



引用格式:李良福,高小小,孙瑞赟,等. 基于稀疏编码的桥梁路面裂缝分类方法研究[J]. 轻工学报,2018,33(3):66-74.

中图分类号:TP391.4 文献标识码:A

DOI:10.3969/j.issn.2096-1553.2018.03.009

文章编号:2096-1553(2018)03-0066-09

基于稀疏编码的桥梁路面裂缝分类方法研究

Study on bridge floor crack classification method based on sparse coding

李良福,高小小,孙瑞赟,陆铖

LI Liangfu, GAO Xiaoxiao, SUN Ruiyun, LU Cheng

关键词:

桥梁路面裂缝; 分类算法; 深度学习; 白化主成分分析; 尺度不变特征; 稀疏编码

陕西师范大学 计算机科学学院, 陕西 西安 710119

School of Computer Science, Shaanxi Normal University, Xi'an 710119, China

Key words:

bridge floor crack;
classification method;
deep learning;
whitening principal
components analysis;
scale invariant feature
transform; sparse coding

摘要:针对桥梁安全和维护问题,提出了一种基于稀疏编码的桥梁路面裂缝分类方法.该方法从网上随机下载图片数据集作为训练集,减少人工标记的工作量,再用相机采集周围的桥梁路面裂缝图片作为测试集和验证集,针对这些高分辨率图像,采用改进的白化主成分分析进行降维,加速特征学习;针对裂缝图像特点,结合自学习算法,从大量未标识的数据集中提取尺度不变特征,经过改进的稀疏编码表示得到特征字典,并用空间金字塔进行池化;最后用线性支持向量机分类器进行分类.验证结果表明,与其他方法相比,本算法获得的分类准确率更高.

收稿日期:2018-03-26

基金项目:国家自然科学基金项目(61573232,61201434,61401263)

作者简介:李良福(1977—),男,陕西省西安市人,陕西师范大学副教授,博士,主要研究方向为模式识别、计算机视觉.

Abstract: For the bridge safety and maintenance issues, a sparse coding method for the classification of bridge pavement cracks was proposed. Random downloading of image datasets from the Internet as a training set reduced the amount of manual tagging, and then the camera was used to capture the surrounding bridge crack images as test sets and validation sets. An improved whitening principal component analysis was used to reduce dimensions and accelerate feature learning for these high resolution images. A self-learning algorithm was used to extract scale-invariant features from a large number of unlabeled data sets based on the characteristics of crack images, and an improved sparse code representation was used to obtain a feature dictionary, and the space pyramid was used for pooling. Finally, multiclassification was performed using a linear support vector machine classifier. Experimental results showed that compared with other methods, the proposed algorithm could achieve higher classification accuracy.

0 引言

随着经济的飞速发展,桥梁在我国交通运输中的地位越来越重要,但是桥梁裂缝给国家财产和人民群众生命安全埋下了重大隐患.通常,桥梁路面的检修与维护采用人工现场确认检查方式,耗时耗力,而且不安全^[1].近年来,随着模式识别与计算机视觉技术的广泛应用,不但使人类从这些繁重又危险的工作中解放出来,甚至能够解决人类无法完成的问题^[2-3].

目前,国内外对于桥梁路面裂缝分类的研究较少,但是对于分类算法的研究由来已久.在国内,刘海洋等^[4]通过研究标记间的依赖关系,改进了属性空间扩展法,提出了一种基于ReliefF剪枝的多标记分类算法.韩洁等^[5]利用深度置信网络对高分辨率遥感图像进行分类,提高了分类识别率并缩短了分类时间,分类效率有所提高.张号逵等^[6]对深度学习在高光谱图像分类领域的应用进行了研究,发现并总结了现有的图像分类主要方法存在的一些问题.王倩等^[7]提出了一种改进的局部聚合描述符,对图像特征进行描述,最后对目标进行分类,获得了较高的分类准确率.石祥斌等^[8]为了提高深度学习模型的迁移学习能力,通过加强特征描述和识别能力,提出了一种基于受限玻尔兹曼机与卷积神经网络的混合学习模型,该方法充分融合了两种模型的优势,具有较高的分类

准确率.徐佳等^[9]提出了一种基于主动深度学习的极化SAR图像分类方法,该方法致力于减少人工标记样本的成本,具有比较理想的分类准确率.夏梦等^[10]提出了一种新的深度学习模型,将卷积神经网络与条件随机场相结合,不仅具有很好的抑噪能力,还可以防止过平滑现象,保护边缘信息不丢失,使得提取的特征更接近本质,是一种精确有效的分类方法.

国外对于基于深度学习的分类研究成果也十分丰硕.R. F. Berriel等^[11]对高分辨率的遥感图像进行了研究,运用基本的深度学习框架对斑马线进行了分类识别,准确率达到97.11%,且鲁棒性强.A. Afan等^[12]提出了一种基于深度学习自动编码的可自主调试的分类系统,该研究忽略非重要因素,只关注具有典型性的描述或特征,大大提升了分类效率.T. J. O' Shea等^[13]研究了一种基于深度学习的音频信号分类方法,该方法具有良好的鲁棒性和抗干扰能力.S. De等^[14]研究了极化合成孔径雷达(PolSAR)数据中的城市地区分类,提出了一种基于深度学习的新的分类技术,它利用合成目标数据库进行数据增强,使用堆叠自动编码器网络将增强数据集中的信息转换为紧凑辨识,最后用多层感知器网络进行分类,总体准确率达到91.3%.A. Santara等^[15]针对HSI图像中的陆地分类问题,提出了一种基于BASS网络的频带自适应的频谱空间特征学习神经网络

络,用于解决高光谱图像的分类问题,该方法不仅减少了冗余信息,而且减少了所需参数和训练样本. D. Dey 等^[16]在充分研究深度卷积神经网络的基础上,提出了一种新的变压器故障识别定位方法,比现有的故障检测方法检测准确率提高了7%. E. Gundogdu 等^[17]针对视频追踪中的特征表示问题,提出了一种基于深度学习的特征学习与表示方法,使得追踪的准确率提高了25%.

由此看出,深度学习相较于传统的分类方法,具有优良的特征提取和描述能力,非常适合将其运用于桥梁裂缝分类. 鉴于此,本文拟提出一种基于稀疏编码的桥梁路面裂缝分类方法,以期获得更高的分类准确率.

1 基于稀疏编码的桥梁路面裂缝分类方法的构建

深度学习中的样本标记需要的工作量十分庞大,因此本方法借鉴自学习算法和迁移学习

算法,从网上随机下载数据集作为测试集,以获得大量的特征来丰富学习到的特征字典. 同时,用相机采集周围的桥梁路面裂缝图片,这些图像的分辨率都非常高,相应地,冗余也很多,为了消除部分冗余,采用改进的白化主成分分析法进行降维,以便加速特征学习的速度. 鉴于桥梁路面裂缝有不同的方向、粗细、纹理和未知噪声等特征,所以从中选取尺度不变特征,又因为尺度不变特征具有多量性,需要对特征进行显著性描述,过滤掉一些典型性不强的特征,形成特征字典. 然后用这些特征字典对桥梁路面裂缝进行描述,并进行空间金字塔池化,进一步降维. 最后,用线性支持向量机分类器进行分类. 简化的流程图如图1所示,其中特征字典的提取和表示都采用改进的稀疏编码方法.

1.1 数据集处理

1.1.1 数据集的采集 从网上随机下载图片数据集作为训练集,减少人工标记的工作量,再用相机采集周围的桥梁路面裂缝图片作为测试

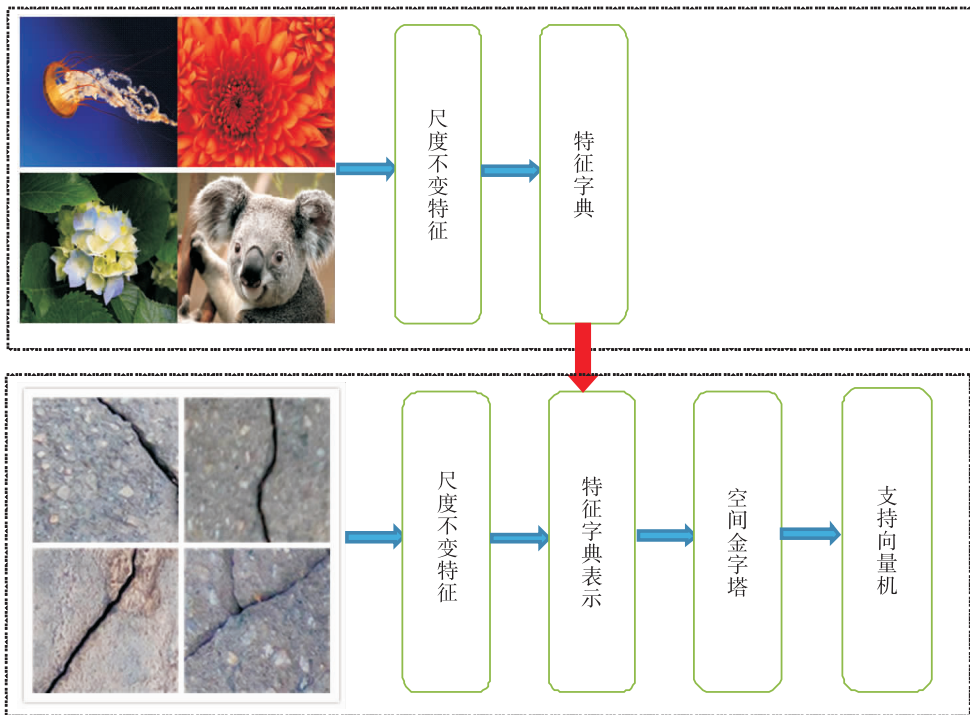


图1 桥梁路面裂缝分类方法简化流程图

Fig. 1 A simplified flow chart of bridge floor crack classification method

集和验证集;特别地,使用相机采集桥梁图像作为测试集时,需要注意相机应尽可能与桥梁路面平行,并且不使用人工光照,拍摄的地点最好不存在阴影或者阴影尽可能少。

1.1.2 标准化测试集和验证集 对图像进行分析,图像的灰度直方如图2所示,每组图片中上图表示路面存在裂缝的桥梁图像的灰度直方图,下图表示背景的灰度直方图.从图2可以看出,无论路面是否存在裂缝,桥梁图像大多服从高斯分布,而且,如果单纯将灰度作为特征,用静态的阈值进行分割,则很难区分裂缝和背景.由于图像大致服从高斯分布是可以进行均值标准化的前提条件,因此,桥梁图像可进行均值标准化,使其均值全部为0,如下式所示:

$$\begin{cases} u = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N x(i,j) \\ x_{\text{norm}} = x - u \end{cases}$$

其中, x 代表桥梁图像, M 和 N 分别表示图像的行数和列数, x_{norm} 是均值标准化最终的结果。

1.1.3 白化主成分分析 主成分分析法是一种可以用来加速无监督特征学习的降维算法^[18].假设现有数据集 $\{x_1, x_2, \dots, x_m\}$,且 $x \in \mathbf{R}^n$,则需要把 x_i 从 n 维降到 k 维,首先定义

$$\mathbf{\Sigma} = \frac{1}{m} \sum_{i=1}^m (x_i)(x_i)^T$$

如果 x 的均值是0,那么 $\mathbf{\Sigma}$ 就是 x 的协方差矩阵.显然, x 经过预处理后,均值为0,那么 $\mathbf{\Sigma}$ 的协方差矩阵应为对角矩阵,这可以作为判断特征向量或者特征值是否计算正确的依据.然后,求取 $\mathbf{\Sigma}$ 的特征向量,并且把所有的特征向量组合成矩阵

$$U = [u_1 \quad u_2 \quad \dots \quad u_n]$$

其中, u_1 表示数据集的主方向,也是 $\mathbf{\Sigma}$ 的主特征向量; u_2 是次方向;以此类推,到一定程度时,剩下的特征向量就全为0,而 $\lambda_1, \lambda_2, \dots, \lambda_n$ 表示对应的特征值.然后,将原数据集投影到相应的特

征方向上,式①表示 x_i 在 u_1 方向上的投影,则 x 在所有特征方向上的投影记为式②:

$$\tilde{x}_i = x_{\text{rot},1}^{(i)} = u_1^T x_i \quad (1)$$

$$\begin{aligned} \tilde{x} &= [x_{\text{rot},1}, x_{\text{rot},2}, \dots, x_{\text{rot},k}, 0, \dots, 0]^T \approx \\ &= [x_{\text{rot},1}, x_{\text{rot},2}, \dots, x_{\text{rot},k}, x_{\text{rot},k+1}, \dots, x_{\text{rot},n}]^T = \\ &\quad x_{\text{rot}} \end{aligned} \quad (2)$$

鉴于 U 是一个正交矩阵,满足 $U^T U = U U^T = I$,其中 I 是单位矩阵,那么由 x_{rot} 重建原始数据集可以记为

$$\hat{x} = U[\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_k, 0, \dots, 0]^T = \sum_{i=1}^k u_i \tilde{x}_i$$

其中, k 的选取尤为重要,其选取标准为

$$\sum_{j=1}^k \lambda_j / \sum_{j=1}^n \lambda_j \geq 0.99$$

至此,主成分分析法已经降低了各个特征彼此之间的相关性,而白化则进一步使所有特征具有相同的方差.白化是在主成分分析的基础上得到的,可以在原来的基础上进一步降低冗余:

$$x_{\text{PCA}_{\text{white},i}} = \frac{x_{\text{rot},i}}{\sqrt{\lambda_i}}$$

1.2 特征提取与特征表示

1.2.1 数据集描述 对训练集和测试集分别进行描述.假设未标记的训练样本是 $\{x_u^{(1)}, \dots, x_u^{(m_u)}\}$,样本数量为 m_u ,标记的测试样本为 $\{(x_l^{(1)}, y^{(1)}), \dots, (x_l^{(m_l)}, y^{(m_l)})\}$, $y \in \{0, 1, 2, 3, 4, 5\}$,样本数量为 m_l .其中, $x_u^i (1 \leq i \leq m_u)$ 表示从网上随机下载的数据集; $x_l^j (1 \leq j \leq m_l)$ 表示从周围桥梁上收集的桥梁图像(桥梁图像可以含有路面裂缝,也可以不含路面裂缝); $y = 0$,表示不存在路面裂缝的桥梁图像,称为背景; $y = 1$,表示横向裂缝; $y = 2$,表示纵向裂缝; $y = 3$,表示左斜裂缝; $y = 4$,表示右斜裂缝; $y = 5$,表示网状裂缝。

1.2.2 改进稀疏编码 由于尺度不变特征的多量性,初始特征集是十分庞大的,而稀疏编码

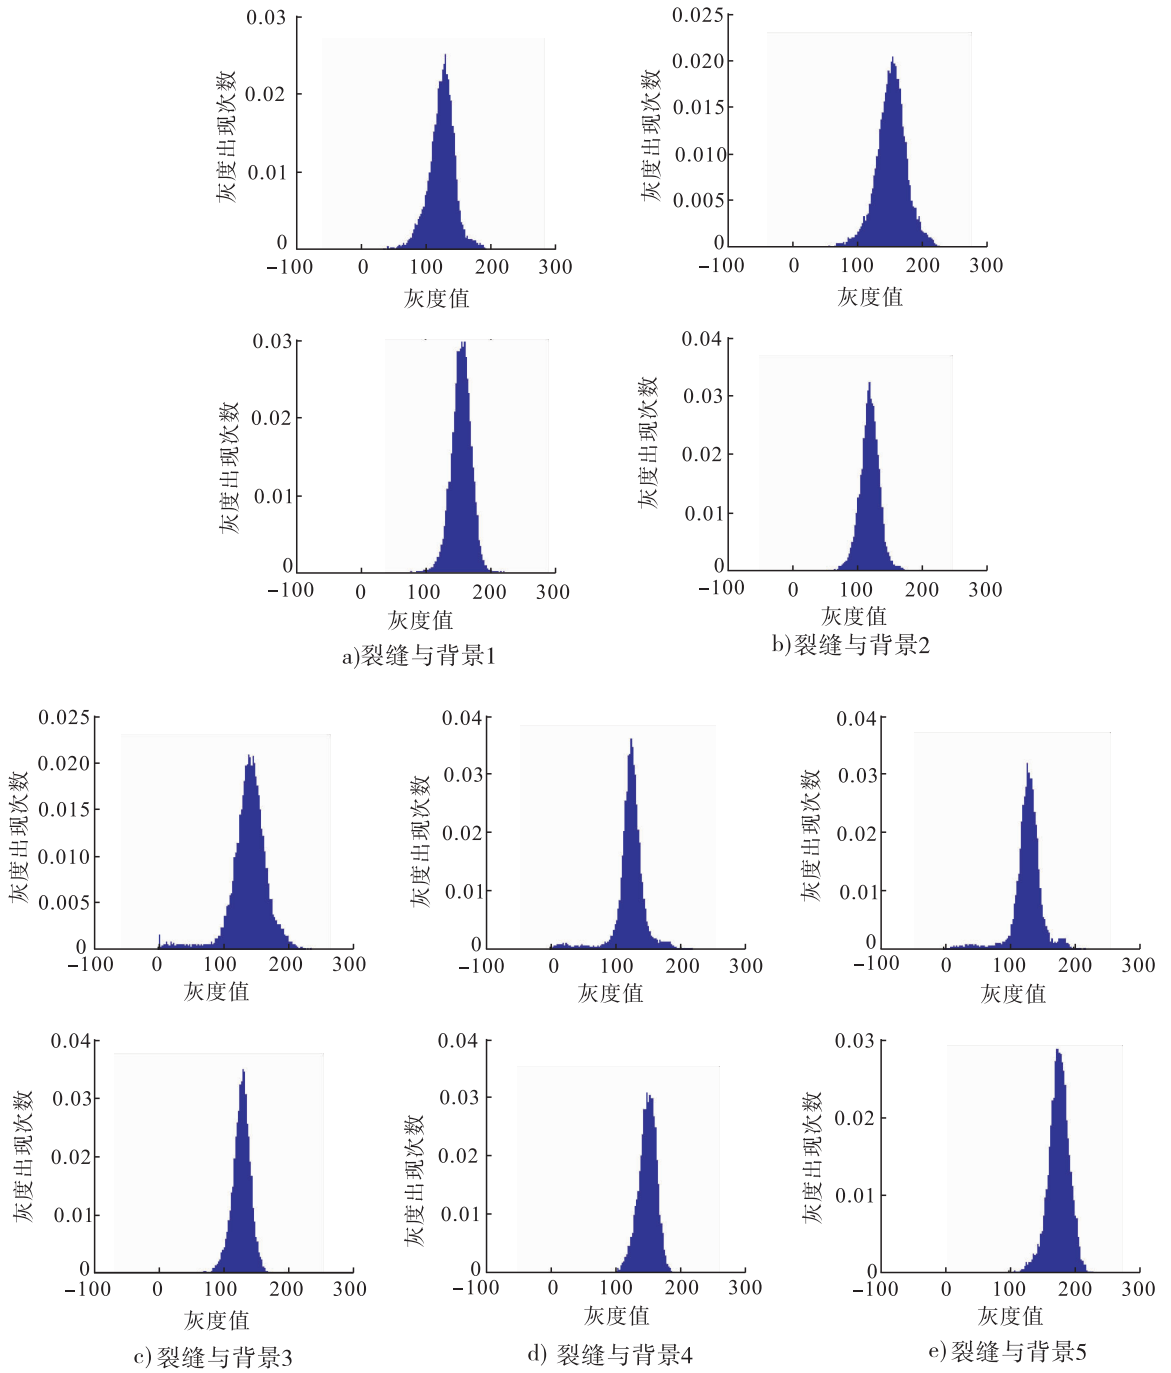


图2 灰度直方图分析

Fig. 2 The Grayscale histogram analysis

对于高维特征 的表示十分有效,并且已经成功应用到人脸识别、目标识别、文字识别和动作识别等^[19] 任务中. 稀疏编码的目的在于从已经得到的特征集中学习到完备的元素,通过线性结合的方式,用少量的元素描述输入的数据集. 这些少量的元素,又被称为原子或者基向量,所

有基向量的集合被称为字典,这些基向量所对应的系数称为稀疏码,之所以叫作稀疏码,是因为大部分的系数都为0,少量为1.

假设单个输入向量 $\xi \in \mathbf{R}^k$, 基向量 $b_1, b_2, \dots, b_n \in \mathbf{R}^k$, 我们的目标在于求得一个稀疏

向量 $s \in \mathbf{R}^n$, 使得 $\xi \approx \sum_j b_j s_j$, 通常来说 $n > k$, 这样字典就是过完备的. 重建错误项 $\xi - \sum_j b_j s_j$ 满足均值为0的高斯分布, s_j 是服从指数分布的.

那么, 对于一个输入数据集 $\{\xi^{(1)}, \xi^{(2)}, \dots, \xi^{(m)}\}$ 和对应待定的稀疏系数 $\{s^{(1)}, s^{(2)}, \dots, s^{(m)}\}$, 其最大后验概率其实是一个优化问题, 原因在于它们之间的差值越小, 则联合概率越大. 那么, 代价函数为

$$\min \{b_j\} \{s_j\} \sum_{i=1}^m \frac{1}{2\sigma^2} \cdot$$

$$\left\| \xi^{(i)} - \sum_{j=1}^n b_j s_j^{(i)} \right\|^2 + \beta \sum_{i=1}^m \sum_{j=1}^n \varphi(s_j^{(i)})$$

s. t. $\|b_j\| \leq c, \forall j = 1, 2, \dots, n$ ③

其中, c 为常数, $\varphi(\cdot)$ 为稀疏函数:

$$\varphi(s_j) = \begin{cases} \|s_j\|_1 \\ (s_j^2 + \varepsilon)^{\frac{1}{2}} \\ \log(1 + s_j^2) \end{cases}$$

从式 ③ 可以得出, 如果要使代价函数尽可能小, 则重建错误应尽可能小, 并且稀疏系数应尽可能全部为 0. 实际上经过标准化的数据集是很小的, 接近于 0, 那么稀疏系数全部为 0, 或者说稀疏项为 0, 也是可以满足代价函数尽可能小的条件的. 但是, 这是不符合实际情况的. 针对此问题, 本文改进了稀疏编码, 改进后的稀疏编码以用户期望为主, 可以自主调整稀疏系数:

$$\min \{b_j\} \{s_j\} \sum_{i=1}^m \frac{1}{2\sigma^2} \left\| \xi^{(i)} - \sum_{j=1}^n b_j s_j^{(i)} \right\|^2 +$$

$$\rho \log \frac{\rho}{\hat{\rho}} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}}$$

s. t. $\|b_j\| \leq c, \forall j = 1, 2, \dots, n$

其中, ρ 表示实际稀疏系数中 1 的个数, $\hat{\rho}$ 表示期望的稀疏系数中 1 的个数.

1.2.3 空间金字塔池化 改进稀疏编码后得到的稀疏特征集的维数还是很高的, 不利于收

敛. 根据统计学原理, 统计特征可以作为区分图像类别的依据. 原有的空间金字塔^[20] 利用均值来进行统计特征的提取, 但是, 由于经过稀疏编码后存在过多的 0 元素, 均值对整体特征的贡献不大, 所以, 需将均值变换为最大值. 空间金字塔算法反复利用最大值特征来降低稀疏特征集的维数, 最终达到加速收敛的目的. 池化过程如图 3 所示, 其中 X 表示输入的图像, U 是求得的局部稀疏矩阵, Z 是空间金字塔. 空间金字塔的第一个尺度空间由下式得到:

$$z_j = \max \{ |u_{1j}|, |u_{2j}|, \dots, |u_{mj}| \}$$

其中, z_j 表示 Z 的第 j 个元素, u_{ij} 表示 U 的第 i 行第 j 列的元素. 然后, 把第一个尺度空间的元素分成 4×4 的小块, 分别求出每个小块的最大值, 构成第二个尺度空间; 最后, 把第二个尺度空间的元素分成 2×2 的小块, 分别求出每个小块的最大值, 构成第三个尺度空间, 第三个尺度空间为 Z 的最终值.




图 3 池化过程

Fig. 3 The process of pooling

1.3 数据分类

经过以上处理后, 标识的训练样本由最初的 $\{(x_l^{(1)}, y_l^{(1)}), \dots, (x_l^{(m_i)}, y_l^{(m_i)})\}$ 变成 $\{(z_l^1, y^{(1)}), \dots, (z_l^{(m_i)}, y^{(m_i)})\}$, 共 m_l 个, 其中 $y \in \{0, 1, 2, 3, 4, 5\}$. 基于支持向量机^[21] 的线性分类器旨在学习到一个线性函数 $\{w_c^T z | c \in y\}$, 使得目标函数 $y = \max_{c \in y} w_c^T z$ 最大. 实际上, 就是解决式 ④ 的凸优化问题:

$$\min_{w_c} \{ J(w_c) = \|w_c\|^2 + c \sum_{i=1}^n \lambda(w_c; y_i^c, z_i) \} \quad (4)$$

其中 $\lambda(w_c; y_i^c, z_i) = [\max(0, w_c^T z_i \cdot y_i^c - 1)]^2$, 如果 $y_i = c$, 则 $y_i^c = 1$, 否则 $y_i^c = -1$. 经过线性分类器后, 最终训练集被分为 6 类, 然后经过交叉验证, 得到分类准确率. 之所以选择线性分类器而不是非线性分类器的原因有两方面, 一是线性分类器的时间复杂度更低, 二是本文学习到的特征适合用线性分类器处理.

2 验证实验

为了验证本文提出的基于稀疏编码的桥梁路面裂缝分类算法的有效性, 在 3.30 GHz 双核 CPU, 8.00 G 内存的计算机上, 用 Matlab R2016a 对原数据集中 27 471 张不同分辨率的

桥梁路面裂缝图像进行分类.

在原数据集中, 随机抽取一张图片, 采用白化主成分分析进行降维、减少冗余处理, 结果见图 4, 其中 $k = 16$. 图 4b) 协方差矩阵为对角矩阵, 验证了特征向量或者特征值计算正确; 由图 4c) 可以看出, 图像存在大量冗余, 且减少冗余后, 重要的信息没有丢失.

对随机抽取的 200 个 8 像素 \times 8 像素的原始图像块进行特征字典学习, 结果见图 5. 由图 5 可以看出, 以图像形式显示的字典虽然是过完备的, 但是字典的大小在可接受范围内, 甚至可以说字典中的数据是比较少的, 这就说明改进后的稀疏编码对于解决特征比较复杂的这类问题是十分有效的.

利用本文方法与其他常用分类方法对原始

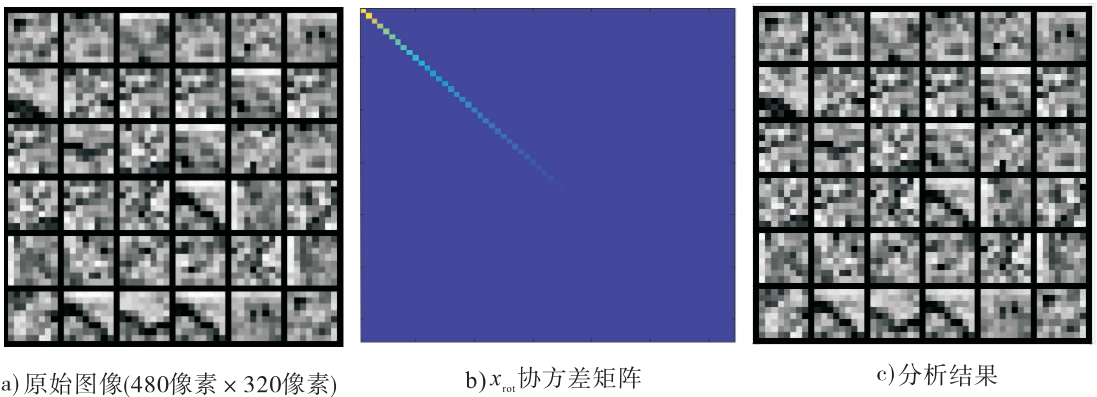


图 4 白化主成分分析结果

Fig. 4 The result of whitening PCA




图 5 特征字典的学习结果

Fig. 5 The result of feature dictionary

数据集进行分类, SVM 方法、Random Forest 方法、Adaboost 方法、本文方法的分类正确率分别为 79.6%、76.3%、90.8%、92.7%。由此可见,对于桥梁路面裂缝的分类问题,本文提出的分类方法有更好的实验效果。又因为绝大多数桥梁路面裂缝图像都可以利用稀疏特征集表示出来,所以本文提出的分类方法的泛化能力也是很强的。而且,原数据集因为经过了白化主成分分析、改进的稀疏编码和空间金字塔池化这三个过程都有降维的作用,所以本文提出的分类方法的收敛比较快,对于高分辨率图像和大数据集的处理具有不可比拟的优势。

3 结语

针对桥梁安全和维护问题,提出了基于稀疏编码的桥梁路面裂缝分类方法。与其他分类方法相比较,本文提出的方法有很多优势:

- 1) 针对实地采集的桥梁路面裂缝图像的区域局限性和数量局限性,借鉴自学习算法,将实地采集的数据集进行了扩充;
- 2) 白化主成分分析和改进的稀疏编码使得算法的收敛速度加快;
- 3) 尺度不变特征和改进的稀疏编码使得算法具有完备的特征字典,增强了算法的泛化能力;
- 4) 根据统计学原理,应用空间金字塔对特征进行池化,降低了特征维数,加速了收敛,再利用线性支持向量机进行多分类,有效减少了分类的时间,提高了分类效率,增强了分类能力。

大量实验表明,本文提出的分类方法确实加速了特征学习,而且相对于其他分类方法,获得了更高的分类准确率。不可避免地,深度学习也存在一些问题,例如参数依赖问题、特征维数过大问题和训练时间过长问题。下一步,我们将进一步简化该学习模型,减少其对参数的依赖。

参考文献:

- [1] ORTOLANO M, DELIA V, CALLEGARO L. A three-arm current comparator digitally assisted bridge for the comparison of arbitrary four terminal-pair impedances [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66 (6):1496.
- [2] CHEN Y, MEI T, WANG X J, et al. A bridge crack image detection and classification method based on climbing robot [C] // 35th Chinese Control Conference. Piscataway: IEEE, 2016: 4037-4042.
- [3] 陈瑶,梅涛,王晓杰,等.基于爬壁机器人的桥梁裂缝图像检测与分类方法[J].*中国科学技术大学学报*,2016,46(9):788.
- [4] 刘海洋,王志海,张志东.基于 ReliefF 剪枝的多标记分类算法[J/OL].<http://kns.cnki.net/kcms/detail/11.1826.TP.20180119.1133.014.html>.
- [5] 韩洁,李盛阳,张涛.基于深度学习的遥感影像城市扩展方法研究[J].*载人航天*,2017,23(3):414.
- [6] 张号逵,李映.深度学习在高光谱图像分类领域的研究现状与展望[J/OL].<http://kns.cnki.net/kcms/detail/11.2109.TP.20171102.1403.002.html>.
- [7] 王倩,张新明,蔡强,等.基于改进 VLAD 算法的图像分类[J/OL].*计算机应用研究*,2018,35(11).[2017-11-10].<http://www.arocmag.com/article/02-2018-11-050.html>.
- [8] 石祥斌,房雪键,张德园,等.基于深度学习混合模型迁移学习的图像分类[J].*系统仿真学报*,2016,28(1):167.
- [9] 徐佳,袁春琦,程圆娥,等.基于主动深度学习的极化 SAR 图像分类[J].*国土资源遥感*,2018,30(1):72.
- [10] 夏梦,曹国,汪光亚,等.结合深度学习与条件随机场的遥感图像分类[J].*中国图象图形学报*,2017,22(9):1289.
- [11] BERRIEL R F, LOPES A T, DE SOUZA A F.

- Deep learning-based large-scale automatic satellite crosswalk classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(9): 1513.
- [12] AFAN A, FAN Y Y. Automatic modulation classification using deep learning based on sparse autoencoders with nonnegativity constraints [J]. *IEEE Signal Processing Letters*, 2017, 24(11): 1626.
- [13] O'SHEA T J, ROY T, CLANCY T C. Over-the-air deep learning based radio signal classification [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 168.
- [14] DE S, BRUZZONE L, BHATTACHARYA A, et al. A novel technique based on deep learning and a synthetic target database for classification of urban areas in PolSAR data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(1): 154.
- [15] SANTARA A, MANI K, HATWAR P, et al. BASS net: Band-adaptive spectral-spatial feature learning neural network for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(9): 5293.
- [16] DEY D, CHATTERJEE B, DALAI S, et al. A deep learning framework using convolution neural network for classification of impulse fault patterns in transformers with increased accuracy [J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2017, 24(6): 3894.
- [17] GUNDOGDU E, ALATAN A A. Good features to correlate for visual tracking [J]. *IEEE Transactions on Image Processing*, 2018, 27(5): 2526.
- [18] PEHLEVAN C, CHKLOVSHII D B. Optimization theory of Hebbian/anti-Hebbian networks for PCA and whitening [C] // Fifty-third Annual Allerton Conference on Communication, Control, and Computing (Allerton). Piscataway: IEEE, 2015: 1458 – 1465.
- [19] QUAN Y H, XU Y, SUN Y P, et al. Sparse coding for classification via discrimination ensemble [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 5839 – 5847.
- [20] CHUNDI P, SUBRAMANIAM M, SABET K, et al. Analyzing retinal optical coherence tomography images using differential spatial pyramid matching [C] // 2016 IEEE 16th International Conference on Bioinformatics and Bioengineering. Piscataway: IEEE, 2016: 316 – 323.
- [21] URICAR M, TIMOFTE R, ROTHE R, et al. Structured output SVM prediction of apparent age, gender and smile from features [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2016: 730 – 738.