a 7-dimensional fully connected BP neural network was added for training through a sample set of (563, 7) (563 samples containing 7 parameters such as the number of alum flocs, the average equivalent diameter of alum flocs, and the inflow flow rate). The optimal weights for each layer were calculated and determined, resulting in a linear regression model with a minimum loss value of 0.018. The production test showed that the detection accuracy of alum floc target was 83.5%, and the predicted dosage was 11.0% lower than the original empirical value. Compared with the traditional control method, the system has lower time ductility, stronger reliability and lower coagulant consumption, which have effec-

收稿日期: 2023-03-09; 责任编辑: 全丽丽

DOI: 10.20078/j.eep.20230502

作者简介: 付 元 (1984—), 男, 山东滕州人, 副研究员, 从事智能绿色矿山、水污染治理及其智能化技术研究。E-mail: ccteg@139.com

通讯作者: 蔡博涵 (1999—), 男, 湖南株洲人, 硕士研究生, 从事混凝剂投加智能化研究。E-mail: m202174075@hust.edu.cn

周爱姣 (1975—), 女, 湖北仙桃人, 教授, 从事饮用水水质安全、水处理功能材料研发、水处理厂工艺节能降耗优化调试、数据挖掘等方向的研究。E-mail: ajzhou@hust.edu.cn

tively reduced the production and management costs of dosing in water plants.

Keywords: Alum floc; Recognition; Coagulant; Intelligent dosing

0 引言

混凝剂投加是水处理工艺的关键一环,其处理效果对后续工艺有着至关重要的影响。混凝效果受多种因素影响,如进水水质指标(如流量、浊度、温度、TP、COD等)、搅拌速度、混凝剂类型与投加量等^[1]。一般在确定混凝剂的种类后,如何根据进水的水质特征来准确控制投加量,是众多水厂需要解决的问题。投加量过低或过高都会使矾花形成效果不好,影响后续沉淀过程,导致水质不达标,偏高更会增加药剂成本,甚至二次污染^[2]。国内大多数的污水处理厂和自来水厂对于混凝剂投加量的控制一般通过人工设定投加量,采用自动控制或手动控制的方式,根据运行人员的工作经验,肉眼观察矾花的大小、数量以及沉淀出水情况来调节混凝剂投加量,这种控制方式对人员的经验依赖性较高^[3],同时无法针对进水水质的变化迅速作出相应的调整,调控过程不够及时、灵敏。改进混凝剂投药的控制模式,成为从业人员面临的一次机遇和挑战。

随着智慧水务的发展,智能化投药成为水厂物联网基础设施建设的主流控制方式。1997年 Claude Gagnon^[4]等根据酸碱度、温度、浊度等数据,采用人工神经网络预测污水处理厂的混凝剂投加量;2006年王新增^[5]等采用纹理分析的方法提取出矾花的纹理特征,实现矾花的自动识别;2017年翟士才^[6]等通过图像处理得到絮体的等效直径和沉降速度,实现混凝剂投加的智能控制。可见在双碳政策的指导下,混凝剂的智能投加已成为水处理行业的必然趋势,而对于将图像识别得到的多个矾花特征参数与水质结合,进行机器视觉和水质为输入变量的机器学习相融合的生产研究较少。

本研究在某10万 m^3/d 的大型污水处理厂开展,该厂采用高效沉淀池+曝气生物滤池的生物处理工艺。以污水厂高效沉淀池混凝剂投加为研究对象,设计了一套基于矾花图像识别的混凝剂智能投加系统,通过在高效沉淀池内安装摄像头,比较多种智能算法进行矾花图像分析,结合进出水水质、矾花特征值和投药量情况,搭建智能算法模

型,准确预测混凝剂的投加量,并与人工自动控制模式下的出水水质进行比较,分析其效能。

1 矾花图像采集与目标检测

1.1 矾花图像采集

本研究选用带有光源与清扫装置的水下图像采集摄像头,如图1(a)~(b)所示,安装于高密沉淀池絮凝区。装置实时采集絮凝区矾花图像,以视频记录矾花形成与状态变化过程。采集后的图像进行图像识别、数据处理、机器学习等流程,再结合水质参数等进行智能决策,以预测最优投加量,具体如图1(c)所示。

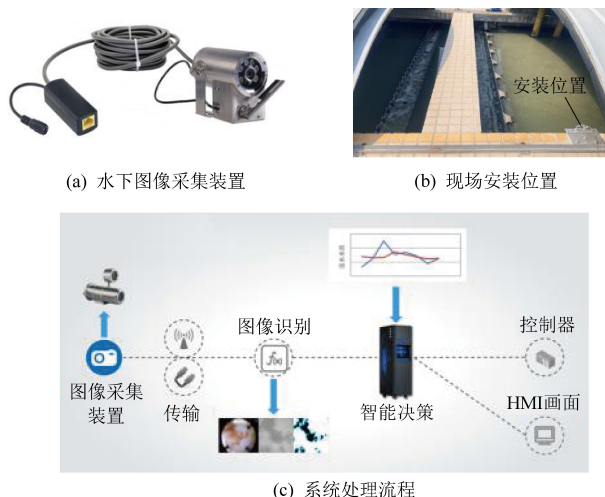


图1 矾花图像采集与处理流程

Fig. 1 Alum floc image acquisition and process

1.2 矾花识别算法选择

采集的矾花图像信息需进行业务规则的转换输入,将其转化为数字信息,即通过图像识别算法将矾花的形态信息进行提取,转为可以直接读取利用的几何数据。目前常用的图像识别算法有K最近邻(KNN)、卷积神经网络(CNN)、支持向量机(SVM)、K均值聚类算法(K-means)等^[7]。CNN是一种经典的目标检测算法,可以实现高精度的单目标检测,具有准确度高、可扩展性强、鲁棒性好的特点。其中的Mask R-CNN(Mask Region-based Convolutional Neural Network)算法精度高、灵活性强,YOLO(You Only Look Once)算法速度快、结构简单^[8-10],本研究以矾花作为单一目标进行检测,选择Mask R-CNN、YOLOv5两种算法进行比较。

不同算法在不同场景的应用效果存在较大差

异,为评价算法性能以及进行研究者之间的比较,需要统一的评价标准。本项目采用广泛的混淆矩阵^[11-12]评价图像精度,可把图像分类结果的精度显示于混淆矩阵中,常用的二维混淆矩阵见表1。将图像分为A类(矾花)和B类(背景),TP表示样本真实类别为A,模型识别结果也为A,FN表示样本真实类别为A,模型识别结果为B,FP表示样本真实类别为B,模型识别结果为A,TN表示样本真实类别为B,模型识别结果也为B。

表1 二维混淆矩阵

Table 1 Two-dimensional confusion matrix

预测类别 真实类别		
	A	B
A	TP (True Positive)	FN (False Negative)
B	FP (False Positive)	TN (True Negative)

通过二维混淆矩阵可以计算图像识别中的五类标准分类指标,具体为准确率(Accuracy)、精确率(Precision)、漏报率(FPR)、误报率(FNR)、召回率(Recall),各指标计算方式如公式(1)所示。

$$\begin{aligned}
 Accuracy &= \frac{TP+TN}{TP+TN+FP+FN} \\
 Precision &= \frac{TP}{TP+FP} \\
 FPR &= \frac{FP}{TP+FP} \\
 FNR &= \frac{FN}{TN+FN} \\
 Recall &= \frac{TP}{TP+FN}
 \end{aligned} \quad (1)$$

采用常用的开源精灵标注助手软件对50张不同时间段的矾花图像进行标注,框定图像中矾花的边缘,提取坐标信息并将其定义为“Alum Floc”类型组成训练集。两类算法在训练后以上述5项指标为评价标准,考虑矾花特征的提取对矾花识别的准确程度要求较高,设置准确率权重设为0.40,其余4项指标权重平均分配,均设为0.15,经加权平均得到综合评分,具体计算如公式(2)所

示。筛选评分较高的算法用于模型搭建,目标检测训练的效果如图2所示。

$$S = 0.4 \times Accuracy + 0.15 \times Precision + 0.15 \times Recall + 0.15 \times (1 - FPR) + 0.15 \times (1 - FNR) \quad (2)$$




图2 目标检测算法训练效果对比图

Fig. 2 Comparison of training effects of target detection algorithm

由图2可知,相较于Mask R-CNN,YOLOv5算法的综合评分为83.0分,有着更高的准确率和召回率,表明其分类准确性更好,检索能力更强,能够更精准地识别图像中的各类矾花。同时,YOLOv5误报水平也更低,因此选择YOLOv5算法用于高密沉淀池矾花目标的检测识别。

1.3 矾花目标检测

目标检测是根据待测目标的几何和统计信息,将目标从图像中识别并分割出来,确定其类别与位置的一种图像分割方法。传统目标检测算法,主要基于人工进行特征提取以及滑动窗口,存在计算量大和复杂场景下鲁棒性差的缺点,基于深度学习的检测算法,能够利用深度学习自动提取输入图像中的隐藏特征,对样本进行更高精度的分类和预测。

根据矾花识别算法比选结果,本研究采用YOLOv5算法进行矾花目标的检测,依据训练时产生的模型对矾花图像进行识别,框选目标,具体如图3所示。




图3 YOLOv5目标检测图

Fig. 3 Target detection diagram with YOLOv5

从图3(a)可以看出,水下摄像头能够清晰地拍摄絮凝区的矾花图像,为运行人员实时观察矾花形态以及高密池水质状况提供便利。图3(b)是优化前YOLOv5算法的总体检测效果,准确率为73.5%,对于面积较大、离镜头较近的矾花目标检测准确度高,然而小面积矾花的检测准确度偏低。韦一^[13]等通过构建小目标数据集,对小目标进行强化训练,此外,在算法中增加小目标检测层实现了海面图像中浮标、小渔船等目标检测准确率的提高。本研究采用类似方法,增加小面积矾花样本集对YOLOv5算法进行训练强化,优化后矾花检测准确率提升至83.5%,同一张图中识别的矾花数量增加5个,能更精准地识别出小面积矾花,如图3(c)所示。

通过目标检测框选矾花,能够确定位置信息和数量信息,计算矾花数量,有利于后续图像处理和数据提取,获取矾花面积、等效直径、湿周等特征参数,增加智能混凝剂投加系统的学习参数。

2 矾花图像处理与信息分类

2.1 矾花图像阈值分割

图像中的矾花需与非矾花的背景或杂物区分开,需要进行图像分割。传统的图像分割方法有基于阈值、区域、边缘、聚类、图论和深度学习等。其中阈值分割根据检测图像中某些特征不连续的原理,将图像分割成具有共同像素属性的对象区域。阈值分割通过灰度值的差异将图像划分为目标(矾花)区域与背景区域两种不同灰度类别的集合,通过选择合适的阈值,比较每个像素点的灰度与所设阈值的大小关系,最终形成相对应的二值化图像。由于阈值分割能够大规模压缩数据,降低容量负担,大大简化后续分析及处理步骤,因此它成为图像分割中应用最广泛的技术^[14-15]。

阈值分割方法中的重要环节是灰度阈值的选取,其大小会影响图像分割的合理性和效果,常用灰度分布直方图进行最优阈值的选取。将图3(a)中878块像素点的灰度进行排序分类,得到灰度分布直方图如图4所示。可见像素点的灰度值基本呈双峰分布,矾花图像可分成矾花目标和水流背景,其中 T_1 峰对应的水流灰度为30, T_2 峰对应的矾花灰度为190,可在两峰间低谷对应的灰度范围进行最优阈值的选取,张坤艳^[16]等对车牌图像也采用了全局阈值的方法进行二值化将白色车牌和蓝色背景进行区分。实验采用110、135、160

三个灰度值作为全局阈值并将图像二值化,比较不同阈值下的分割效果并确定最优阈值。




图4 灰度直方图

Fig. 4 Gray histogram

水下矾花图像在不同阈值条件下的二值化处理效果如图5所示。图像中的白色区域即为矾花目标所在位置,对比图5(b)~5(d)可知,以110灰度值进行分割会剔除许多面积较小的矾花,矾花面积占比为16.7%;135灰度值分割下的矾花面积占比为24.6%,能基本将有效矾花区域分离;160灰度值则容易涵盖部分易受镜头灯光影响离镜头较远的矾花,面积占比为33.5%。因此,选择135灰度值作为全局阈值。




图5 二值化图像

Fig. 5 Binary images

2.2 矾花数据处理与样本生成

2.2.1 矾花数据处理

为避免由于水流速度、悬浮杂质造成的图像骤变,试验采用了图像平滑时间序列数据的滑动平均值,以减少图像骤变的影响,从而更好地识别图像长期趋势和周期性变化。通过计算一定时间段内的数据均值来消除数据中的异常值,从而提高数据的可读性和可理解性,减少瞬时图像的处理结果所带来的误差。

同时,为避免图片流量过大导致运算缓慢,经优化后,设置每 5 s 截取一次拍摄图片并传输,通过阈值分割进行二值化处理,再取一定时间内的矾花面积的平均值数据,可有效剔除异常数据造成的波动影响,使矾花面积和平均等效直径等特征值变化趋势更为平缓,沈彦^[17]对絮体分析结果也采用了加权平均的方法,避免异常值使系统迭代计算不收敛,加强矾花信息与投药量间的相关性。

2.2.2 样本生成

将图像数据转化后,从原始数据库中提取历史水质、水量数据进行统计计算,得到初步数据样本集。根据算法需求提取样本集数据,同时考虑到现状污水厂一级处理后一般没安装水质仪表,常按照经验去除率计算一级处理后的水质指标,可提取对应时间范围内的进出水流量、进出水 COD、进出水 TN、进出水 TP、高密沉淀池出水 COD 等数据,同时进行时间对齐、插值扩充、条件过滤。

时间对齐通过设置时延时间把每个数据对齐到同一个时间点,例如以进水时刻为时间起点 0,则混凝剂投加时间为水流经过格栅和沉砂池所需的总水力停留时间。

部分数据在采集传输过程中会断线或通讯延迟,出现空值时段,考虑到插入数值的稳定性和插值方法的适用性,选择贝塞尔插值法进行数据增殖,将插值函数表示为一组贝塞尔函数的线性组合,并根据插值节点的位置和导数的信息,求解出组合系数^[18]。例如,小时级别的数据通过插值后可扩增为分钟级别,数据量提升 60 倍,从而补充算法样本集,在建模初期缺乏数据时效果显著,且对模型的拟合程度的影响小。

条件过滤^[19]用于剔除因仪器出错上传的异常数据。由于在线仪表校正不及时或温度等外部环境的影响,COD、TN 等传感器传输的数据显著不符合实际,如 14 mg/L 的 TN 突然降至 0.2 mg/L,一段时间后又回到 14 mg/L 左右,COD 显示为量程的极值等现象,设置过滤条件能够将此部分数据滤除。

2.3 矾花分类

由于矾花形态各异,需要对其大小、数量、等效直径等参数进行综合评价,为此需要进行矾花分类。分类分析主要包含识别和预测过程,通过构建模型识别某些特定的对象,经过训练后能够从其他图像中将类似对象预测并分离出来。常用的分类算法有 K 最临近法 (KNN),支持向量机 (SVM),决策树 (Decision Tree) 等,其中 KNN 算法

不会对数据做出任何的假设,仅针对训练样本进行特征分类,对异常值不敏感,模型训练时间快,预测效果好^[20],因此本研究采用 KNN 算法进行矾花分类。




图 6 矾花分类实验图

Fig. 6 Experimental diagram of alum floc classification

图 6 显示了不同混凝剂投量下矾花形态的样本特征信息。随着 PAC 投加量的逐渐减少,矾花数量与矾花面积呈现出先减小后增大的趋势,推测是混凝剂投加量的初步降低使絮体粒径减小,周边絮体生成量降低,随着投药量的进一步减少,絮体难以粘结,大面积矾花无法形成,细小矾花充斥在镜头前,且小絮体更易滞留在镜头前的水域,导致了矾花面积与数量的增加。但矾花的平均等效直径随着投药量的降低而降低,变化趋势与投药量基本一致,可作为矾花的有效参数。

在与水质、水量等信息结合后,使用 KNN 模型训练得到矾花状态分类模型,依据干扰实验对应的混凝剂投加梯度与矾花特征参数,并结合技术人员经验,将混凝剂投加分为 5 类(投药过多、较多、适中、较少、过少),并将判断结果反馈至投药控制系统,不同的水厂分类标准会有所变化。

3 智能投药机器学习模型构建与预测

3.1 算法选择

在进行矾花图像识别与分类后,为实现投药量的智能调控,还需要选择合适的算法,构建机器学习模型,预测并控制混凝剂的投加。目前业内主流的机器学习算法有很多,鉴于线性回归 (Linear Regression) 和决策树等算法的决策规则和特征权重比较直观,可以通过可视化的方式来解释模型的决策过程,可解释性更强。其中基于决策树的两种典型算法极端梯度提升算法 (XGBoost) 和随机森林 (Random Forest),都是集成学习算法,但二者在算法原理、训练方式、特征选择、预测方式上均有差异,试验对 Linear

Regression、XGBoost 和 Random Forest 三种算法进行了比较,其优缺点与适用性见表 2。

表 2 机器学习算法^[21-23]

Table 2 Machine learning algorithm^[21-23]


名称	优点	缺点	适用性
Linear Regression	支持线性和非线性模型,学习速度快,可处理非结构化数据与处理多元数据,且可以显示出变量之间的强度	可能会出现欠拟合或过拟合,容易受到异常值的影响,不能处理离散值或文本类型的数据	适用于预测和推断,特别适用于连续变量的预测,可以用于回归和分类任务
XGBoost	支持并行计算,可以处理稀疏数据,自动处理缺失值,还可提升算法的性能	对数据集有要求,不易理解和解释,需大量的计算时间	适用于分类问题,可用于回归、分类任务和计算序列预测
Random Forest	准确率高,能有效地在大数据集上运行,不容易过拟合	当决策树个数很多时,训练所需空间和ación会导致模型运行较慢	适合变量没有顺序,比较离散的分类问题

本系统根据以往水质预测的机器学习经验,采用 Linear Regression、XGBoost、Random Forest 三种算法学习了武汉市某水厂 90 天的进出水 COD、进出水 TN、进出水 TP、药剂投加量等数据,预测了历史投药量,与实际投药量进行对比,效果良好,如图 7 所示。


由图 7(a)可知,初始 10 天,由于所选模型刚开始学习,各个算法预测的混凝剂投加量与实际均有较大差距。随着数据集的增多,Linear Regression 算法预测量与实际投加量的差距越来越小,直至趋势走向基本相同,说明其在较小训练集的条件下便能够达到预期的预测效果。此外,结合图 7(b),Linear Regression 算法的相关系数约 0.98,均方误差为 0.02 左右,与其他算法的拟合效果比较,Linear Regression 算法预测准确率良好,学习效果优,拟合程度较高,本次继续采用了以 Linear Regression 算法为基础搭建机器学习模型。

3.2 模型构建与预测

搭建基于矾花图像识别的智能混凝剂投加机器学习模型时,通过反复学习,比较参数,在传统 Linear Regression 模型的基础上添加一个 7 维的全连接 BP 神经网络,其结构为 7×32×32×1,7 表



(a) 不同算法拟合预测效果



(b) 不同算法相关系数与均值方差对比

图 7 预测结果与实际数据对比

Fig. 7 Comparison between predicted results and actual data

示输入层有 7 个节点,对应着 7 个输入特征(如矾花数量、矾花平均等效直径、进水流量等),第一个 32 表示第一个隐藏层有 32 个节点,第二个 32 表示第二个隐藏层也有 32 个节点,1 表示输出层有一个节点,对应投药量。用(563,7)的样本集(563 条包含 7 项参数的样本的集合)进行训练,计算后确定每一层的最佳权重,最终得到输入层与输出层的线性关系,得到最低损失值为 0.018 的线性回归模型。

为考察机器学习模型的投药量预测效果,比较了其经验公式投药的差异。试验水厂当前混凝剂投加量主要依据经验公式确定,具体如公式(3)所示。其中 TP 目标值、投加系数与混凝剂密度均为定值,仅依靠进水流量和进水 TP 的变动改变投药量,对仪表依赖性强,投药波动幅度大。

$$L = \frac{Q \times (TP_1 - TP_2) \times K}{\rho \times 1000} \quad (3)$$

式中:L——混凝剂投加量,L/h;

Q——进水流量,m³/h;


TP_1 ——TP 进水值, mg/L;

TP_2 ——TP 目标值, mg/L;


K ——投加系数, 36;

ρ ——混凝剂密度, 1.4 g/cm^3 。

高密池 PAC 投药量预测值和经验值以及投加效果如图 8 所示。



(a) 智能投药量与经验投药量比较



(b) 智能投药与经验投药出水COD对比

图 8 智能投药与经验投药效果对比

Fig. 8 Comparison of intelligent dosing and experience dosing

由 8(a) 知, 在模型运行的前 50 h, 智能投药与经验投药的混凝剂投加量变化趋势均较为平缓, 在 120 L/h 至 130 L/h 范围波动, 而在 150 h 时因进水 COD 与 TP 突增, 智能投药与经验投药均出现 90~170 L/h 的大幅波动, 在 190 h 后, 机器学习模型预测值逐渐恢复稳定, 经验值仍呈振荡式波动, 说明机器学习模型预测的稳定性更好。经过积分处理, 得出智能控制的投药量较比经验投药低 11.0%。图 8(b) 为智能投药与经验投药的出水 COD 对比 (由于在线仪表存在一定的系统误差, 显示值偏低, 但不影响总体投药预测), 可以看出, 智能投药对应的出水 COD 在 100 h 后波动幅度减小, 表明智能投药系统出水的稳定性更好。

此外, 为增强模型的拟合效果, 通过干扰试验确定最佳投药范围、更新数据进行迭代学习和反馈调节的方法提高模型的智慧程度。

4 结 论

(1) 通过对图像识别算法的比较, 选择综合评分更高的 YOLOv5 进行矾花目标检测, 经过优化 YOLOv5 的检测准确率由 73.5% 提升至 83.5%, 能准确框选矾花, 确定位置信息和数量信息, 利于后续图像处理和数据提取。

(2) 研究采用直方图双峰全局单阈值分割法, 选取 135 灰度值作为全局阈值对图像进行二值化分割, 得到矾花数量、面积占比、等效直径等参数, 经数据处理后利用 KNN 算法进行矾花状态分类。

(3) 经过机器学习算法比较, 采用 Linear Re-

gression 算法进行学习, 在传统模型的基础上添加 7 维的隐藏层函数, 构成输入-时间序列数组-输出的神经元结构, 迭代计算后得到最低损失值为 0.018 的线性回归模型。

(4) 搭建了基于矾花图像识别的智能投药系统, 实现 PAC 等混凝剂的投加量的预测, 总体投药量降低 11.0%, 实现了混凝剂的自动化智能化投加, 与传统控制方法相比时延性更低, 可靠性更强, 同时降低了药耗, 减少水厂运营成本, 为其他水厂节能降耗提供了参考。

参考文献 (References):

- [1] GUPTA Vinod Kumar, ALI Imran, SALEH Tawfik A, et al. Chemical treatment technologies for waste-water recycling—An overview [J]. RSC Advances, 2012, 2: 6380–6388
- [2] XIA Xiang, LAN Shuhuan, LI Xudong, et al. Characterization and coagulation-flocculation performance of a composite flocculant in high-turbidity drinking water treatment [J]. Chemosphere; Environmental Toxicology and Risk Assessment, 2018, 206: 701–708.
- [3] 徐少川, 阎相伊, 刘宝伟, 等. 智能控制在净水混凝投药系统中的应用 [J]. 中国给水排水, 2017, 33(13): 60–63.
XU Shaochuan, YAN Xiangyi, LIU Baowei, et al. Application of intelligent control in coagulant dosing system in a waterworks [J]. China Water & Wastewater, 2017, 33(13): 60–63.
- [4] GAGNON Claude, GRANDJEAN Bernard P A, THIBAUT Jules. Modelling of coagulant dosage in a water treatment plant [J]. Artificial Intelligence in Engineering, 1997, 11(4): 401–404.
- [5] 王新增, 严国莉. 基于纹理特征的矾花图像自动识别方法 [J]. 电脑开发与应用, 2006, 9: 46–48.
WANG Xinzeng, YAN Guoli. Automatic recognition of alum im-

- age based on Texture Feature [J]. Computer Development & Applications, 2006, 9: 46-48.
- [6] 翟士才, 陆明刚. 基于机器视觉的混凝剂投加控制系统研究 [J]. 工业控制计算机, 2017, 30(9): 79-81.
ZHAI Shicai, LU Minggang. Research on coagulant dosing control system based on machine vision [J]. Industrial Control Computer, 2017, 30(9): 79-81.
- [7] YU Miao. Corpus English word detection and image recognition algorithm based on improved convolutional neural network [J]. Microprocessors and Microsystems, 2021, 82: 103920.
- [8] DEEPIKA Jaswal, SOWMYA V, SOMAN KP. Image classification using convolutional neural networks [J]. International Journal of Scientific and Engineering Research, 2014, 5(6): 1661-1668.
- [9] HUANG Shuiyuan, WAN Jiaan, ZHANG Deshun, et al. Image classification and adversarial robustness analysis based on hybrid quantum-classical convolutional neural network [J]. Optics Communications, 2023, 533: 129287.
- [10] HE Kaiming, GKIOXARI Georgia, DOLLAR Piotr, et al. Mask R-CNN [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 386-397.
- [11] DÜNTSCH Ivo, GEDIGA Gediga. Indices for rough set approximation and the application to confusion matrices [J]. International Journal of Approximate Reasoning, 2020, 118: 155-172.
- [12] VALERO Carreras Daniel, ALCARAZ Javier, LANDETE Mercedes. Comparing two SVM models through different metrics based on the confusion matrix [J]. Computers & Operations Research, 2023, 152: 106131.
- [13] 韦一, 张妙藏, 武智强, 等. 基于改进 YoloV5 的海面小目标检测方法 [C]. 2022 年无人系统高峰论坛 (USS2022), 2022: 80-85.
- [14] 严国莉. 基于数字图像处理对沉淀池矾花控制系统的算法研究 [D]. 成都: 四川大学, 2003: 19-22.
YAN Guoli. The research of alum control system in precipitator based on digital image processing [D]. Chengdu: Sichuan University, 2003: 19-22.
- [15] PADMANABHAN Krishnan, EDDY Willam F, CROWLEY Justin C. A novel algorithm for optimal image thresholding of biological data [J]. Journal of Neuroscience Methods, 2010, 193(2): 380-384.
- [16] 钟宜亚, 苗松池, 王桂娟. 一种基于全局阈值二值化方法的 BP 神经网络车牌字符识别系统 [J]. 计算机工程与科学, 2010, 32(2): 88-90.
ZHONG Yiya, MIAO Songchi, WANG Guijuan. A plate-character identification system based on global-value binarization and the BP neural network [J]. Computer Engineering & Science, 2010, 32(2): 88-90.
- [17] 沈彦. 基于机器视觉的多级分析絮凝加药表征系统 [J]. 集成电路应用, 2022, 39(1): 63-65.
SHEN Yan. Multi-level analysis flocculation dosing characterization system based on machine vision [J]. Application of IC, 2022, 39(1): 63-65.
- [18] MURAVSKII G B. Choice of specific interpolation points in quadrature formula for integrals containing Bessel functions [J]. Applied Mathematics and Computation, 2013, 224: 724-734.
- [19] CAI Jian, BARLOW Robert S, KARPETIS Adonios N, et al. Conditionally filtered diffusion of mixture fraction and temperature in turbulent partially premixed flames [J]. Proceedings of the Combustion Institute, 2011, 33(1): 1505-1513.
- [20] 李景奎, 张义民. 基于 KNN 方法的多载荷作用下连续体结构拓扑优化设计 [J]. 机械科学与技术, 2012, 31(6): 873-876.
LI Jingkui, ZHANG Yimin. K Nearest Neighbor based topology optimization design of multi-loaded continuum structure [J]. Mechanical Science and Technology for Aerospace Engineering, 2012, 31(6): 873-876.
- [21] SAMUELSSON Oscar, BJORK Anders, ZAMBRANO Jesus, et al. Gaussian process regression for monitoring and fault detection of wastewater treatment processes [J]. Water Science and Technology, 2017, 75(12): 2952-2963.
- [22] YE Miao, ZHU Lin, LI Xiaojuan, et al. Estimation of the soil arsenic concentration using a geographically weighted XGBoost model based on hyperspectral data [J]. Science of the Total Environment, 2023, 858: 159798.
- [23] TOFT Håvard B, MÜLLER Karsten, HENDRIKX Jordy, et al. Can big data and random forests improve avalanche runout estimation compared to simple linear regression? [J]. Cold Regions Science and Technology, 2023, 211: 103844.