

DOI:10.16136/j.joel.2022.10.0418

应用于水下生物识别的联合范数主成分分析算法

张浣星¹, 王肖锋^{1,2}, 武 刚^{2*}

(1. 天津市先进机电系统设计与智能控制重点实验室, 天津理工大学, 天津 300384; 2. 机电工程国家级实验教学示范中心, 天津理工大学, 天津 300384)

摘要:针对 F 范数对离群数据较为敏感, 而 L1 范数能降低离群数据的影响, 但无法有效控制重构误差的问题, 本文将 L1 范数与 F 范数同时作为目标函数的距离度量方式, 提出了二维主成分分析 (two-dimensional principle component analysis, 2DPCA) 联合算法 2DPCA-F-L1, 并给出了其非贪婪求解方法。该算法确保了对图像的分类能力, 同时也降低了图像重构时的平均重构误差。本文将提出的 2DPCA-F-L1 算法在应用于水下生物图像识别时, 可以抑制水下光学影像存在的噪声干扰。实验证明, 该算法能够精确地识别水下生物的种类, 并且在图像重构时相较于其他主成分分析 (principle component analysis, PCA) 算法具有更优的鲁棒性。

关键词:主成分分析 (PCA); 生物识别; 图像识别; 鲁棒性; 联合范数

中图分类号: TP312 **文献标识码:** A **文章编号:** 1005-0086(2022)10-1067-08

Principal component analysis algorithm with joint norm for underwater biometrics recognition

ZHANG Huanxing¹, WANG Xiaofeng^{1,2}, WU Gang^{2*}

(1. Tianjin Key Laboratory for Advanced Mechatronic System Design and Intelligent Control, School of Mechanical Engineering, Tianjin University of Technology, Tianjin 300384, China; 2. National Demonstration Center for Experimental Mechanical and Electrical Engineering Education, Tianjin University of Technology, Tianjin 300384, China)

Abstract: F-norm is sensitive to outlier data, while L1-norm can significantly reduce the sensitivity and cannot effectively control reconstruction errors. To tackle the problem, we take both F-norm and L1-norm as the distance metric of the objective function, and propose a joint-norm two-dimensional principal component analysis (2DPCA) algorithm called 2DPCA-F-L1, and give its non-greedy solution. This algorithm not only ensure the ability of image classification, but also decrease the average reconstruction error in image reconstruction. When applied to underwater biometric image recognition, the proposed 2DPCA-F-L1 suppresses the noise interference in underwater optical images. Experiments show that the 2DPCA-F-L1 algorithm can accurately recognize the species of underwater creatures, and has better robustness than other principal component analysis (PCA) algorithms in image reconstruction experiments.

Key words: principal component analysis (PCA); biometric recognition; image recognition; robustness; joint norm

1 引 言

海洋资源的开发离不开对水下生物的检测和识别。在进行水下探测时, 一般通过声信号和视

觉信号来采集信息。由于视觉信号包含着丰富的图像信息, 且不会出现雷达和超声波相互干扰的现象, 因此随着水下光学图像传感器和水下光学技术的发展, 水下光学生物图像识别已成为海洋

* E-mail: mlyh389@163.com

收稿日期: 2022-06-01 修订日期: 2022-07-02

基金项目: 国家重点研发计划 (2018AA0103004) 和天津市科技计划重大专项 (20YFZCGX00550) 资助项目

工程和图像处理领域的研究热点^[1]。如何解决水下生物图像处理遇到的问题,进而获得鲁棒性更强的算法,则有着十分重要的研究价值。

受到浮游生物、水流波动、深水中光线衰减等影响,水下设备采集到的光学影像常呈现出低对比度、模糊多噪声的特点^[2]。因此在将深度学习应用于水下生物图像识别时,识别算法应该具有较强的鲁棒性。基于此目标,LI等^[4]针对 Life-CLEF 数据集中部分鱼类目标提出了一种轻量型 R-CNN 算法,获得了较高的识别准确率。顾郑平等^[5]在卷积神经网络的基础上提出了迁移学习、支持向量机相融合的方法并应用于鱼类识别研究。刘萍等^[6]提出一种改进的 YOLOv3 网络识别算法并将其应用于海洋生物识别。在处理水下图像数据时,使用神经网络算法能达到较高的识别准确率,但与其他算法相比需要的数据训练样本更多,因此并不适用于处理数据量小的生物样本。另外,许多特征提取算法也被应用至水下图像处理中。HOU等^[7]提出了一种基于水下物体颜色和形状的特征检测方法。OLMOS等^[8]提出了一种检测海底影像中的是否存在物体的系统,通过提取目标轮廓特征,使用贝叶斯分类器检测图像是否存在人造物体。如何从图像中寻找最能有效表征原始数据的低维特征一直是模式识别领域的基本问题,其中代表性的方法有主成分分析(principal component analysis, PCA)^[9]、线性判别分析^[10]、独立分量分析^[11]等。

PCA 是一种常见的特征提取与数据降维方法,被广泛地应用在人脸识别、遥感影像降维、股票走势预测、医学图像识别、故障缺陷检测等领域中。李嘉嶝等^[12]提出了一种应用于低分辨率人脸识别的分块 PCA 算法。张亮^[13]使用 PCA 对遥感影像数据进行降维,实现了对高光谱影像的去噪预处理。徐国祥等^[14]构建了 PCA-GA-SVM 模型,并将其应用于沪深 300 和大盘股每日走势的预测。张卫国等^[15]将 PCA 方法应用于肝脏 B 超图像识别,进行特征级的数据融合并获得了较好的识别效果。WANG等^[16]将 PCA 应用至焊缝缺陷检测。在应用于水下图像处理时,PCA 可以去除浮游生物造成的噪声干扰^[17]。目前针对水下生物识别的方法有限,如何使用 PCA 算法解决水下图像识别领域的问题是值得探索研究的。

PCA 通过寻找样本的最优投影方向来提取出表征原始数据的低维特征。传统的一维 PCA 在处理图像数据时需要将二维图像矩阵转换为一维向量,破坏了图像的空间结构导致空间信息无法被充分利用。针对此问题,YANG等^[18]提出了二

维主成分分析(two dimensional PCA, 2DPCA)。2DPCA 算法直接对原图像样本的二维矩阵进行协方差矩阵的构造,避免了矩阵矢量化带来的巨大计算量。2DPCA 以 F 范数平方为距离度量方式,对噪声的扰动较为敏感,鲁棒性较差。而 L1 范数被认为是基于投影距离最大进行鲁棒降维的最有效手段^[19]。KWAK^[20]和 NIE等^[21]提出了 PCA-L1 算法,并给出了求解子空间最大化向量 1 范数投影矩阵的贪婪和非贪婪求解法。LI等^[22]和 WANG等^[23]将 L1 范数延伸到二维图像领域,分别提出了 2DPCA-L1 的贪婪求解和非贪婪求解法。使用 L1 范数度量虽具有较强的鲁棒性,却无法同时满足图像重构误差最小的目标。为此,GAO等^[24]提出了一种使用 F 范数作为距离度量方式的 Angle2DPCA 算法,以重构误差与投影距离的比值最小化作为目标函数,综合考虑了两者的影响。WANG等^[25]提出了使用向量 2 范数作为距离度量的 Cos-2DPCA 算法,以最小化广义余弦的比值作为目标函数。考虑到向量 1 范数和向量 2 范数均为 L_p 范数的特例,WANG^[26]提出了基于 L_p 范数度量方式的 G2DPCA 算法,以 L_p 范数为度量方式讨论不同参数下的算法性能。

针对 L1 范数能抑制离群数据的影响,但 L1 范数作为度量方式时,令投影距离最大时却无法保证重构误差最小;而 F 范数能保证重构误差最小,但对离群数据更敏感的问题,本文将 L1 范数与 F 范数同时作为距离度量,提出了联合算法 2DPCA-F-L1。该算法具有较强的抗噪声能力同时降低算法重构误差。实验证明,相较于单一使用 L1 范数作为度量方式的 2DPCA-L1 算法,所提出的 2DPCA-F-L1 算法平均重构误差值更低。在水下图像分类识别实验中也表现出了良好的分类能力。

2 相关算法

数据的分散程度可以通过方差来表示。为了方便计算投影方差,本文将所有训练样本零均值化。

假设训练集有 N 个满足 $1/N \sum_{i=1}^N \mathbf{X}_i = 0$ 零均值化的训练图像样本 $\mathbf{X}_1, \dots, \mathbf{X}_N$, 其中 $\mathbf{X}_i \in \mathcal{R}^{m \times n}$, $i = 1, 2, \dots, N$, m 和 n 分别是图像的高度和宽度。 $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k] \in \mathcal{R}^{m \times k}$ 表示由前 k 个特征向量构成的投影矩阵。因此,目标函数的意义可以被描述为:寻找一个特征矩阵 $\mathbf{W}$,使得所有图像数据投影到 $\mathbf{W}$ 上,在规定的距离度量方式下,投影距离的方差最大。

2.1 基于平方 F 范数度量的 2DPCA 算法

在平方 F 范数的度量下,2DPCA 的目标函数为:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \|\mathbf{X}_i \mathbf{W}\|_F^2, \quad (1)$$

$\|\cdot\|_F$ 代表矩阵的 Frobenius 范数的平方。

因为重构误差与投影距离之间满足:

$$\sum_{i=1}^N \|\mathbf{E}_i\|_F^2 + \sum_{i=1}^N \|\mathbf{X}_i \mathbf{W}\|_F^2 = \sum_{i=1}^N \|\mathbf{X}_i\|_F^2, \quad (2)$$

式中, $\mathbf{E}_i = \mathbf{X}_i - \mathbf{X}_i \mathbf{W} \mathbf{W}^T$ 表示第 i 个样本的重构误差, 因为等式(2)的右式为定值, 式(1)的目标函数也可以表示为令样本的重构误差之和最小, 即:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \|\mathbf{E}_i\|_F^2. \quad (3)$$

根据文献[18], 式(3)可以通过求解协方差矩阵 $\sum_{i=1}^N \mathbf{X}_i^T \mathbf{X}_i$ 的前 k 个最大特征值所对应的单位正交特征向量得到 $\mathbf{W}$ 。求解出的特征矩阵满足目标函数式(1)。

2.2 基于 L1 范数度量的贪婪迭代 2DPCA-L1 算法

在 L1 范数的度量下, 2DPCA-L1 的目标函数为:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \|\mathbf{X}_i \mathbf{W}\|_{L1}, \quad (4)$$

式中, $\|\cdot\|_{L1}$ 代表矩阵的 L1 范数。

由于无法像 2DPCA 一样直接求得满足目标函数式(4)的特征矩阵 $\mathbf{W}$, 2DPCA-L1 采用贪婪迭代的方法求解, 根据文献[22]提出的方法, $\mathbf{W}$ 的第 $t+1$ 次迭代式为:

$$\mathbf{W}_{t+1} = \frac{\sum_{i=1}^N \sum_{j=1}^m p_{ij}(t) \mathbf{X}_{ij}^T}{\left\| \sum_{i=1}^N \sum_{j=1}^m p_{ij}(t) \mathbf{X}_{ij}^T \right\|_2}, \quad (5)$$

式中:

$$p_{ij}(t) = \begin{cases} 1, & \text{if } |\mathbf{X}_{ij} \mathbf{W}_t| > 0 \\ -1, & \text{if } |\mathbf{X}_{ij} \mathbf{W}_t| \leq 0 \end{cases} \quad (6)$$

在 L1 范数的度量下, 目标函数不能满足重构误差最小的优化目标, 即:

$$\sum_{i=1}^N \|\mathbf{E}_i\|_{L1} + \sum_{i=1}^N \|\mathbf{X}_i \mathbf{W}\|_{L1} \neq \sum_{i=1}^N \|\mathbf{X}_i\|_{L1}. \quad (7)$$

L1 范数能抑制离群数据的影响, 但在满足式(4)投影方差最大的情况下, 根据式(7), 无法保证其平均重构误差最小。因此, 与基于平方 F 范数的 2DPCA 相比, 基于 L1 范数的方法虽具有一定的抑制噪声能力, 但平均重构误差并没有得到有效控制。

2.3 基于 F 范数的非贪婪迭代 Angle2DPCA 算法

2DPCA-L1 算法的目标函数不能同时满足投影方差最大和平均重构误差最小, 为了解决此问题,

Angle2DPCA 采用使平均重构误差和投影方差的比值最小作为目标函数。通过最小化重构误差和与投影距离的比率获得最优投影矩阵, Angle2DPCA 的目标函数为:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{X}_i \mathbf{W}\|_F}, \quad (8)$$

式中, $\|\cdot\|_F$ 代表矩阵的 Frobenius 范数。

根据文献[24]的方法, 令带系数协方差矩阵 $\mathbf{G}_W = \mathbf{X}_i^T \mathbf{X}_i d_i$, 投影后的矩阵 $\mathbf{H} = \mathbf{G}_W \mathbf{W}$, 其中:

$$d_i = \frac{1}{\|\mathbf{X}_i \mathbf{W}\|_F \|\mathbf{X}_i - \mathbf{X}_i \mathbf{W} \mathbf{W}^T\|_F}, \quad (9)$$

将 $\mathbf{H}$ 进行奇异值分解(singular value decomposition, SVD), 得到 $\mathbf{H} = \mathbf{A} \sum \mathbf{B}^T$, $\sum \in \mathbb{R}^{k \times k}$ 是对角元素为特征值的 k 维对角矩阵。

则 $\mathbf{W} = \mathbf{A} \mathbf{B}^T$ 即为满足目标函数(8)的解。

由于权重系数 d_i 和特征矩阵 $\mathbf{W}$ 都是变量, 因此 Angle2DPCA 采用非贪婪迭代方式求解。通过先固定权重系数 d_i 求解 $\mathbf{W}$, 再通过求解后的 $\mathbf{W}$ 更新 d_i , 当满足算法预设的收敛条件时, 停止迭代并输出特征矩阵 $\mathbf{W}$ 。

2DPCA 使用 F 范数的平方值作为距离度量的方式, 对噪声、离群数据的扰动较为敏感, 鲁棒性较差。基于 L1 范数的算法虽具有一定的抑制噪声能力, 但是平均重构误差并无法得到有效控制。Angle2DPCA 的目标函数减弱了远距离离群点的影响, 在优化投影距离最大的基础上兼顾了限制平均重构误差。但该算法本身还是使用单一的 F 范数为度量方式, 算法本身具有局限性。

3 2DPCA-F-L1 的提出与求解

L1 范数是基于投影距离最大进行鲁棒降维的最有效手段, 相较于其他范数的度量方式, L1 范数有着更强的抑制离群数据的能力。根据式(7), 使用 L1 范数作为度量方式时在保证投影距离最大的情况下无法保证平均重构误差最小。而 F 范数度量能够控制平均重构误差, 但对离群数据较敏感。为了使算法在拥有强抗噪能力的同时兼顾降低平均重构误差的能力, 本文将 L1 范数与 F 范数同时作为距离的度量方式, 借鉴了 Angle2DPCA 的求解方式, 提出了一种联合 F 范数与 L1 范数的新目标函数:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{X}_i \mathbf{W}\|_{L1}}, \quad (10)$$

上式可以进行如下变换:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{X}_i \mathbf{W}\|_{L1}} = \arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \frac{\|\mathbf{E}_i\|_F^2}{\|\mathbf{X}_i \mathbf{W}\|_{L1} \|\mathbf{E}_i\|_F} =$$

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^N \frac{\sum_{i=1}^N \|\mathbf{X}_i\|_F^2 - \sum_{i=1}^N \|\mathbf{X}_i \mathbf{W}\|_F^2}{\|\mathbf{X}_i \mathbf{W}\|_{L1} \|\mathbf{X}_i - \mathbf{X}_i \mathbf{W} \mathbf{W}^T\|_F} =$$

$$\sum_{i=1}^N (tr(\mathbf{X}_i^T \mathbf{X}_i d_i) - tr(\mathbf{W}^T \mathbf{X}_i^T \mathbf{X}_i d_i \mathbf{W})) =$$

$$tr(\mathbf{G}_W) - tr(\mathbf{W}^T \mathbf{G}_W \mathbf{W}), \quad (11)$$

式中, tr 为矩阵的迹, $\mathbf{G}_W$ 为带系数的协方差矩阵, d_i 为权重系数。

$$\mathbf{G}_W = \mathbf{X}_i^T \mathbf{X}_i d_i, \quad (12)$$

$$d_i = \frac{1}{\|\mathbf{X}_i \mathbf{W}\|_F \|\mathbf{X}_i - \mathbf{X}_i \mathbf{W} \mathbf{W}^T\|_{L1}}. \quad (13)$$

因为式(11)中包含未知变量 $\mathbf{W}$ 和 d_i , 且 d_i 的值与 $\mathbf{W}$ 相关。因此本文通过分别求解 $\mathbf{W}$ 和 d_i 来进行迭代更新。

先固定 $d_{i(t)}$ 来迭代更新 $\mathbf{W}$, 其中 t 是迭代次数。再固定 d_i 迭代后的值来更新 $\mathbf{W}$ 。

首先, 固定 $d_{i(t)}$ 更新 $\mathbf{W}$ 。因为 $tr(\mathbf{G}_W)$ 是定值, 因此目标函数等价于:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} tr(\mathbf{W}^T \mathbf{G}_W \mathbf{W}). \quad (14)$$

令 $\mathbf{H} = \mathbf{G}_W \mathbf{W}$, 则目标函数更新为:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} tr(\mathbf{W}^T \mathbf{H}). \quad (15)$$

针对 $\mathbf{W}$ 的求解, 有如下定理成立:

对于二维矩阵 $\mathbf{H} \in \mathcal{R}^{m \times k}$, 将矩阵 $\mathbf{H}$ 进行 SVD 分解, 得到 $\mathbf{H} = \mathbf{A} \sum \mathbf{B}^T$, 其中 $\mathbf{A}^T \mathbf{A} = \mathbf{B}^T \mathbf{B} = \mathbf{I}_{k \times k}$, $\sum \in \mathcal{R}^{k \times k}$ 的对角元素即为特征值, k 为主成分个数。则 $\mathbf{W} = \mathbf{A} \mathbf{B}^T$ 即为目标函数式(15)的解。此解满足目标函数式(10)。

证明:

$$\text{将 } \mathbf{H} \text{ 进行 SVD 分解, 得到 } \mathbf{H} = \mathbf{A} \sum \mathbf{B}^T,$$

$$tr(\mathbf{W}^T \mathbf{H}) = tr(\mathbf{W}^T \mathbf{A} \sum \mathbf{B}^T) = tr(\mathbf{B}^T \mathbf{W}^T \mathbf{A} \sum), \quad (16)$$

此时目标函数可转换为:

$$\arg \max_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} tr(\mathbf{B}^T \mathbf{W}^T \mathbf{A} \sum). \quad (17)$$

因为 $\sum \in \mathcal{R}^{k \times k}$ 是一个非奇异对角矩阵, 当且仅当 $\mathbf{B}^T \mathbf{W}^T \mathbf{A} = \mathbf{I}_{n \times k}$, 即 $\mathbf{W} = \mathbf{A} \mathbf{B}^T$ 时, 目标函数成立。至此得到一个新的基于第 t 次迭代的 $d_{i(t)}$ 值的新特征矩阵。

记第 t 次迭代的特征矩阵为 $\mathbf{W}_t$, 权重系数为 $d_{i(t)}$ 。当得到第 t 次迭代的投影矩阵 $\mathbf{W}_t$ 后, 更新 d_i

$$d_{i(t+1)} = \frac{1}{\|\mathbf{X}_i \mathbf{W}_t\|_{L1} \|\mathbf{X}_i - \mathbf{X}_i \mathbf{W}_t \mathbf{W}_t^T\|_F}, \quad (18)$$

2DPCA-F-L1 算法将投影方差和重构误差之和集成为目标函数, 使用 F 范数来约束重构误差值, 使

用 L1 范数来最大化图像样本的投影方差。利用 SVD 分解的方式对目标函数进行贪婪迭代求解, 进而实现提升算法鲁棒性的目的。

表 1 2DPCA-F-L1 算法伪代码

Tab. 1 Algorithm procedure of 2DPCA-F-L1

Input: $\mathbf{X}_1, \dots, \mathbf{X}_N$ Output: $\mathbf{W}$
Initialize: $\mathbf{W} \in \mathcal{R}^{n \times k}, \mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}; t = 1$
for $t = 1, 2, \dots$
do
Calculate d by (13) for each image matrix $\mathbf{X}_i$;
$\mathbf{G}_W$ by (7);
matrix $\mathbf{H} = \mathbf{G}_W \mathbf{W}$;
SVD of matrix $\mathbf{H} = \mathbf{A} \sum \mathbf{B}^T$;
Feature matrix $\mathbf{W} = \mathbf{A} \mathbf{B}^T$;
Update t to $t+1$;
while converge
Output $\mathbf{W}$;

4 实验与分析

4.1 数据集

为了验证本文提出的算法应用在水下图像处理的有效性以及能否发挥基于联合范数进行特征提取的优势, 本文对无噪声数据集进行了加噪预处理。本文的数据测试集样本来自于日本海洋地球科学技术开发机构(JAMSTEC)采集到的水下影像数据集, 该机构通过使用 SHINKAI6500, HYPER-DOLPHIN 等载人和无人研究潜水器探测深海环境获得了 J-EDI 水下影像数据集, 其中包括上百种水下生物视频信息。本文选择了 9 种不同水下生物的视频影像进行随机图像捕获。针对每种生物, 分别在随机捕获的图像中选取 100 张拥有纯净背景的水下生物图像, 并将图像大小调整为长 152 像素、宽 108 像素, 由此构成了一个含有 900 张无噪声图像的基础水下生物图像数据集。

水下采集影像会受到水下浮游生物和水流波动的干扰。因此采集的图像除模糊外, 还经常存在不可避免的噪声块。由于自然采集样本中的噪声无法量化而导致实验无法控制变量, 本文通过在无噪声数据集中随机抽取样本数为 20%、40%、60% 的图像样本, 人为加入位置随机、像素长宽占比分别为 20%、40%、60% 的黑白杂点噪声块, 来构造不同比

例噪声条件下的数据样本。为了验证算法的鲁棒性,本文使用上文提到的 2DPCA、2DPCA-L1、Angle-2DPCA 与新算法进行了重构误差实验与分类率实验,对比分析了不同算法的性能。




图 1 不同比例噪声的数据集图片样本
Fig. 1 Image samples with different scale of noise






图 2 2DPCA-F-L1 算法在 60% 比例噪声条件下的重构图片
Fig. 2 Reconstructed image with 60% scale noise by 2DPCA-F






图3 不同比例噪声条件下的平均重构误差

Fig. 3 Average reconstruction error under different scale of noise

4.2 鲁棒性实验

平均重构误差常被作为判断算法鲁棒性的判定标准。在实验条件相同的情况下,平均重构误差越小,则说明算法的鲁棒性越强。本文将上述数据集进行零均值化后,通过使用不同噪声比例的数据集样本求解不同算法的平均重构误差值,来测试算法在不同噪声条件下的性能,借此进行不同算法鲁棒性的对比分析。平均重构误差被定义为:

$$\bar{E} = 1/N \sum_{i=1}^N \|E_i\|_F. \quad (19)$$

算法的重构能力也可以通过观察算法重构图像的清晰程度来更直观地判断。从图2中可以看出,随着主成分个数的增加,提取的低维特征包含的信息增多,重构图像越清晰。因此在主成分数相同的情况下,平均重构误差值越低,重构图像越清晰,代表算法的鲁棒性越强。

本文使用含有0%、20%、40%、60%噪声比例的测试集进行算法的重构误差实验。在噪声条件相同的情况下,每种算法求取1-50阶主成分数中每一阶的平均重构误差进行横向对比,得到算法随主成分数变化的趋势。通过在相同噪声条件下对比不同算法的平均重构误差,可以测试出不同算法的鲁棒性。从图3中可以看出,随着主成分个数的增加,低维特征包含的信息越多,平均重构误差逐阶减小,在主成分数达到15之后变化放缓并趋于平稳。

4种算法在0%噪声的纯净测试集中差异不明显,但随着噪声比例的增加,2DPCA的平均重构误差明显大于其他三种算法的平均重构误差,可以看出2DPCA受噪声影响最大,验证了平方F范数对背

景、遮挡的微小变化高度敏感,鲁棒性较差。与2DPCA相比,2DPCA-L1采用了具有鲁棒特性的L1范数来抵抗噪声的干扰。2DPCA-L1在噪声比例小于等于40%的时候性能较为稳定,但在噪声比例达到60%时的平均重构误差高于Angle2DPCA和2DPCA-F-L1,鲁棒性下降,验证了L1范数无法有效控制平均重构误差。Angle2DPCA与2DPCA-F-L1表现出了较好的鲁棒性,实验数据显示2DPCA-F-L1的平均重构误差更小,可以说明2DPCA-F-L1算法在大噪声情况下比其他算法具有更强的鲁棒性。

在水下识别领域中,采集器收集到的图像分辨率低、包含信息少,背景简单但容易受到光斑、水波、浮游生物的干扰,因此测试应用于水下图像识别的算法是否具有抗噪声能力是十分必要的。

4.3 分类率实验

将机器学习和模式识别算法合理地应用于水下生物识别,关系着海洋工程和生物研究领域的发展。为了验证PCA算法是否适用于水下生物图像分类识别,本文使用不同的PCA算法对测试集进行特征提取,采用K最邻近分类法(K-nearest neighbor, KNN)进行分类率测试实验。KNN分类法指在一个含未知样本的空间里,可以根据离未知样本最邻近的K个样本的数据类型来确定样本的类型。实验选取固定的主成分数 $k=50$ 进行特征提取;选取相邻样本数 $K=1$ 进行分类。所有实验样本均零均值化处理。

在每种水下生物的100张图像中随机抽取20张作为训练样本,其余80张作为测试样本。同样地,

为了得到拥有不同噪声比例的数据集,本文在训练样本中分别随机抽取样本数为 20%、40%、60% 的图像样本加入位置随机、像素长宽占比分别为 20%、40%、60% 的黑白杂点噪声块,构成了分别含有 0%、20%、40%、60% 的训练数据集。为了避免噪声块位置的随机性对实验结果产生影响,本文随机生成 5 组噪声比例相同,但噪声位置不同的训练样本。重复实验 5 次取其平均值作为不同噪声条件下的分类率。分类率实验能够验证 PCA 算法提取特征的能力。当分类率较高时,代表算法提取的特征向量更接近真实特征向量。在应用于实际领域时,分类率高也代表算法的识别准确率更高,应用性能更好。

实验固定了特征提取的主成分数,因此可以得出对每种算法在噪声条件下的分类能力。通过表 2 可以看出,每种 PCA 算法的分类率都达到了 90 左右,可以见得 PCA 算法在水下图像识别中达到了高分类率,验证了 PCA 算法在水下图像分类的有效性。除此之外,从度量方式上看,主成分数与噪声比例相同时,不同算法之间的差异比较小。随着噪声比例的增加,每种算法的分类率有不同程度的下降。但在大噪声下,以 L1 范数为度量方式的算法相对于其他算法有更高的分类率,验证了基于 L1 范数度量的强抗噪声能力。如何更好地将 L1 范数与其他范数相联合,进而构成鲁棒性更强、平均重构误差更低的算法,则值得不断地探索研究。

在生态研究领域,海水生物种类繁多、难以观测,检测种群多样性、开展大规模水下生物识别已成为了解海洋生态系统和生物多样性的必要研究内容。由于水下物种外观形态差异极小,在进行分类时极易造成类间或类内的混淆。因此如何提取出不同物种之间细微的特征差异、乃至进行正确的分类,是推动生态领域发展的必要研究内容。

表 2 不同比例噪声条件下的平均分类率

Tab. 2 Average classification rate with different noise scale

Noise	2DPCA	2DPCA-L1	Angle2DPCA	2DPCA-F-L1
0%	95.00	95.00	95.00	95.00
20%	94.69	94.67	94.58	94.61
40%	93.39	93.03	93.00	93.00
60%	89.83	90.06	89.66	89.63

4 结 论

本文讨论了不同 2DPCA 算法的度量方式和求解方法,使用 J-EDI 水下影像的随机捕获图像作为数据集,测试了不同算法应用于水下图像识别时的鲁

棒性。比较了基于 F 范数以及基于 L1 范数不同度量方式的优缺点,L1 范数有较强的抗噪声能力和分类能力,而 F 范数能够在投影方差最大的情况下保证平均重构误差最小。本文将 L1 范数与 F 范数同时作为目标函数的度量方式,提出了一种联合 F 范数和 L1 范数的新算法 2DPCA-F-L1。实验表明,2DPCA-F-L1 算法相较于单一使用 F 范数度量方式和 L1 范数度量方式而言有更强的鲁棒性,在强噪声干扰的情况下依旧可以保整降低平均重构误差值。而分类率依旧逊于基于单一 L1 范数度量的算法。

本文仅仅将 L1 范数和 F 范数进行联合,而目前应用于图像识别领域的度量方式除了 L1 范数和 F 范数之外,还有 S 范数、Lp 范数、核范数等距离度量方式,以及双向降维,分块处理等诸多求解办法。如何将不同的度量方式和求解方法相结合以获得性能更好的算法,将成为未来值得不断探索研究的课题。

参考文献:

[1] LU H, LI Y, ZHANG Y, et al. Underwater optical image processing: a comprehensive review [J]. Mobile Networks & Applications, 2017, 22: 1204-1211.

[2] LI Y, LU H, LI J, et al. Underwater image de-scattering and classification by deep neural network [J]. Computers and Electrical Engineering, 2016, 45(C): 68-77.

[3] JAFFE J S. Underwater optical imaging: the past, the present, and the prospects [J]. IEEE Journal of Oceanic Engineering, 2015, 40(3): 683-700.

[4] LI X, TANG Y, GAO T. Deep but lightweight neural networks for fish detection [C]//OCEANS 2017-Aberdeen, June 19-22, 2017, Aberdeen, UK. New York: IEEE, 2017: 1-5.

[5] GU Z P, ZU M. Fish classification algorithm based on depth learning [J]. Computer Applications and Software, 2018, 35(1): 200-205.

顾郑平, 朱敏. 基于深度学习的鱼类分类算法研究 [J]. 计算机应用与软件. 2018, 35(1): 200-205.

[6] LU P, YANG H B, SONG Y. Improved marine biometrics identification algorithm for YOLOv3 network [J]. Application Research of Computers, 2020, 37(S1): 394-397.

刘萍, 杨鸿波, 宋阳. 改进 YOLOv3 网络的海洋生物识别算法 [J]. 计算机应用研究, 2020, 37(S1): 394-397.

[7] HOU G, LUAN X, SONG D, et al. Underwater man-made object recognition on the basis of color and shape features [J]. Journal of Coastal Research: An International Forum for the Littoral Sciences, 2016, 32(5): 1135-1141.

[8] OLMOS A, EMANUELE T. Detecting man-made objects in

- unconstrained subsea videos[C]//British Machine Vision Conference, September 2-5, 2002, Candiff, UK. Manchester: BMVA, 2002, 50: 1-10.
- [9] JOLLIFFE I T. Principal component analysis[J]. Journal of Marketing Research, 2002, 87(4): 513.
- [10] BELHUMEUR P N, HESPANHA J P, KRIEGMAN D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [11] YANG Z Q, LI Y, HU D W. Independent component analysis: a survey[J]. Acta Automatica Sinica, 2002(5): 762-772.
杨竹青, 李勇, 胡德文. 独立成分分析方法综述[J]. 自动化学报, 2002(5): 762-772.
- [12] LI J D, CHEN Z X, LIU C Y. Low-resolution face recognition based on blocking CS-LBP and weighted PCA algorithm[J]. Journal of Optoelectronics · Laser, 2016, 27(2): 210-216.
李嘉頔, 陈振学, 刘成云. 分块 CS-LBP 和加权 PCA 的低分辨率人脸识别[J]. 光电子 · 激光, 2016, 27(2): 210-216.
- [13] ZHANG L. Study on the hyperspectral remote sensed image classify based on PCA and SVM[J]. Optical Technique, 2008, 34(S1): 184-187.
张亮. 基于 PCA 和 SVM 的高光谱遥感图像分类研究[J]. 光学技术, 2008, 34(S1): 184-187.
- [14] XU G X, YANG Z J. Research for construction and application of PCA-GA-SVM model[J]. The Journal of Quantitative & Technical Economics, 2011, 28(2): 135-147.
徐国祥, 杨振建. PCA-GA-SVM 模型的构建及应用研究——沪深 300 指数预测精度实证分析[J]. 数量经济技术经济研究, 2011, 28(2): 135-147.
- [15] ZHANG W G, WANG G H. Research and implementation of liver B ultrasound clinica images recognition based on pca multi-feature fusion[J]. Computer Applications and Software, 2014, 31(4): 239-243.
张卫国, 王桂花. 基于 PCA 多特征融合的肝脏 B 超临床医学图像识别研究与实现[J]. 计算机应用与软件, 2014, 31(4): 239-243.
- [16] WANG X, ZHANG Y, LIU J, et al. Online detection of weld surface defects based on improved incremental learning approach[J]. 2022, 195: 116407.
- [17] ELAD M, MEMBER S, IEEE, et al. On the role of sparse and redundant representations in image processing[J]. Proceedings of the IEEE, 2010, 98(6): 972-982.
- [18] YANG J, ZHANG D, FRANGI A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [19] WANG W, AGGARWAL V, AERON S. Principal component analysis with tensor train subspace[J]. Pattern Recognition Letters, 2019, 122(MAY): 86-91.
- [20] KWAK N. Principal component analysis based on L1-norm maximization[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2008, 30(9): 1672-1680.
- [21] NIE F, HUANG H, DING C, et al. Robust principal component analysis with non-greedy L1-Norm maximization [C]//International Joint Conference on Artificial Intelligence, July 6-22, 2011, Barcelona, Spain. Palo Alto: AAAI, 2011: 1433-1438.
- [22] LI X, PANG Y, YUAN Y. L1-norm-based 2DPCA[J]. IEEE Transactions on Systems, Man, and Cybernetics. Part B (Cybernetics), 2010, 40(4): 1170-1175.
- [23] WANG R, Nie F, YANG X, et al. Robust 2DPCA with non-greedy L1-norm maximization for image analysis[J]. IEEE Transactions on Cybernetics, 2015, 45(5): 1108-1112.
- [24] GAO Q, LAN M, YANG L, et al. Angle 2DPCA: a new formulation for 2DPCA[J]. IEEE Trans Cybern, 2018, 48(5): 1672-1678.
- [25] WANG X, SHI L, LIU J, et al. Cosine 2DPCA with weighted projection maximization[J]. IEEE Transaction on Neural Networks and Learning Systems, 2022: 3159011.
- [26] WANG J. Generalized 2-D principal component analysis by Lp-Norm for image analysis[J]. IEEE Transactions on Cybernetics, 2016, 46(3): 792-803.

作者简介:

武 刚 (1974—), 男, 研究生, 实验师, 主要从事机器学习领域的研究。