

文章编号: 2095-2163(2021)03-0134-05

中图分类号: TP183

文献标志码: A

# 基于 LBFSG 神经网络的水质评价方法优化研究

杨晓峰

(山西建筑职业技术学院 计算机工程系, 山西 晋中 030600)

**摘要:** 渔业水质评价智能化对提高渔业生产水平起到关键促进作用。本文针对渔业水质评价设计了基于 LBFSG 优化的神经网络模型, 深入讨论选取特征的有效性并优化了特征选择, 实现了模型压缩, 更适合前端嵌入式环境。实验表明, 本文设计模型能够有效提供水质评价信息。

**关键词:** 水质; 评价; LBFSG; 神经网络

## Research on optimization of water quality evaluation method based on LBFSG neural network

YANG Xiaofeng

(Department of Computer Engineering, Shanxi College of Architectural, Jinzhong Shanxi 030600, China)

**[Abstract]** The intelligent evaluation of water quality plays a key role in increasing the fishery production. In this paper, a neural network model based on LBFSG optimization is designed for fishery water quality evaluation. The effectiveness of features is discussed, and the model is compressed. This mode is more suitable for the front-end embedded environment. Experiments show that the model designed in this paper can effectively provide water quality evaluation information.

**[Key words]** water quality; evaluation; limited-memory Broyden-Fletcher-Goldfarb-Shanno; artificial neural network

## 0 引言

渔业水质评价是对渔业养殖池塘内水体的情况做出的量化判断的一种评价标准。由于渔业养殖池塘内水体的微生物以及浮游动植物的数量需要保持一定的比例, 微生物以及浮游动植物的数量会影响水体颜色, 通常需要通过观测水体颜色来判别水质情况, 准确的水质智能化评价对提高渔业生产水平起到关键促进作用。由于带有主观性的人工观测会造成一定的偏差, 因此有必要将专家渔业养殖水色判断经验转化为可以量化的评价标准, 结合专家经验和计算机视觉分析模型, 在前端摄像机内采集水体图像以及分析水色等级, 实现快速准确的判断水质情况。目前基于可见光图像判断水色的模型特征主要方法有如下 2 种: 采用多种颜色空间分布特征的方法<sup>[1]</sup>和采用颜色矩特征的方法<sup>[2-3]</sup>。目前, 胡朝莹等人<sup>[1]</sup>研究了多种颜色空间分布特征对水色判断的稳定性; 许新华<sup>[2]</sup>利用 RGB 空间的颜色矩特征, 建立了 LM 算法优化的神经网络, 实现水质等级评价。

采用颜色空间分布特征的方法多采用颜色直方图方法计算图像特征, 通过颜色直方图可以统计不同颜色在图象中出现的频率, 但是颜色直方图无法

描述颜色的空间分布位置信息, 并且颜色直方图特征维数较高, 例如: 将 32 位色图像的所有颜色都进行直方图统计将会有  $2^{32}$  维特征, 特征维度非常高。

颜色矩特征<sup>[4]</sup>根据概率统理论利用随机变量的矩表示图像中颜色分布特征。在一幅图像中, 颜色信息具有一定的概率分布, 而颜色信息分布就可以用矩的方法来描述。颜色矩将图像中的颜色通道信息分别进行一阶矩、二阶矩和三阶矩统计, 一幅图像 RGB 信息可以使用 9 个维度的颜色矩信息表示, 相比颜色直方图特征, 特征维度大幅降低, 带来的好处是特征处理的计算量将大幅降低, 所以最近的水质评价研究<sup>[2]</sup>中多使用颜色矩特征。但是文献<sup>[2]</sup>在水质评价研究中并未对颜色矩的各阶特征的有效性做出分析, 并且水质检测准确率较低 (小于 90%)。

针对文献<sup>[2]</sup>不足, 本文对颜色矩各阶特征做了有效性分析, 提高了水质检测的准确率, 并且优化了模型, 使模型更适合在前端嵌入式环境下使用。

## 1 数据准备

本文使用的渔业养殖池塘水体数据集来源于文献<sup>[5]</sup>, 水样图像通过相机拍摄采集, 采集到的图像样本中包含了玻璃容器, 由于玻璃容器的高亮度反

作者简介: 杨晓峰(1979-), 男, 硕士, 讲师, 主要研究方向: 智能计算与计算机视觉。

收稿日期: 2020-06-20

光会影响水体样本图像颜色的分布,因此对图像进行了裁剪,只保留了图像中央 101×101 像素的部分,用于颜色矩特征的提取。数据集中不同类型水质样本数量统计如图 1 所示。从图 1 中可以看出数据集中各种水质样本分布是不均匀的。训练样本和测试样本随机选取,比例为 8 : 2,训练集中的水质样本数量统计如图 2 所示,测试集中的水质样本数量统计如图 3 所示。




图 1 数据集各类样本统计

Fig. 1 Sample statistics in dataset




图 2 训练集各类样本统计

Fig. 2 Sample statistics in training set




图 3 测试集各类样本统计

Fig. 3 Sample statistics in test set

## 2 特征提取

本文选用颜色的一阶矩、二阶矩以及三阶矩分别提取水体样本图像特征,颜色矩特征计算过程可阐释表述如下。

(1)颜色的一阶矩。表示图像整体的亮度,具体数学公式为:

$$E_i = \frac{1}{N} \sum_{j=1}^N p_{ij}, \quad (1)$$

其中,  $E_i$  表示颜色通道  $i$  的一阶矩,  $p_{ij}$  表示像素  $j$  的通道  $i$  的颜色数值。

(2)颜色的二阶矩。表示图像色域的广度,具体数学公式为:

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2}, \quad (2)$$

其中,  $\sigma_i$  表示颜色通道  $i$  的二阶矩;  $p_{ij}$  表示像素  $j$  的通道  $i$  的颜色数值;  $E_i$  表示颜色通道  $i$  的一阶矩,参见公式(1)。

(3)颜色的三阶矩。表示图像颜色分布对称性,具体数学公式为:

$$s_i = \sqrt[3]{\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3}. \quad (3)$$

其中,  $s_i$  表示颜色通道  $i$  的三阶矩;  $p_{ij}$  表示像素  $j$  的通道  $i$  的颜色数值;  $E_i$  表示颜色通道  $i$  的一阶矩,参见公式(1)。

对预处理后的图像提取颜色矩特征,提取的颜色矩特征见表 1。

## 3 模型建立与分析

在神经网络优化算法中,最常见的是随机梯度下降法以及其改进方法。梯度下降法是一阶最优化算法,优化思想是在当前空间点位置的负梯度方向进行搜索,该方向被认为是寻找最优解的最佳方向。梯度下降法简单,适用于凸函数,但是应用于非凸函数时很容易落入局部最优解。

表 1 部分颜色矩特征值

Tab. 1 Part of color moment features

| 类别 | R 通道一阶矩   | G 通道一阶矩  | B 通道一阶矩   | R 通道二阶矩   | G 通道二阶矩  | B 通道二阶矩     | R 通道三阶矩    | G 通道三阶矩    | B 通道三阶矩    |
|----|-----------|----------|-----------|-----------|----------|-------------|------------|------------|------------|
| 2  | 0.469 600 | 0.483 73 | 0.283 220 | 0.022 300 | 0.020 95 | 0.018 850 0 | 0.006 865  | 0.011 163  | 0.010 587  |
| 2  | 0.540 330 | 0.541 11 | 0.296 560 | 0.008 150 | 0.006 09 | 0.009 210 0 | -0.005 780 | -0.003 320 | 0.003 510  |
| 1  | 0.624 190 | 0.568 27 | 0.322 870 | 0.008 110 | 0.004 63 | 0.010 950 0 | -0.006 570 | -0.001 210 | -0.007 100 |
| 4  | 0.409 610 | 0.385 24 | 0.170 010 | 0.013 150 | 0.008 79 | 0.012 360 0 | 0.006 972  | 0.004 403  | -0.007 330 |
| 3  | 0.533 990 | 0.496 65 | 0.200 830 | 0.008 770 | 0.006 70 | 0.011 090 0 | 0.004 768  | -0.001 560 | -0.003 040 |
| 2  | 0.537 263 | 0.538 89 | 0.314 051 | 0.009 690 | 0.007 90 | 0.008 510 0 | 0.003 140  | 0.004 671  | 0.003 790  |
| 1  | 0.556 370 | 0.575 49 | 0.285 100 | 0.007 260 | 0.005 09 | 0.009 856 7 | -0.002 590 | -0.002 770 | 0.006 990  |

针对一阶最优化算法,牛顿法利用了目标函数的一阶导数信息和二阶偏导信息,相对于一阶优化算法有更快的收敛速度,更容易从局部最优解中逃逸。但是在迭代过程中,牛顿法每次迭代都需要计算目标函数的海森矩阵 Hessian 的逆矩阵,计算复杂度很高,并且如果海森矩阵不可逆的时候出现无法计算的情况。

拟牛顿法是对牛顿法的改进方法,是目前非线性问题求解最佳方法之一。拟牛顿法避免了海森矩阵逆矩阵的复杂求解过程,通过正定矩阵近似海森矩阵的逆,简化运算复杂度。LBFGS 优化算法就是一种拟牛顿法。本文采用 LBFGS 算法优化神经网络,保证了网络快速优化并能够最大程度接近全局最优解,这也是本文后续特征有效性分析的理论基础。

本文采用的神经网络模型,输入层为 9 个节点,两个隐藏层分别为 20 个节点和 8 个节点,输出层为 5 个节点。模型训练,最大训练次数设为 3 000,优化器参数设为 *lbfgs*, *random\_state* 设为 1。模型评价采用混淆矩阵,训练结果如图 4 所示,测试结果如图 5 所示。图 4、图 5 中, True label 表示真实的分类信息, Predicted label 表示模型预测的分类信息,矩阵中对角线上元素表示各个分类预测正确数量,其他元素表示预测错误的数量。模型训练准确率为 100%,测试准确率为 95.43%,与文献[2]结果对比见表 2。本文模型相对于文献[2]准确率提高了 7 个百分点,说明方法有效。

表 2 水质分析结果对比

Tab. 2 Comparison of water quality analysis results %

|       | 训练结果  | 测试结果  |
|-------|-------|-------|
| 文献[2] | 95.70 | 88.10 |
| 本文模型  | 100   | 95.43 |



图 6 I 类, II 类, III 类, IV 类, V 类样本图像

Fig. 6 Sample images of class I, class II, class III, class IV and class V

### 4 模型优化

(1) 补充实验 1。特征选取一阶颜色矩和二阶颜色矩两组特征,模型选用 2 层隐藏层,节点数分别是 9 和 5,最大训练次数设为 3 000,优化器参数设为 *lbfgs*, *random\_state* 设为 1。实验结果如图 7、图 8 所示。

(2) 补充实验 2。特征选取一阶颜色矩一组特

征,模型选用 2 层隐藏层,节点数分别是 9 和 3,最大训练次数设为 3 000,优化器参数设为 *lbfgs*, *random\_state* 设为 1。实验结果如图 9、图 10 所示。

(3) 补充实验 3。特征选取二阶颜色矩一组特征,模型选用 2 层隐藏层,节点数分别是 8 和 4,最大训练次数设为 3 000,优化器参数设为 *lbfgs*, *random\_state* 设为 1。实验结果如图 11、图 12 所示。




图 4 训练结果(混淆矩阵)

Fig. 4 Confusion matrix of training results

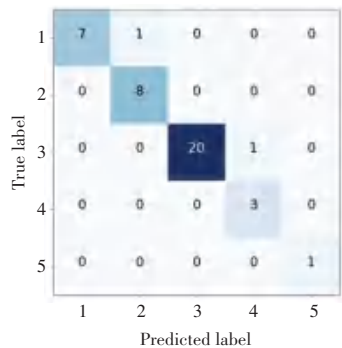


图 5 测试结果(混淆矩阵)

Fig. 5 Confusion matrix of test results

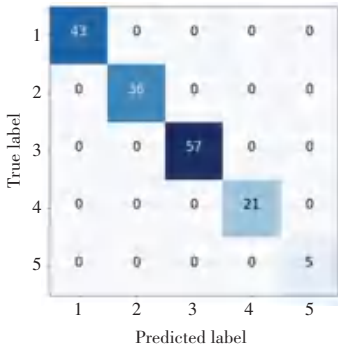


图 7 补充实验 1 训练结果(混淆矩阵)

Fig. 7 Confusion matrix of training results of supplementary experiment 1

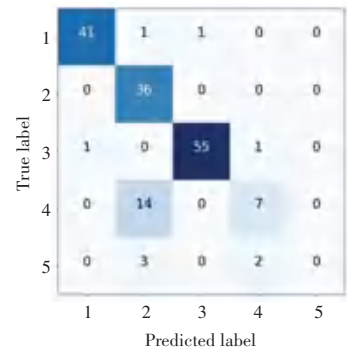


图 11 补充实验 3 训练结果(混淆矩阵)

Fig. 11 Confusion matrix of training results of supplementary experiment 3

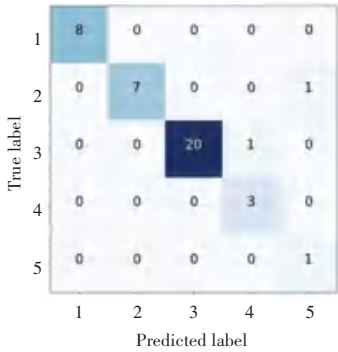


图 8 补充实验 1 测试结果(混淆矩阵)

Fig. 8 Confusion matrix of test results of supplementary experiment 1

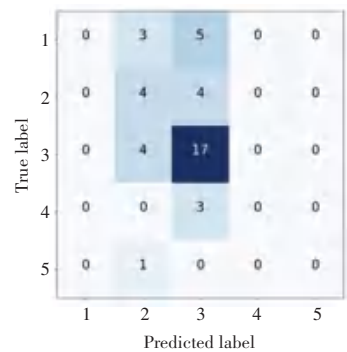


图 12 补充实验 3 测试结果(混淆矩阵)

Fig. 12 Confusion matrix of test results of supplementary experiment 3




图 9 补充实验 2 训练结果(混淆矩阵)

Fig. 9 Confusion matrix of training results of supplementary experiment 2




图 10 补充实验 2 测试结果(混淆矩阵)

Fig. 10 Confusion matrix of test results of supplementary experiment 2

补充实验 1 训练准确率为 100%, 测试准确率为 95.43%, 与本文实验结果相同, 充分证明了上一节的实验分析结论。因此本文方法可以优化, 减少特征数量, 压缩模型规模, 提高模型运行效率。由于压缩后的模型与原始模型准确率相同, 所以相对于原模型, 则更符合边缘计算的要求, 更适合在嵌入式环境下运行。补充实验 2 的测试准确率为 87.81%, 补充实验 3 的测试准确率为 51.22%, 详见表 3, 结果说明在水质评价中一阶颜色矩特征提供了主要信息, 也就是水样的明暗程度对水质评价有至关重要的作用; 二阶颜色矩特征提供相对次要的信息, 颜色的分布范围信息对水质评价也有一定帮助; 三阶颜色矩特征贡献度几乎为零, 颜色分布的对称性对水质评价不起作用。因此, 一阶颜色矩特征和二阶颜色矩特征可以提供水质评价的所有信息。

表 3 特征选择结果

| Tab. 3 Comparison of feature selection |       |       | % |
|--|-------|-------|---|
| 特征选择                                   | 训练准确率 | 测试准确率 |   |
| 一阶矩+二阶矩+三阶矩                            | 100   | 95.43 |   |
| 一阶矩+二阶矩                                | 100   | 95.43 |   |
| 一阶矩                                    | 85.80 | 87.81 |   |
| 二阶矩                                    | 46.30 | 51.22 |   |