

供排水企业运行及管理成果专栏

陈汪洋. 水厂絮凝过程矾花状态的自动识别与应用[J]. 净水技术, 2023, 42(10): 179–189.

CHEN W Y. Automatic recognition and application of alum state in the coagulation process of WTPs[J]. Water Purification Technology, 2023, 42(10): 179–189.

水厂絮凝过程矾花状态的自动识别与应用

陈汪洋*

(中国水务投资有限公司, 北京 100053)

摘要 针对净水工艺絮凝剂优化调控过程中面临的非线性、大迟滞和多变量因素问题, 文中研究了矾花图像分割和特征提取方法, 提出了一种基于深度模糊非参数映射(DFM)模型的矾花状态自动识别技术。该技术将矾花状态细分为密实、中片、大片、不均和稀疏5种类型, 通过图像采集系统分别采集相应的图像来构建样本库, 并使用样本库训练模型的相关参数。研究结果表明, 从矾花图像中提取密度特征和尺寸特征作为模型输入可以获得最佳的识别效果。DFM模型在矾花状态识别方面的准确率可以达到95%以上, 明显优于传统的机器学习方法[如支持向量机(SVM)、反向传播(BP)神经网络]和深度学习方法(如ResNet和AlexNet模型)。同时, 基于DFM模型的矾花图像识别技术已经成功应用于舟山某水厂, 在应用前后, 絮凝剂的平均投加量从11 mg/L降低到8.5 mg/L, 沉淀池的平均出水浑浊度从0.9 NTU降低到0.4 NTU。

关键词 净水工艺 絮凝过程 矾花识别 深度学习 模糊优化

中图分类号: TU991 **文献标识码:** A **文章编号:** 1009-0177(2023)10-0179-11

DOI: 10.15890/j.cnki.jsjs.2023.10.023

Automatic Recognition and Application of Alum State in the Coagulation Process of WTPs

CHEN Wangyang*

(China Water Investment Co., Ltd., Beijing 100053, China)

Abstract In response to the challenges of nonlinearity, hysteresis, and multivariable factors in the optimization and control process of coagulants for water treatment processes, this paper investigated the method of image segmentation and feature extraction for floc recognition, and proposed an floc image state automatic recognition technique based on the deep nonparametric fuzzy mapping model (DFM). The floc states were categorized into five types: dense, medium-sized, large, uneven, and sparse. Corresponding images were captured using an image acquisition system to build a sample library, and model parameters were trained based on this library. The research results indicated that extracting density and size features from alum flower images as model inputs achieved the best recognition performance. The DFM model achieved an accuracy rate of over 95% in alum flower state recognition, which was significantly superior to traditional machine learning methods such as support vector machine (SVM) and back propagation (BP) neural network, as well as deep learning methods such as ResNet and AlexNet models. Furthermore, the floc image recognition technology based on the DFM model had been successfully applied in a water treatment plant (WTP) in Zhoushan. Before and after the application, the average dosage of coagulant had decreased from 11 mg/L to 8.5 mg/L, and the average effluent turbidity value from the sedimentation tank had decreased from 0.9 NTU to 0.4 NTU.

Keywords water treatment process coagulation process alum recognition deep learning fuzzy optimization

[收稿日期] 2023-06-12

[通信作者] 陈汪洋(1976—), 男, 高级工程师, 主要从事供水排水及环境工程的规划、技术管理及研究工作, E-mail: chenwangyang@vip.sina.com.

絮凝是净水工艺中的重要环节, 絮凝过程中准确控制絮凝剂的投加量是关键^[1]。絮凝剂投加调控面临着几个主要问题。首先是非线性关系^[2], 投加量和效果之间并非简单线性关系, 存在饱和效应

或非线性响应。其次,絮凝过程具有较大的迟滞效应^[3],投加量的变化不会立即反映在效果上。最后,絮凝过程受到多个变量因素的影响^[4],需要考虑这些因素的相互作用和影响关系。为解决这些问题,需要采用系统辨识和模型预测控制等技术,建立准确的非线性模型,并考虑迟滞效应和多变量影响,通过优化算法和控制策略实现准确的投加量控制,以达到最佳效果。

近年来,基于机器学习和深度学习技术的矾花图像识别技术逐渐应用于絮凝优化控制过程^[5-6]。机器学习和深度学习的应用可以实现矾花图像的特征提取、分类和目标检测,帮助运营人员发现异常情况,优化投加量,提高絮凝效果和水质稳定性,进一步提升水处理系统的运行效率和可靠性^[7]。

然而,基于机器学习或深度学习的矾花图像识别研究仍面临挑战。主要问题包括维数灾难、迁移性差和鲁棒性差。为了解决这些问题,本文提出了基于深度模糊非参数映射(DFM)模型的矾花图像识别增强算法,具有较高的计算效率、识别准确率和鲁棒性,提高了矾花识别的准确性和稳定性。

1 矶花采集实验平台搭建

矾花采集实验平台是由水下摄像机、固定支架、通讯线缆、图像处理器组成。其中,水下摄像机搭载500万像素、工业级、定焦、自动补光的摄像头,具有防水和自动清洗的功能。通过调整镜头焦距,确保矾花图像清晰,并将此焦距作为统一的拍摄标准。

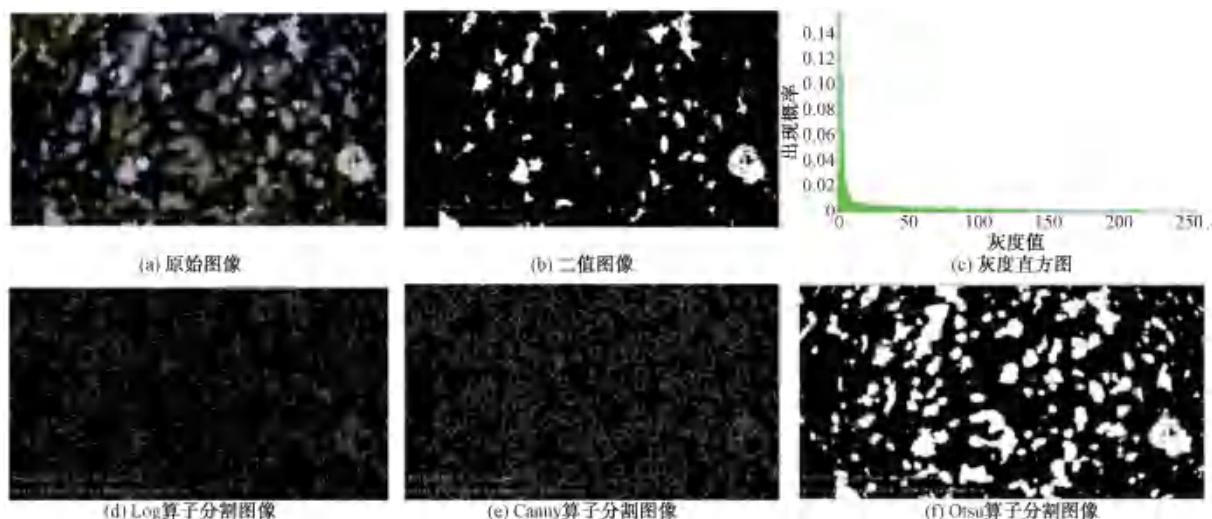


图 2 矶花原图与各种图像分割算法对比

Fig. 2 Comparison of Alum Original Image and Various Image Segmentation Algorithms

水下摄像机的安装位置取决于矾花生成位置和絮凝工艺结构。矾花是由絮凝药剂投加后逐步形成的絮体。因此,矾花图像的拍摄主要集中在矾花成熟状态,即位于絮凝反应池末端,尚未进入沉淀池的过渡区域,如图1所示。水下摄像机应安装在水深为0.5~1.0 m的位置。



图 1 絮凝沉淀池中水下摄像机的安装位置

Fig. 1 Installation Position of the Underwater Camera in the Flocculation Sedimentation Tank

2 图像分割和特征提取

2.1 图像分割算法

将矾花主体从背景中分离出来是矾花识别的第一步,分离效果会对后续矾花识别的精度有较大影响。本研究测试并比较了目前常见的图像分割算法,包括直方图分割^[8]、Log算子分割^[9]、Canny算子分割^[9]、Otsu算子分割^[10]等,结果如图2(a)~图2(f)所示。其中Otsu算法在性能和精度上相较其他算法在本研究试验数据集中取得了最优的效果,如图2(f)所示。Otsu算子能够提取矾花图像中高对比度的线条,这些线条在描绘矾花的轮廓同时还包

含间隙,有利于分离形态复杂的矾花。因此,Otsu 算子作为本次研究的图像分割算法。

2.2 矶花图像特征提取

在矶花图像分割的基础上,本研究进一步提取矶花图像特有的统计特征,作为训练模型的输入,以提高矶花分类的准确率,包括矶花的平均絮凝体尺寸(基于平均费雷特直径)、矶花絮凝体面积、矶花絮凝体面积方差、整体占比、最大片占比、矶花数量、面积中位数、花絮凝体周长、矶花圆形度以及矶花分形维数等。传统对矶花形态的研究主要集中在面积和周长等指标,本研究引入分形维数,分形维数有助于描述欧几里得几何没有很好定义的大型、不规则、多孔聚集体的粗糙表面特征。在分形几何中,面积和体积不是以标准特征长度来表征,而是以整数幂来表征。具有不规则边界的非均匀形态可以通过非线性关系来定义,其中物体的特性随着特征长度维度的增加而缩放,其幂被称为分维。分形维数的计算方法如式(1)^[10]。

$$\ln A = D_f \ln L + \ln a \quad (1)$$

表 1 矶花图像标签及说明
Tab. 1 Labels and Descriptions of Floc Image

矶花图像示例	图像标签	标签说明
	密实	矶花状态细小紧密、分布均匀、密集度高;类似小米的雪花是高流量负荷运行状态下较为理想的矶花状态
	中片	矶花状态较大,较密实状态明显增大,分布均匀、密集度高;类似鹅毛的中雪是中等运行流量负荷下较为理想的矶花状态
	大片	矶花为大型片状、数量较少、密集度低,小矶花不多、不明显;属于低流速下的矶花状态,不利于沉淀,可能出现矾花上浮现象,影响出水水质

其中: A ——絮体颗粒的投影面积, m^2 ;

L ——投影的最大长度, m ;

a ——比例常数;

D_f ——絮体在二维空间的分形维数。

絮体分型维数能够反映混凝阶段,可以将其作为混凝投药量控制的反馈参数。

3 矶花图像数据集构建

本研究基于舟山某水厂絮凝池图像采集系统构建了一个包含不同种类的矶花图像数据集。该数据集的构建经过精心设计和标注,涵盖了典型的矶花形态和颜色变化(表 1)。数据集中包含了各种光照条件下的矶花图像,以及不同絮凝剂投加量和池水浑浊度的情况。该数据集的构建为矶花图像识别算法的研究提供了宝贵的资源和平台。研究者们可以利用这个数据集进行算法的训练和评估,提出新的方法和技术来改进矶花图像的识别准确性和稳定性。此外,该数据集还可以用于验证不同算法的泛化能力和实际

应用效果。

(续表1)

矾花图像示例	图像标签	标签说明
	不均	矾花大小不均,部分矾花明显较大;属于不太理想的状态,大的矾花可能无法沉降,导致出水变差
	稀疏	矾花小,数量少;系统可能出现问题,加药严重不足或停止加药等

本研究矾花图像数据采集覆盖 24 h,同时结合舟山某水厂智慧加药系统接入水质参数,包括进水浑浊度、电导率、COD、pH 等。研究阶段共采集图像 10 万余张,对采集图像进行各种特征值的均值,同时剔除异常数据,特征属性如表 2 所示。

表 2 矾花提取特征属性值

Tab. 2 Feature Attribute Values of Alum Images

矾花特征	平均值
矾花的絮凝体尺寸/ μm	45
矾花絮凝体周长/ μm	183
矾花絮凝体面积/ μm^2	95.73
矾花絮凝体面积方差/ μm^4	380.18
整体占比	4.2%
最大片占比	0.51%
矾花数量/个	549
面积中位数	13
矾花圆形度	0.3°
矾花分形维数	1.6

4 矜花图像识别

4.1 DFM 模型

本文使用 DFM 对矾花图像进行识别,DFM 由若干个 DFM 单元组成,如图 3 所示^[11]。

图 3 为一个典型的多输入多输出 DFM 模型,其中 $\mathbf{m}_x = [m_{x_1}, m_{x_2}, \dots, m_{x_n}]^T \in R^n$ 表示 n 维无噪音输入向量; $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in R^n$ 表示 n 维有噪音输入向量(观测值); $\mathbf{v}_x = [v_{x_1}, v_{x_2}, \dots, v_{x_n}]^T \in R^n$ 表

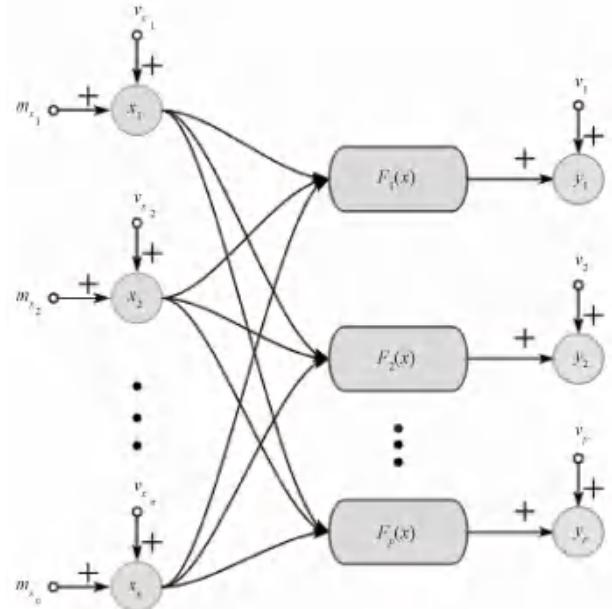


图 3 多输入多输出 DFM

Fig. 3 Multi-Input/Multi-Output DFM with Input and Output Noises

示 n 维输入噪音向量, $x_i = m_{x_i} + v_{x_i}$ ($i \in 1, 2, \dots, n$); $\mathbf{y} = [y_1, y_2, \dots, y_p]^T \in R^p$ 表示 p 维包含噪音的输出向量; $\mathbf{v} = [v_1, v_2, \dots, v_p]^T \in R^p$ 表示 p 维输出噪音向量, $y_j = F_j(x) + v_j$ ($j \in 1, 2, \dots, p$); $F_j(\cdot)$ 表示 \mathbf{y} 第 j 个输出对应的输入向量 \mathbf{x} 的模糊映射。本文中输入向量 \mathbf{x} 和输出向量 \mathbf{y} 分别对应矾花图像和图像标签, $\mathbf{m}_x, \mathbf{v}_x$ 和 \mathbf{v} 参数未知,其特征通常使用模糊隶属函数(例如:高斯隶属函数或伽马隶属函数)来描述。

本文 $F_j(\cdot)$ 中使用的是 t 分布,主要是因为 t 分布在有限数据的统计分析方面表现出卓越的性能优势。对于给定的 N 个样本的输入向量 $\mathbf{x} = \{\mathbf{x}^i | \mathbf{x}^i \in R^n, i = 1, 2, \dots, N\}$, 对应的模糊映射集为 $\mathbf{f}_j = [F_j(\mathbf{x}^1), F_j(\mathbf{x}^2), \dots, F_j(\mathbf{x}^N)]^T \in R^N$, f_j 的不确定性通过 t 分布隶属函数 $\mu(f_j)$ 来表征,如式(2)和式(3)。

$$\mu(f_j) = \frac{1}{\zeta + N} + \frac{1}{\zeta} (\mathbf{f}_j - \mathbf{m}_j)^T (\mathbf{K}_{xx})^{-1} (\mathbf{f}_j - \mathbf{m}_j) \quad (2)$$

$$\mathbf{K}_{xx} = \begin{bmatrix} k(\mathbf{x}^1, \mathbf{x}^1) & \cdots & k(\mathbf{x}^1, \mathbf{x}^N) \\ \vdots & \ddots & \vdots \\ k(\mathbf{x}^N, \mathbf{x}^1) & \cdots & k(\mathbf{x}^N, \mathbf{x}^N) \end{bmatrix} \quad (3)$$

其中: ζ —— 实数, 取值为 0~2;

\mathbf{m}_j —— 平均向量;

\mathbf{K}_{xx} —— $N \times N$ 协方差矩阵。

K_{xx} 第 i 行第 j 列元素如式(4)。

$$k(\mathbf{x}^i, \mathbf{x}^j) = \sigma^2 \exp\left(-\frac{1}{2} \sum_{k=1}^n w_k (\mathbf{x}_k^i - \mathbf{x}_k^j)^2\right) \quad (4)$$

其中: σ —— 方差;

w_k —— 权重。

本文所提出的模糊映射是一个非参数模型,因为它没有参数形式的特征,而是通过选择核函数 $k(\mathbf{x}^i, \mathbf{x}^j)$ 来定义其特征。将有限个图 3 所示的 DFM 单元组合在一起,形成了深度 DFM 模型(图 4)。

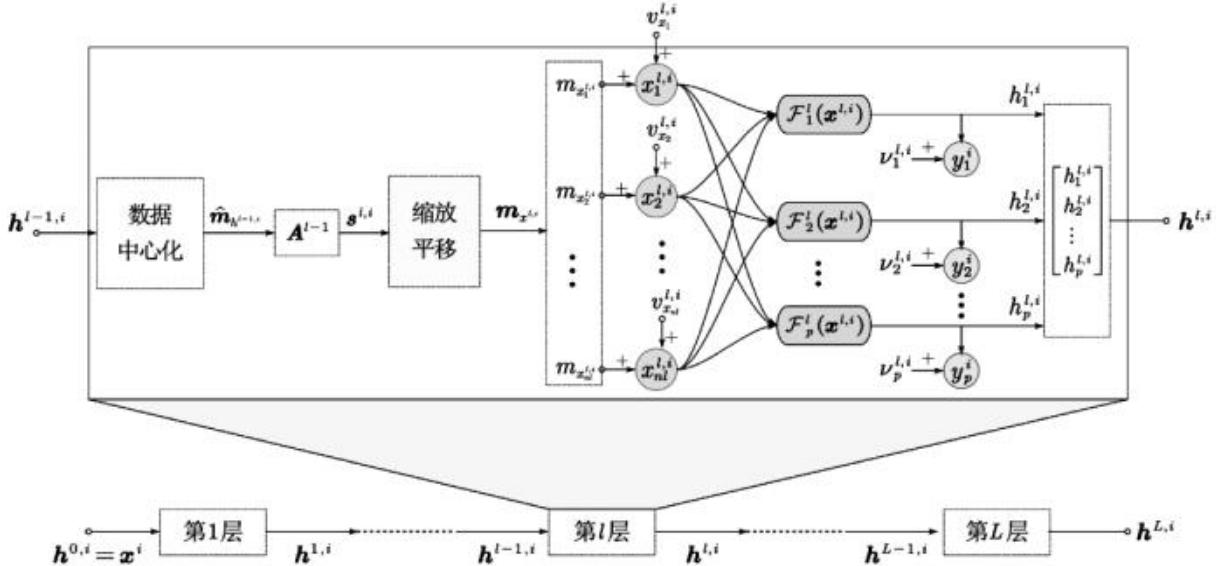


图 4 深度 DFM 模型(L 层)

Fig. 4 Model of Deep DFM (L -Layer)

图 4 是 L 个 DFM 单元组成的深度模糊映射模型架构。令 $\{\mathbf{x}^i, \mathbf{y}^i\}_{i=1}^N$ 为 N 个输入输出样本对, $\mathbf{x}^i = [x_1^i, x_2^i, \dots, x_n^i]^T \in R^n$ 表示第 i 个输入样本, $\mathbf{y}^i = [y_1^i, y_2^i, \dots, y_p^i]^T \in R^p$ 表示第 i 个输出样本; $\mathbf{h}^{l,i} = [h_1^{l,i}, h_2^{l,i}, \dots, h_p^{l,i}]^T \in R^p$ 表示第 l 层的模糊映射输出, $h_j^{l,i} = F_j^l(\mathbf{x}^{l,i})$; $\boldsymbol{\nu}^{l,i} = [\nu_1^{l,i}, \nu_2^{l,i}, \dots, \nu_p^{l,i}]^T \in R^p$ 表示第 l 层的输出误差, $y_j^i = h_j^{l,i} + \nu_j^{l,i}$; $\mathbf{x}^{l,i} = [x_1^{l,i}, x_2^{l,i}, \dots, x_n^{l,i}]^T \in R^{nl}$ 为第 l 层的输入向量; $\mathbf{v}_x^{l,i} = [\mathbf{v}_{x_1}^{l,i}, \mathbf{v}_{x_2}^{l,i}, \dots, \mathbf{v}_{x_n}^{l,i}]^T \in R^{nl}$ 为第 l 层的输入误差, $\mathbf{x}^{l,i} = \mathbf{m}_{x^{l,i}} + \mathbf{v}_x^{l,i}$; $\mathbf{m}_{x^{l,i}} \in R^{nl}$ 为缩放向量, 计算过程如式(5)~式(8)。

$$\begin{aligned} \hat{h}_1^{l-1,i} &= \frac{1}{N} \sum_{m=1}^N h_1^{l-1,m} \\ \hat{h}_2^{l-1,i} &= \frac{1}{N} \sum_{m=1}^N h_2^{l-1,m} \\ \hat{h}_{p-1}^{l-1,i} &= \frac{1}{N} \sum_{m=1}^N h_{p-1}^{l-1,m} \\ \hat{h}_p^{l-1,i} &= \frac{1}{N} \sum_{m=1}^N h_p^{l-1,m} \end{aligned} \quad (5)$$

$$\frac{1}{N-1} \hat{\mathbf{m}}_{h^{l-1,i}} (\hat{\mathbf{m}}_{h^{l-1,i}})^T = \mathbf{U} \Lambda \mathbf{U}^T \quad (6)$$

$$s^{l,i} = \begin{cases} \mathbf{A}^{l-1} \mathbf{x}^i, & if l = 1 \\ \mathbf{A}^{l-1} \mathbf{h}^{l-1,i}, & if l \in \{2, \dots, L\} \end{cases} \quad (7)$$

$$m_{x_k^{l,i}} = x^{\text{low}} + (x^{\text{high}} - x^{\text{low}}) \left(\frac{s_k^{l,i} - s_k^{l,\min}}{s_k^{l,\max} - s_k^{l,\min}} \right) \quad (8)$$

其中: $\hat{\mathbf{m}}_{h^{l-1,i}}$ ——第 $l-1$ 样本 i 数据中心化之后的模型输入向量;

$\mathbf{h}^{l-1,i}$ ——第 $l-1$ 层样本 i 输入向量;

$\bar{\mathbf{h}}^{l-1}$ ——样本中心点向量;

$\Lambda \in R^{p \times p}$ ——基于奇异值分解(SVD)算法得到的特征值对角矩阵(由大到小排序);

$\mathbf{U} \in R^{p \times p}$ —— Λ 对应的特征向量矩阵;

\mathbf{A}^{l-1} —— \mathbf{U} 前 nl 行组成的矩阵;

$s_k^{l,i}$ ——向量 $s^{l,i}$ 中第 k 个元素。

$$s_k^{l,\min} = \min_i (\{s_k^{l,i}\}_{i=1}^N); s_k^{l,\max} = \max_i (\{s_k^{l,i}\}_{i=1}^N) (k \in$$

$1, 2, \dots, nl\}; x^{\text{low}} = -(N-1); x^{\text{high}} = N-1$ 。关于深度 DFM 模型的求解方法,许多研究学者进行了更为深入的研究,保证了模型的求解效率、识别准确度和识别结果的稳定性。

4.2 图像识别方法及识别性能对比

为了验证深度 DFM 模型在矾花图像识别中的性能,本文选用支持向量机(support vector machine, SVM)模型^[12]、反向传播(back propagation, BP)神经网络模型^[13]、ResNet 模型^[14] 和 AlexNet 模型^[15]与 DFM 模型进行对比。

4.2.1 SVM 模型

SVM 是一种广泛应用于分类和回归分析的机器学习方法^[12]。SVM 的核心思想是通过将数据映射到高维特征空间,使得数据在该空间中线性可分,该映射基于核函数来实现,常用的核函数有线性核函数、多项式核函数和高斯径向基函数。在高维特征空间中,SVM 通过最大化支持向量到超平面的间隔来确定最优决策边界。

4.2.2 BP 神经网络模型

BP 神经网络是一种基于反向传播算法的人工神经网络模型^[13]。它是一种多层次前馈神经网络,具有强大的非线性拟合能力和适应性。BP 神经网络的原理是通过训练数据来调整网络的权值和偏置,从而实现对输入数据的映射和分类。BP 神经网络由输入层、隐藏层和输出层组成,通过反向传播算法实现参数训练,并计算梯度和调整权值,逐步减小误差,直到 BP 神经网络的输出与真实值之间的误差达到预定的精度要求。

4.2.3 ResNet 模型

ResNet 是一种深度残差网络模型,被广泛应用于图像识别和计算机视觉任务中^[14]。ResNet 通过引入残差连接来解决深层网络中的梯度消失和网络退化问题,实现了深度网络结构的有效训练。深度残差神经网络的基本结构由残差块组成,使用随机梯度下降(SGD)算法进行优化。在训练过程中,通过最小化损失函数来调整网络的权值,使得网络能够更好地拟合训练数据。

4.2.4 AlexNet 模型

AlexNet 是第一个将深度卷积神经网络成功应用于大规模图像分类任务的模型^[15]。它采用了卷积层和池化层的交替结构,通过卷积操作提取图像的特征,并通过池化操作减小特征图的尺寸。卷积层使用较小的卷积核对输入图像进行滑动窗口操作,提取出不同的特征。池化层则用于降低特征图的尺寸和参数数量,减少计算复杂度。为了进一步提高模型的性能,AlexNet 采用了数据增强和 Dropout 技术。数据增强通过对训练数据进行平移、旋转、翻转等操作,扩充了训练集的规模,减少了过拟合风险。Dropout 技术则在训练过程中随机关闭一部分神经元,以减少神经元之间的依赖关系,提高模型的泛化能力。

本文采用 2 种方案对上述图像识别方法的性能进行对比:(1)方案 1,矾花图像数据集不经过处理,直接将原始矾花图像与标签分别作为模型的输入和输出;(2)方案 2,使用本文提出的方法首先提取矾花图像特征值,将特征值与标签分别作为模型的输入和输出。

SVM 模型、BP 神经网络、ResNet 模型、AlexNet 模型和 DFM 模型的相关参数设置如表 3 所示。

针对上述模型,数据集按 7 : 3 比例随机分为训练集和测试集,训练集用于训练模型参数,测试集用于验证模型的识别精度,矾花图像识别性能对比如表 4 所示。

由表 4 可知,在图像未经过任何处理的情况下,DFM 模型仍然具有 80% 以上的分类准确率。对图像进行预处理,并将特征作为输入,DFM 模型能够达到 95% 以上的识别准确率,表明本文提出的基于 DFM 模型的矾花图像识别方法具有更高的准确率和稳定性,能够应用于实际工程中。

表 3 相关模型参数设置

Tab. 3 Related Model Parameter Settings

模型	参数设置
SVM	核函数:RBF(径向基函数) RBF 参数: $\gamma \in [2^{-8}, 2^8]$ 惩罚系数: $C \in [2^{-8}, 2^8]$
BP	隐含层数量:10 训练函数:Levenberg-Marquardt 最大训练次数:20 学习率:0.01
ResNet	卷积层数量:17 全连接层数量:1 循环次数:epoch = 300 (一个 epoch 指代所有的数据送入网络中完成一次前向计算及反向传播的过程) 学习率:0.01
AlexNet	卷积核大小:3×3 池化层大小:2×2 全连接层参数:dropout = 0.15(Dropout 是一种在学习的过程中随机删除神经元的方法,可用于抑制过拟合) 分类函数:softmax(Softmax 是一种数学函数,通常用于将一组任意实数转换为表示概率分布的实数)
DFM	最大层数: $L_{\max} = 20$ t 分布自由度: $s = 2.1$ 训练误差阈值:0.01

表 4 不同方法矾花图像识别准确率

Tab. 4 Accuracy of Image Recognition by Using Different Methods

模型	方案 1	方案 2
SVM	31.16%	78.10%
BP	19.88%	67.42%
ResNet	65.32%	90.02%
AlexNet	25.95%	71.12%
DFM	83.71%	96.47%

5 矾花图像识别的工程应用分析

目前,基于 DFM 模型的矾花图像识别技术已经成功应用在舟山某水厂净水工艺过程中(图 5)。本项目加药系统使用前馈+反馈复合加药控制算法(图 6)。前馈专家控制器可根据原水的浑浊度、温度、COD 等推算出大致的加药量。反馈比例控制器根据矾花识别的状态对沉淀池后水浑浊度反馈作微调,最后,结合实时流量算出最佳加药量。

前馈控制:首先将水厂现状及该水厂的水质因素进行分析研究,然后以影响出水水质主要因素为输入,如原水流量、原水池度、原水温度及原水值为输入,混凝剂投加量为输出,建立混凝投药量通用寄存器(general purpose register, GPR)前馈控制系统。



图 5 水厂智慧加药系统

Fig. 5 Intelligent Dosing System of WTP

反馈控制:被控量实际输出与设定值存在偏差,控制器通过检测到的差值,有针对性地进行调节的过程。本方案反馈控制以矾花图像算法为基础,水下图像采集装置以 500 万~1 000 万像素工业相机

为传感器,以 PC 为主控器,连续采集水厂处理池中矾花图像。根据本文描述的图像分割-特征提取-算法识别过程实时分析矾花形态(图 7),评判水质参数,用于自动监测水厂净水处理过程中的絮凝状

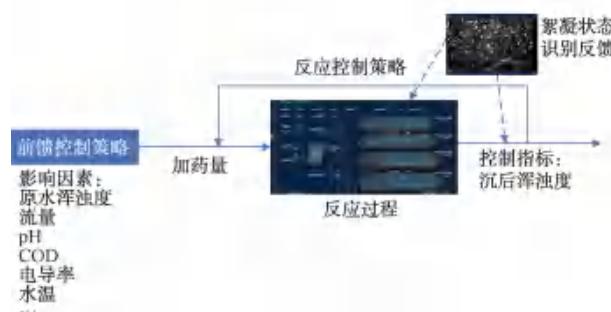


图 6 絮凝加矾系统优化控制过程: 前馈+反馈流程

Fig. 6 Optimization and Control Process of Coagulation and Alum Dosing System: Feedforward + Feedback Loop

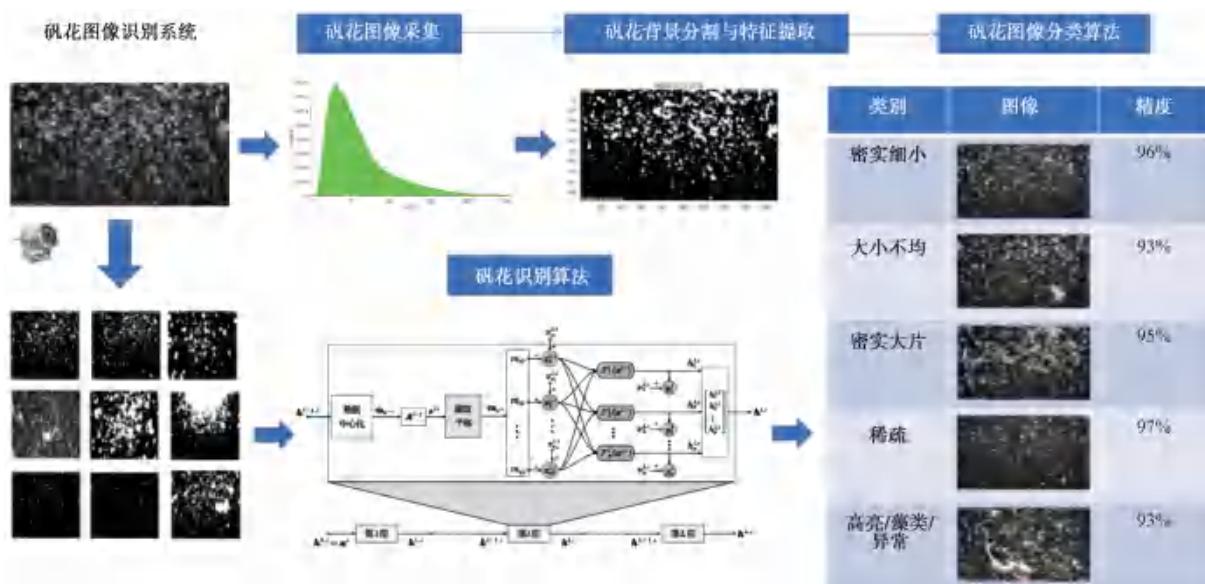


图 7 矶花识别系统: 图像采集+分割+特征提取+识别算法

Fig. 7 Floc Recognition System: Image Acquisition + Segmentation + Feature Extraction + Recognition Algorithm

态, 反馈调节加矾量, 同时减少絮凝过程中检测絮凝效果的时滞。采用反馈校正和在线滚动优化指标的策略, 能够有效克服受控对象的时延、时变和不确定性等因素的动态影响, 并使系统具有良好的稳定性和鲁棒性。

5.1 出水浑浊度达标率分析

图 8 为出水浑浊度达标率的对比, 系统 12 月 1 日开始测试, 数据取自 2022 年 7 月—2023 年 5 月, 间隔周期为 10 min。如图 8 所示, 使用前后, 沉后水浑浊度波动明显降低, 水质更加稳定, 系统投用后沉后水浑浊度达标率(小于 1 NTU)占比由 82.2% 上升为 95.6%, 具体数据如表 5 所示。

5.2 出水浑浊度稳定性分析

图 9 为出水浑浊度稳定性的对比, 2023 年 1 月

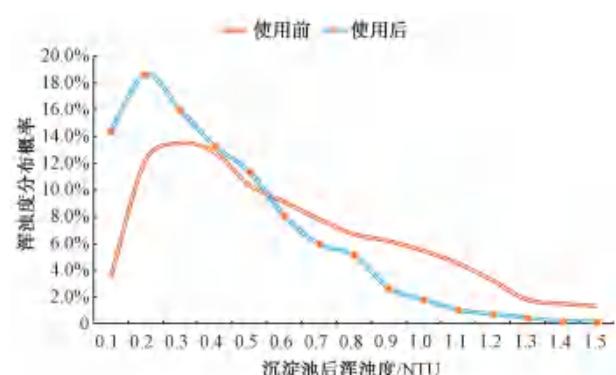


图 8 出水浑浊度达标率对比

Fig. 8 Comparison of Effluent Turbidity Compliance Rates
18 日目标值由 0.7 NTU 调到 0.25 NTU, 1 月 29 日调到 0.7 NTU, 2 月 10 日调到 0.6 NTU, 3 月 3 日调

表 5 不同方法矾花图像识别准确率
Tab. 5 Accuracy of Fritillaria Flower Image Recognition Using Different Methods

浑浊度/NTU	使用前	使用后	浑浊度/NTU	使用前	使用后
0.1~0.2	3.50%	14.40%	0.9~1.0	6.20%	2.70%
0.2~0.3	12.20%	18.60%	1.0~1.1	5.50%	1.80%
0.3~0.4	13.50%	16.00%	1.1~1.2	4.50%	1.10%
0.4~0.5	12.80%	13.30%	1.2~1.3	3.20%	0.70%
0.5~0.6	10.40%	11.40%	1.3~1.4	1.80%	0.50%
0.6~0.7	9.10%	8.10%	1.4~1.5	1.50%	0.20%
0.7~0.8	7.80%	6.00%	1.5~1.6	1.30%	0.10%
0.8~0.9	6.70%	5.10%			

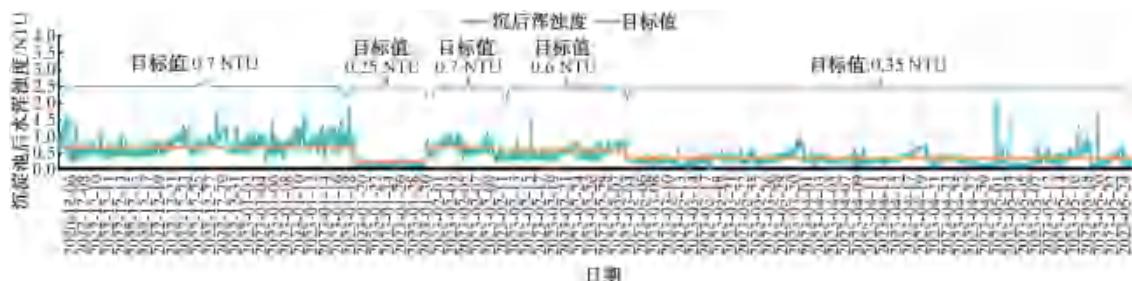


图 9 2022 年 12 月—2023 年 5 月出水浑浊度稳定性对比

Fig. 9 Comparison of Outflow Turbidity Stability from December 2022 to May 2023

到 0.35 NTU, 伴随着沉后浑浊度真实值随目标值变化。数据做目标值与真实值的差值对比, 引入偏差值。偏差值在 ± 0.2 NTU 的数据, 占数据总量的 91.5%, 沉后浑浊度控制精度保持在 90% 以上时间达到 ± 0.2 NTU 以内。

5.3 系统药耗使用量分析

表 6 为系统药耗使用量对比分析, 加药量对比需要在相同的进水水质下作药剂对比分析, 因此, 选

用相同的时间段和进水水质, 采用原有的控制方式和智慧加药对比。2022 年 11 月, 采用了智慧加药控制的 4# 和原有的控制的 1#~3# 进行对比, 1#~4# 沉淀池出水浑浊度均值分别为 0.67、0.72、0.64、0.69 NTU, 1#~3# 药耗均值为 30.48 mg/L, 4# 为 23.84 mg/L。在 1#~3# 与 4# 出水浑浊度均值在 0.6~0.7 NTU 的情况下, 4# 的药剂消耗较 1#~3# 的药剂消耗降低 21.78%。

表 6 系统药耗使用量分析
Tab. 6 Comparison of System Chemicals Consumption

时间	1#沉淀池出水浑浊度/NTU	2#沉淀池出水浑浊度/NTU	3#沉淀池出水浑浊度/NTU	4#沉淀池出水浑浊度/NTU	1#~3#药耗均值/(mg·L ⁻¹)	4#药耗量/(mg·L ⁻¹)	节药量
2022-11-01	0.66	0.81	0.73	0.82	31.80	22.54	29.12%
2022-11-02	0.64	0.66	0.57	0.38	28.14	19.99	28.96%
2022-11-03	0.99	0.97	0.60	0.68	29.66	20.13	32.13%
2022-11-04	0.81	0.76	0.74	0.69	28.78	27.82	3.34%
2022-11-05	0.81	0.74	0.71	0.62	28.86	23.36	19.06%
2022-11-06	0.85	0.81	0.79	0.63	28.94	20.54	29.03%
2022-11-07	0.98	0.93	0.94	0.66	28.86	19.94	30.91%
2022-11-08	0.73	0.84	0.75	0.92	32.61	33.47	-2.64%
2022-11-09	0.71	0.82	0.73	0.76	32.60	29.29	10.15%
2022-11-10	0.51	0.66	0.58	0.47	32.46	25.33	21.97%

(续表6)

时间	1#沉淀池出水浑浊度/NTU	2#沉淀池出水浑浊度/NTU	3#沉淀池出水浑浊度/NTU	4#沉淀池出水浑浊度/NTU	1#~3#药耗均值/(mg·L ⁻¹)	4#药耗量/(mg·L ⁻¹)	节约量
2022-11-11	0.60	0.68	0.60	0.62	32.51	23.34	28.21%
2022-11-12	0.66	0.76	0.68	0.89	32.42	25.72	20.67%
2022-11-13	0.72	0.79	0.86	0.94	29.94	25.75	13.99%
2022-11-14	0.72	0.74	0.63	0.80	29.61	22.24	24.89%
2022-11-15	0.81	0.86	0.53	0.72	29.70	20.01	32.63%
2022-11-16	0.82	0.87	0.59	0.79	29.44	20.13	31.62%
2022-11-17	0.81	0.88	0.58	0.91	30.88	19.96	35.36%
2022-11-18	0.74	0.84	0.56	0.78	31.57	20.91	33.77%
2022-11-19	0.66	0.74	0.80	0.95	31.47	26.66	15.28%
2022-11-20	0.59	0.69	0.63	0.52	31.49	24.66	21.69%
2022-11-21	0.63	0.68	0.63	0.56	31.66	22.18	29.94%
2022-11-22	0.74	0.81	0.73	0.90	31.40	28.17	10.29%
2022-11-23	0.77	0.84	0.72	0.95	31.58	31.43	0.47%
2022-11-24	0.78	0.82	0.74	0.96	30.13	31.26	-3.75%
2022-11-25	0.70	0.85	0.78	0.69	29.71	27.44	7.64%
2022-11-26	0.38	0.56	0.49	0.42	29.67	22.92	22.75%
2022-11-27	0.30	0.37	0.40	0.32	29.54	20.16	31.75%
2022-11-28	0.27	0.32	0.37	0.30	30.01	20.00	33.36%
2022-11-29	0.27	0.27	0.30	0.30	29.60	20.01	32.40%
2022-11-30	0.48	0.30	0.34	0.77	29.48	19.84	32.70%

6 结论

(1) 分割算法方面分别对直方图分割、Log 算子分割、Canny 算子分割、Otsu 算子分割加线性变化等算法并进行比较,结果表明 Otsu 算法结合线性变化在性能和精度上相较其他算法在本研究试验数据集中取得了最优的效果。

(2) 特征提取方面:计算了矾花的平均絮凝体尺寸(基于平均费雷特直径)、矾花絮凝体面积、整体占比、最大片占比、矾花絮凝体周长,矾花圆形度以及矾花分形维数。结果表明,从矾花图像中提取密度特征和尺寸特征作为模型输入,能够达到最好的识别效果。

(3) 识别算法方面:将上述特征作为识别模型输入参数,将矾花状态细分为密实、中片、大片、不均和稀疏 5 种类型,采用 SVM、BP 神经网络和深度学习方法(ResNet 和 AlexNet 模型)和研究团队自主开发的深度 DFM 算法。结果表明,DFM 模型在多次试验中能够达到 95%以上的识别准确率,明显优于传统的机器学习和深度学习方法。

(4) 基于 DFM 模型的矾花图像识别技术已在舟山某水厂应用,采用矾花状态进行絮凝加药量的

反馈调教,应用前后絮凝剂平均投加量由原来的 11 mg/L 降低为 8.5 mg/L,沉淀池平均出水浑浊度由原来的 0.9 NTU 降低为 0.4 NTU。

(5) 本项目使用数据来自单一地区原水水质,后续工作将采集更多不同水质条件下数据,进一步研究矾花图像与水质参数相关性的通用性特征量。

参考文献

- [1] 李峰.絮凝剂、助凝剂联合强化混凝改善水质的研究[D].天津:天津大学, 2007.
LI F. Enhanced coagulation for improving water quality through the combination of coagulants and coagulant aids[D]. Tianjin: Tianjin University, 2007.
- [2] 黄念禹, 武彦林, 李俊, 等. 自来水厂矾花状态自动监测应用研究[J]. 给水排水, 2016, 52(11): 122-125.
HUANG N Y, WU Y M, LI J, et al. Application of alum flower state automatic monitoring in water treatment plants[J]. Water & Wastewater Engineering, 2016, 52(11): 122-125.
- [3] 唐立伟, 王洁, 孟庆彬, 等. 水厂絮凝过程复合控制研究[J]. 科学技术创新, 2019(24): 47-48.
TANG L W, WANG J, MENG Q B, et al. Composite control of coagulation process in water treatment plants[J]. Science and Technology Innovation, 2019(24): 47-48.

- [4] 曲久辉, 汤鸿霄, 栾兆坤, 等. 水厂高效絮凝技术集成系统研究方向[J]. 中国给水排水, 1999(4): 21–22.
- QU J H, TANG H X, LUAN Z K, et al. Integrated system of high-efficiency coagulation technology in water treatment plants [J]. China Water & Wastewater, 1999(4): 21–22.
- [5] MILLER K, CHUANG W L, KIM K, et al. Simultaneous in situ characterization of turbulent flocculation and reactor mixing using image analysis and particle image velocimetry in unison[J]. ACS ES & T Engineering, 2023, 3(2): 295–305.
- [6] 付元, 雷智丰, 崔东峰, 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(4): 83–90.
- FU Y, LEI Z F, CUI D F, et al. Intelligent coagulant dosage system based on alum flower image recognition [J]. Energy Environmental Protection, 2023(4): 83–90.
- [7] 唐登峰. 矜花图像识别智能加药系统在污水厂深度处理中应用[J]. 自动化应用, 2022(10): 24–26, 30.
- TANG D F. Application of alum image recognition intelligent dosing system in advanced treatment of sewage plant [J]. Automation Application, 2022(10): 24–26, 30.
- [8] 王斌, 刘景林, 张婷. 基于直方图的图像分割方法综述[J]. 计算机应用与软件, 2017, 34(11): 21–26.
- WANG B, LIU J L, ZHANG T. Review of image segmentation methods based on histogram [J]. Computer Applications and Software, 2017, 34(11): 21–26.
- [9] 张爱明, 张婷, 张华. 基于 Log 算子的图像边缘检测方法研究[J]. 计算机技术与发展, 2017, 27(6): 125–128.
- ZHANG A M, ZHANG T, ZHANG H. Image edge detection method based on Log operator [J]. Computer Technology and Development, 2017, 27(6): 125–128.
- [10] CHAKRABORTI R K, ATKINSON J F, VAN BENSHOTEN J E. Characterization of alum floc by image analysis [J]. Environmental Science & Technology, 2000, 34 (18): 3969 – 3976.
- [11] ZHANG Q, YANG J, ZHANG W, et al. Deep fuzzy mapping nonparametric model for real-time demand estimation in water distribution systems: A new perspective [J]. Water Research, 2023, 241: 120145. DOI: 10.1016/j.watres.2023.120145.
- [12] CHANG C C, LIN C J. ACM Transactions on Intelligent Systems and Technology [M]. New York: Association for Computing Machinery, 1998.
- [13] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representations by error propagation [M]. Cambridge: MIT Press, 1986.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Las Vegas: IEEE conference on computer vision and pattern recognition, 2016.
- [15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84–90.

(上接第 75 页)

- [7] 刘超然, 张达, 侯宇, 等. 给水厂紫外线消毒设备运行效果及节能降耗研究[J]. 给水排水, 2022, 58(7): 21–26.
- LIU C R, ZHANG D, HOU Y, et al. Study on application effect, energy saving and consumption reduction of ultraviolet disinfection equipment in water plant [J]. Water & Wastewater Engineering, 2022, 58(7): 21–26.
- [8] 敬东明, 鲁显位, 刘建林, 等. 广州北部水厂大型超滤膜项目节能降耗实践[J]. 中国给水排水, 2021, 37(18): 127–133.
- JING D M, LU X W, LIU J L, et al. Energy saving practice of large-scale ultrafiltration project in Beibu waterworks of Guangzhou[J]. China Water & Wastewater, 2021, 37 (18): 127–133.
- [9] 李都望, 余天奇. 水厂的能耗分析与节能措施[J]. 有色冶金设计与研究, 2019, 40(6): 109–110, 118.
- LI D W, YU T Q. Energy consumption analysis and energy saving measures of water plant [J]. Nonferrous Metals Engineering & Research, 2019, 40(6): 109–110, 118.
- [10] 解鹏. 中压变频器在自来水厂中的使用与节能分析[D]. 北京: 北京建筑大学, 2018.
- XIE P. Analysis of application and energy-saving of medium voltage converters in waterworks[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2018.
- [11] 郭杨, 张雪, 蒋福春, 等. 基于碳达峰碳中和目标下供水节能降耗技术研究及管理探讨[J]. 给水排水, 2022, 58(7): 11–15.
- GUO Y, ZHANG X, JIANG F C, et al. Research on energy conservation technology and management in water supply industry based on carbon peaking and carbon neutralization target [J]. Water & Wastewater Engineering, 2022, 58(7): 11–15.
- [12] 刘佩青, 姚青, 沈华, 等. 水厂臭氧发生器的经济运行分析[J]. 净水技术, 2021, 40(4): 85–89.
- LIU P Q, YAO Q, SHEN H, et al. Economic operation analysis of ozone generator in water treatment plant [J]. Water Purification Technology, 2021, 40(4): 85–89.
- [13] 黄慧婷, 邹放, 王敏, 等. 不同消毒方式对供水管段腐蚀的影响[J]. 中国给水排水, 2022, 38(13): 42–45.
- HUANG H T, ZOU F, WANG M, et al. Influence of different disinfection methods on corrosion of water supply pipe[J]. China Water & Wastewater, 2022, 38(13): 42–45.
- [14] 高辉. 基于多个回归方程拟合的数据挖掘方法研究与设计[D]. 长春: 东北师范大学, 2012.
- GAO H. The data mining method and design based on the multiple regression equation fitting[D]. Changchun: Northeast Normal University, 2012.