

基于卷积神经网络的壁画颜料多光谱图像分类

王燕妮, 朱丹娜*, 王慧琴, 王可

西安建筑科技大学信息与控制工程学院, 陕西 西安 710055

摘要 针对传统光谱匹配法在进行古代壁画颜料识别时存在的获取每个点反射率的过程复杂、计算具有一定误差等会影响识别精度的问题, 将壁画颜料识别问题转换成多光谱图像分类问题, 利用在图像分类领域有较强优势的卷积神经网络算法对多光谱图像进行处理, 设计了一种新的卷积神经网络模型, 并提出了光谱特征重组的数据预处理方式, 通过加入两次 dropout 防止训练过程出现过拟合问题, 进而实现了对古壁画颜料的分类。实验结果表明, 该方法与统计流形支持向量机分类方法, 以及未加入 dropout 的卷积神经网络分类方法相比, 在分类效果和分类精度上具有明显的优势。

关键词 图像处理; 壁画颜料; 多光谱图像; 分类; 卷积神经网络

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.221001

Multispectral Image Classification of Mural Pigments Based on Convolutional Neural Network

Wang Yanni, Zhu Danna*, Wang Huiqin, Wang Ke

School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710055, China

Abstract The traditional spectral matching method is based on the spectral reflectivity. However, the process of obtaining the reflectivity of each point is complicated, and the calculation has some errors, which will affect the recognition accuracy. In order to solve this issue, the problem of mural pigment recognition has been transformed into multi-spectral image classification, and a convolutional neural network algorithm with strong advantages is used in image classification to process multi-spectral images. Meanwhile, a new convolution neural network model is designed, and a data preprocessing method of spectral feature reorganization is proposed. By adding two dropouts, the problem of over-fitting in the training process is prevented, and the classification of ancient mural pigments is realized. The experimental results show that compared with the statistical manifold support vector machine classification method and the convolutional neural network classification method without dropout, the proposed method has obvious advantages in classification effect and classification accuracy.

Key words image processing; mural pigment; multispectral image; classification; convolutional neural network

OCIS codes 100.3008; 100.4996; 110.4234

1 引言

在中国的文化遗产宝库中, 壁画艺术是古代劳动人民智慧的结晶, 在绘画艺术传承中具有不可替代性。受文物保存环境的限制, 古壁画容易受到自然或者人为因素的破坏, 失去原有信息^[1], 所以文保工作者一直在探索无损壁画颜料检测识别方法^[2],

并希望通过该方式来推动文物保护的发展。常见的无损颜料检测识别法主要分为两类: 光谱反射率匹配法和基于多光谱^[3]图像的分类方法。前者在获取壁画颜料每个点的光谱反射率时的操作过程极为复杂; 后者相比前者能更高效全面地对壁画颜料进行分类, 因此在壁画颜料分类与识别领域中被广泛应用。

收稿日期: 2019-03-21; 修回日期: 2019-04-30; 录用日期: 2019-05-13

基金项目: 国家自然科学基金(61701388)、陕西省自然科学基金基础研究计划(2016JM6079, 2018JM6080)

* E-mail: mayday9369@163.com

近年来,有文保研究人员在壁画颜料的多光谱图像分类领域先后引入了不同机器学习方法,如支持向量机(SVM)^[4]。SVM最初是为了二分类而设计的,之后也被应用于多分类的问题上。但在多分类问题上,不论是使用直接法在目标函数上进行修改还是用间接法通过多个二分类器来构造多任务分类器,都存在任务实现相对困难、计算复杂程度过高的缺点。此后,也有研究人员提出将统计流形学习算法和 SVM 相结合的方法^[5]来处理壁画颜料的多光谱图像分类问题,该方法可以将颜料的多光谱反射率特征与图像信息充分融合,虽然其处理结果优于传统的 SVM 算法,但仍不适用于训练大规模数据。

相对于机器学习方法,以卷积神经网络(CNN)^[6]为代表的深度学习技术在图像分类、模型识别等领域具有良好的性能表现。CNN 拥有强大的特征学习能力,它通过交替的卷积和池化运算来模拟人脑的多层处理过程,通过权值共享降低了网络的复杂性,且多维矩阵的可直接输入网络在一定程度上避免了手动特征提取和分类过程中复杂的数据重建。目前,使用深度学习方法处理壁画颜料分类与识别问题的研究极为缺乏,本文结合多光谱图像和 CNN 的特点,提出了一种新的 CNN 模型用于

壁画颜料的分类,并针对古壁画的多光谱数据设计了一种多光谱特征重组的数据预处理方式,通过该方式处理得到的颜料多光谱数据更利于 CNN 模型学习。

2 CNN 的基本原理

CNN,简单地说就是让权重在不同位置共享的神经网络,其每个神经元都可以影响一部分覆盖范围内的周围神经元。近年来,CNN 在计算机视觉领域取得了一系列的成果^[7],尤其在解决图像分类问题上效果卓著,对大规模图像的处理效率极高。低层 CNN 提取的特征较为浅显,但随着网络结构加深,神经网络提取的特征更加具体,语义信息也更为丰富。

一般的 CNN 主要由卷积层(convolutional layer)、激活层^[8]、池化层(pooling layer)、全连接层(fully-connected layer)组成,大部分改进的 CNN 模型都是在此基础上进行各种组合和改动。目前,激活函数大都使用 ReLU 函数,其导数易于计算,收敛速度快,性能较为突出。如图 1 所示,数据经过卷积操作之后也会经过激活层,因此实际应用中也经常将卷积层和激活层 ReLU 共称为卷积层。




图 1 CNN 的基本结构

Fig. 1 Basic structure of CNN

卷积层是 CNN 中最核心的部分,主要用作特征提取,它会根据特定需要去探索图像本身的特定概念。卷积层提取特征靠有主动学习功能的卷积核^[9]完成,卷积核作为网络中的过滤器,会根据设置好的核大小、步长,以及填充等参数遍历图像,将被扫描的图像像素矩阵与卷积核的权重对应相乘然后求和,即可得到输出图片中的一个像素值。每扫描一次得到一个输出。具体过程如图 2 所示,* 表示卷积的过程。

卷积的输出结果可表示为

$$y_{ij} = \sum_{u=1}^m \sum_{v=1}^n f_{uv} \cdot x_{i-u+1, j-v+1}, \quad (1)$$

式中: m, n 表示矩阵的大小; $x_{i-u+1, j-v+1}$ 表示任意一个图像的矩阵元,其中, $i \in [1, m_1], j \in [1, n_1]$; f_{uv} 表示卷积核,其中, $u \in [1, m_2], v \in [1, n_2]$,一般




图 2 卷积的过程

Fig. 2 Convolution process

情况下, $m_1 \ll m_2, n_1 \ll n_2$ 。

图像经卷积层处理后,会进入池化层进行池化操作。池化层^[10]又被称为下采样层,主要用来减小图像的空间大小。池化操作可以看作是将一张高分辨率图片转换为低分辨率图片的过程^[11],通过这种方式可减小全连接层的参数数量,在加快计算速率的同时还能防止过拟合,提高所提取特征的稳健性。

池化层在 CNN 中并不是必要部分,应根据实际情况决定是否需要进行池化层。

CNN 中的输出层是全连接层^[12],在整个卷积神经网络中起到分类器的作用,来自其他层的输入在这里被平化和发送,最终以类的形式输出。输出层具有类似分类交叉熵的损失函数,用于计算预测误差。一旦前向传播完成,反向传播就会开始更新权重与偏差,以减小误差和损失。

3 基于 CNN 的多光谱图像分类方法

3.1 CNN 分类模型

AlexNet^[13-14]是 2012 年应用在 ImageNet 上的深度网络模型,它的准确度较传统神经网络方法有很大提升,在图像分类问题上也有优异的表现。为此,基于 AlexNet 设计一种新的 CNN 模型,用于处理古壁画颜料的分类和识别问题。

由于所采用的数据集是壁画颜料的多光谱图像,比其他图像(如高光谱遥感图像)的尺寸小、图像通道少,为此特基于 AlexNet 设计一种适用于壁画颜料多光谱图像分类的 CNN 模型。该模型是对 AlexNet 模型的精简,并重新设置了参数。改进后的 CNN 模型设置了 2 个卷积层和 2 个全连接层。考虑到要对壁画颜料的多光谱图像进行像素级分类,特意区别于以往选取的正方形卷积核,设计了长方形的卷积核,两个卷积层分别设有 32 和 64 个卷积核,卷积核大小均设置为 1×3 ,步长为 1。池化层中过滤器的参数设置为 1×2 ,步长为 1,采用的池化方式为最大池化。同时,引入 flatten 层将输入“压平”,用于卷积层到全连接层的过渡。在 flatten 层之后是 2 个全连接层,节点参数设置为 128 和 num_classes,后者的节点数与实验中模型学习的样本类别数一致,由于拟对 8 种壁画颜料进行识别,所以第二个全连接层的节点设置为 8。最后,用 Softmax 层作为整个 CNN 的输出。所设计的 CNN 模型的可视化结果如图 3 所示,该结果是通过模型结构可视化软件 Netron 处理该 CNN 模型得到的。其中,“ $? \times 1 \times 16 \times 1$ ”中的“?”代表批处理参数(batch_size), 1×16 是处理样本的大小,最后的 1 是指采用多光谱图像,若为 RGB 图像则此处为 3。第一个卷积层“ $1 \times 3 \times 1 \times 32$ ”中的 1×3 代表卷积核大小,1 代表多光谱图像通道数,32 代表卷积核的个数,bias 代表偏置参数;第二个卷积中的各项参数同理可得。第一个全连接层(dense)中的“ 384×128 ”,384 代表非固定值,会随送入网络的样本个数而变

化;128 代表全连接层中的节点参数。第二个全连接层中的参数与之同理。

如图 3 所示,Conv2D 表示卷积步骤,MaxPooling2D 是最大池化操作。加入两次 dropout,分别设置在池化层和第一个全连接层之后,参数分别设置为 0.25 和 0.5。加入 dropout 的目的是避免训练过程中出现过拟合问题,并增强模型的泛化能力^[15]。CNN 的训练过程中,会临时随机地按照定义的概率舍弃一部分神经元,即部分神经元暂时停止更新计算,但是其权重仍被保留,在下次训练的过程中很可能重新开始更新。向模型中加入 dropout 的方式可以减少神经元之间的相互依赖,从而确保模型能够提取互相独立的特征,其中,减少权重提高了网络对神经元连接的稳健性^[16]。

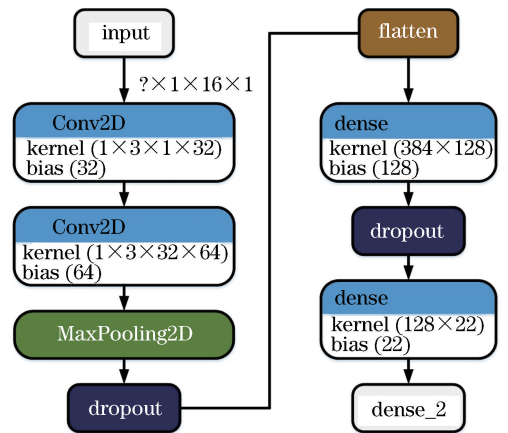


图 3 所设计的 CNN 模型

Fig. 3 Designed CNN model

图 4(a)所示为没有 dropout 层的普通 2 层全连接结构,记为 $r = a(Wv)$,其中: $a(\cdot)$ 为激活函数, V 和 v 表示输入值, r 表示输出值, W 为网络权重。图 4(b)所示为在第 2 层全连接后添加 dropout 层的示意图,即在模型训练时随机让网络中某些神经元不工作,其他过程保持不变。

3.2 光谱特征重组的数据预处理方式

采集的实验数据集取自 16 个波段下标准颜料块的多光谱图像,分辨率均为 $61 \text{ pixel} \times 61 \text{ pixel}$ 。采集的波段都在可见光范围($400 \sim 900 \text{ nm}$),波段间隔为 $20 \sim 40 \text{ nm}$ 。如图 5 所示,以颜料真银朱为示例,其在 $400 \sim 580 \text{ nm}$ 波段内($400, 420, 460, 520, 540, 580 \text{ nm}$)和 $820 \sim 900 \text{ nm}$ 波段内($820, 860, 900 \text{ nm}$)的多光谱图像相似度较高,肉眼难以区分。类似情况在其他颜料的多光谱图像中也较为常见。若将此类数据直接输入到 CNN 模型中进行




图 4 Dropout 原理。(a)无 dropout 的网络;(b)加入 dropout 的网络

Fig. 4 Principles of dropout. (a) Network without dropout; (b) network with dropout




图 5 颜料真银朱的多光谱图像

Fig. 5 Multispectral images of the pigment true silver

特征学习,可能会致使模型的自学习效果不佳,从而降低实验后期的分类精度。

若选取一般数据增强的方式(如图像翻转)来扩充数据量,则同种颜料在不同波段下的多光谱图像相似度仍然很高,纹理信息也不明显,易出现过拟合。针对此问题,设计了一种新的数据预处理方式:对原始壁画的多光谱图像进行多光谱特征重组,即将灰度图像的每个像素点排列之后切割成 M 个像元送入设置好的 CNN 模型中进行训练。此方法可以缓解直接将多光谱数据输入模型泛化能力差的缺点,并能够有效提高模型分类精度。

为了更加形象地说明所采用的数据预处理方法,给出如图 6 所示的流程图,其中,光谱波段表示为 R ,波段个数表示为 N 。数据预处理步骤如下: 1)分别将 R 在这 N 个波段下的多光谱灰度图像中的每个光谱像元按顺序重组并排列成 N 个一维向量,如当 $R = 400 \text{ nm}$,此波段下的多光谱图像大小为 $P \times Q$,则将这 $P \times Q$ 个像元按照像元顺序纵向排列成为一个一维向量,此一维向量的大小为 $1 \times (P \times Q)$; 2)将这 N 个一维向量按照波段从小到大的顺序递进排列,重组成为一个二维矩阵,这个二维矩阵的大小为 $N \times (P \times Q)$ 。若要增大模型对光谱灰度图像在不同波段下的学习程度,使得每个像元携带的信息量更加清晰,可对该二维矩阵进行降维处理,将矩阵按顺序逐层分割成 $P \times Q$ 个分辨率为 $N \times 1$ 的多光谱样本单元。

以颜料真银朱为例,其在 $400 \sim 900 \text{ nm}$ 范围内的 16 个波段下的多光谱图像分辨率为 $61 \text{ pixel} \times 61 \text{ pixel}$,每个波段下灰度图中的像素点按照步骤 1)得到 16 个大小为 1×3721 的一维向量;再按照步骤 2)进行特征重组,这 16 个一维向量按照波段值从小到大的顺序排列之后得到大小为 16×3721 的二维矩阵,这个二维矩阵被逐层分割成 3721 个 16×1 的颜料真银朱的分类样本单元;最后将得到的样本单元送入设计好的 CNN 模型进行学习。类似这样的多光谱样本单元同时含有 16 个波段的光谱信息,原光谱数据的纹理信息通过这种转变方式能够被丰富地表达,更加利于 CNN 学习。

壁画颜料分类的具体实验步骤如图 7 所示。具体步骤为: 1)通过 CCD 多光谱相机拍摄获取标准颜料库和模拟壁画的多光谱图像,再利用所设计的光谱特征重组的数据预处理方式对这两类数据进行处理,得到标准颜料库的训练样本单元和模拟壁画的预测样本单元; 2)将标准颜料库的训练样本单元送入所设计的 CNN 模型中,使其自身特征可以被充分学习; 3)将模拟壁画的待预测样本单元输入到训练好的壁画颜料 CNN 分类模型中,得到颜料分类的最终效果图。

4 实验与分析

4.1 实验环境

采用以 TensorFlow - GPU 1.9.0 为后台的

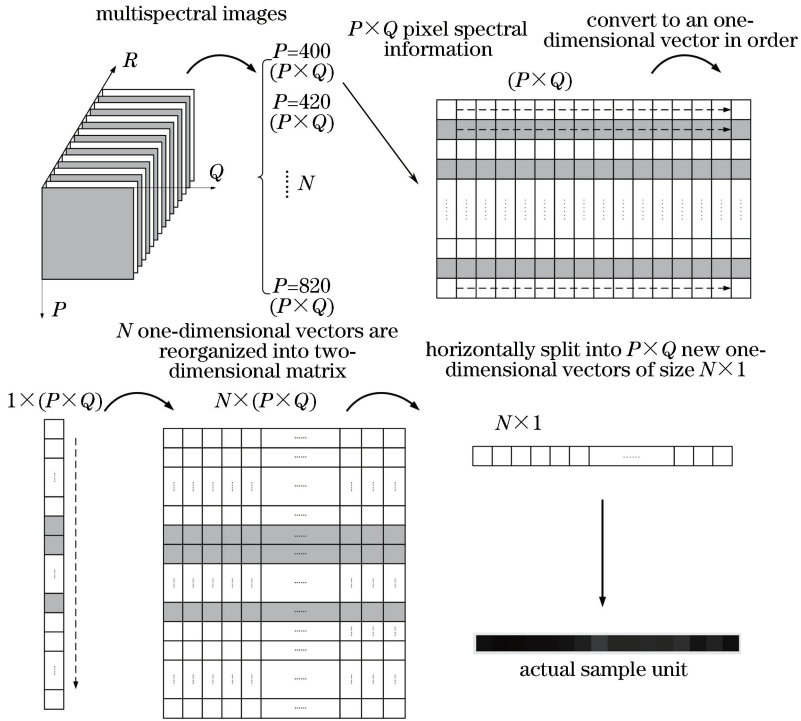


图 6 光谱特征重组流程图

Fig. 6 Flow chart of spectral feature reorganization

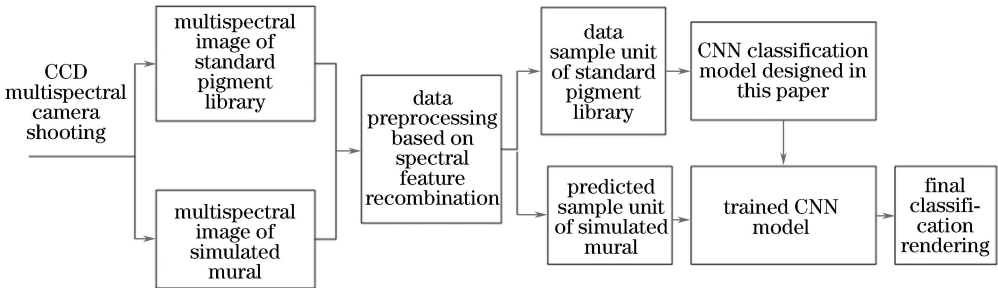


图 7 壁画颜料分类实验流程图

Fig. 7 Flow chart of classification experiment for mural pigments

KERAS 2.2.2 深度学习开源框架,操作系统为 Windows,处理器为 Inter (R) Core (TM) i7-7700HQ @2.81 GHZ,运行内存为 16 G。

所选用的多光谱数据集,由使用美国海洋光学公司生产的型号为 SpectroCam VIS 的 CCD 多光谱相机、16 个窄带干涉滤光片和 CIE 标准 A 照明光源拍摄而来。

4.2 实验数据处理

4.2.1 训练样本的制作

所使用的训练样本是通过 CCD 相机拍摄的标准颜料块在 16 个波段下的多光谱图像,波段范围处于可见光 400 ~ 900 nm,波段间隔基本为 20 ~ 40 nm。标准颜料块的样本制作过程如下。

1) 矿物质块状颜料。首先将颜料用适量清水

浸透,颜料与水分别按照 1 : 1、1 : 3 和 1 : 5 的质量比例配制,待全部融化后方可使用。

2) 矿物质粉末颜料。倒出所需要的明胶,加入 5 ~ 6 倍的开水充分将明胶融化成明胶液;取适量的矿物质粉末颜料,与明胶液一起放置在乳钵中研磨,待研磨成糊状之后,再加入清水。胶体、颜料、水分别按照 1 : 1 : 1、1 : 1 : 3 和 1 : 1 : 5 的质量比例配制。

3) 标准颜料版制备。将配制好的每种颜料均匀涂抹在木基板上,如图 8 所示。这种木基板的作用是模仿古代壁画的载体墙壁,为此,在其表面均匀涂抹了一层碳酸钙(CaCO₃)。为了保证每种颜料上色的饱满程度,必须将其涂抹均匀。

4) 使用 CCD 多光谱相机采集标准颜料块的

多光谱数据,配准之后用 Matlab 对标准颜料板的灰度图进行切割,按照颜料类别打标签,并归类存放。

使用 CCD 多光谱相机采集标准颜料块的多光谱数据。图 8 展示了在 400~900 nm 范围内标准颜料块的多光谱图像。




图 8 标准壁画颜料板的多光谱图像

Fig. 8 Multispectral images of standard mural paint board

4.2.2 预测样本的采集

实验预测数据是通过多光谱 CCD 相机拍摄的 16 个波段模拟壁画的多光谱图像,选取的波段范围是可见光 400~900 nm,波段间隔基本为 20~

40 nm,所获得的壁画多光谱图像分辨率为 1370 pixel×1030 pixel。模拟壁画的多光谱图像如图 9 所示。

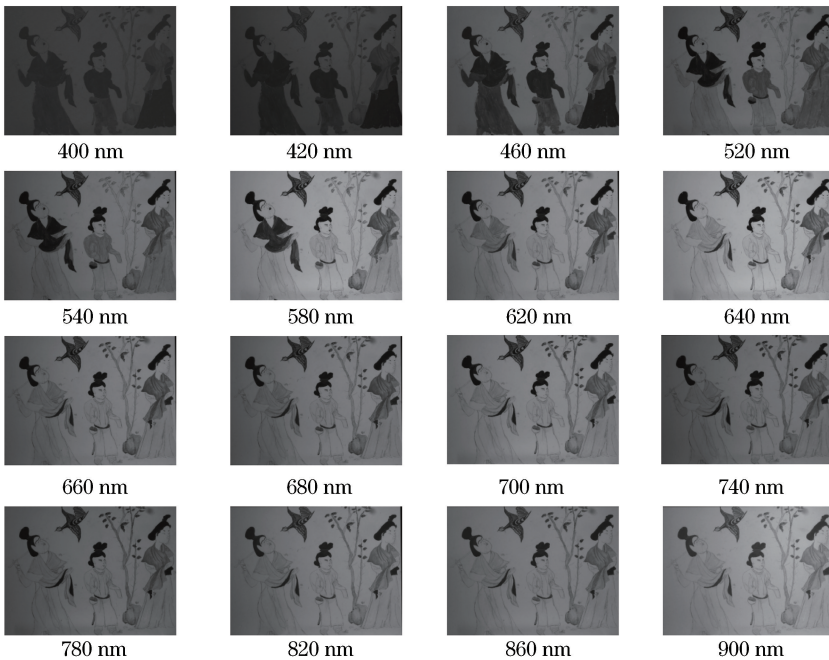


图 9 模拟壁画的多光谱图像

Fig. 9 Multispectral images of simulated mural

根据壁画中颜料的实际分布情况,预测样本分为银珠、煤黑、四绿、头绿、青金石、铅丹、铬黄和背景

石膏共 8 类,样本总量为 1411100 个。壁画中每种颜料的待预测样本个数如表 1 所示。

表 1 每种颜料的样本个数

Table 1 Number of samples of each pigment

Pigment type	Mercuric sulfide	Coal black	Tetra green	First green	Lazurite	Minium	Chrome yellow	Gypsum
Sample No.	54612	64126	11705	38776	70282	1155	287858	882586

4.2.3 数据预处理

所使用的训练样本和待预测样本均是通过多光谱特征重组法的数据预处理方法获得的,得到的样本单元分辨率均为 $16 \text{ pixel} \times 1 \text{ pixel}$ 。如图 10 所示,以 8 种标准颜料块的其中一个训练样本为例,可看出每类颜料中 1 个像素点的 16 个波段的光谱信息可同时体现在一个样本单元中。共选取这样的像素级样本单元 1414423 个,随机选择其中 1/8 的数据样本单元作为验证集,将剩余的数据样本作为训练集。将待预测的模拟壁画多光谱图像按照光谱特征重组的数据预处理方式得到待预测的颜料样本单元,将每个样本单元输入到训练好的 CNN 模型中,对模拟壁画的每个待预测样本单元进行像素级分类。将每个像素点分类出来的正确结果按照原壁画的像素点顺序排列,最终可得到模拟壁画的分类效果图。




图 10 标准颜料光谱特征重组后的样本单元

Fig. 10 Sample units after spectral feature recombination of standard pigment

4.3 实验结果及分析

为了验证所提出的基于 CNN 的模型对壁画颜料多光谱图像进行识别的优势,以及加入 dropout 层对提高模型泛化能力的效果,统计流形-SVM 模型、CNN 模型(无 dropout 层),以及 CNN 模型(加入 dropout 层)对壁画颜料分类后的结果,可得这三种分类方法对壁画颜料的总体分类正确率(accuracy)分别为 84.92%, 88.53%, 89.18%。可以看出,统计流形-SVM 模型对壁画颜料多光谱图像的分类正确率最低,本文模型的正确率较其提高了 4.26%,而无 dropout 层的 CNN 模型

的分类正确率与之相比也提高了 3.61%,这说明 CNN 对壁画颜料的分类效果远优于机器学习浅层的分类算法。这是因为,CNN 由具有相互交替的卷积层和池化层这种独特的结构构成,能够自动提取数据的光谱特征,同时,CNN 具有强大的学习能力,这使得它在处理这些极其相似的多光谱图像时具有很大的分类优势。两种 CNN 模型的正确率差别不大,CNN 模型在加入 dropout 层后分类正确率虽然仅提高了 0.65%,但也验证了 dropout 层的加入在一定程度上提高了模型的稳健性和分类正确率。

表 2 展示了所设计的加入 dropout 层的 CNN 模型对各种颜料分类效果的混淆矩阵。从单个类别的颜料分类情况来看,该模型对颜料铬黄的分类效果最好,其分类精度(PA 值)高达 95.21%;对颜料头绿的分类效果最差,其 PA 值为 70.74%。模型错将颜料头绿全部分成四绿,经查看这两种颜料的光谱曲线波形图得知,这两种绿色颜料的光谱曲线十分相似,影响了模型的正确率。同时,模型将颜料铅丹错分为真银朱的比例较高,这是因为真银朱的底层颜料即是铅丹,两种颜料的光谱特征相似,导致模型错分。

表 3 显示了 3 种模型对壁画各类颜料的分类精度概况,虽然这三种方法都能达到分类目的,但统计流形-SVM 模型对各类颜料的分类效果不如其他模型。加入 dropout 层之后,CNN 对真银朱和铅丹的分类精度稍有下降,但是对其他 6 种颜料的分类精度均有所提高。

图 11 为三种分类方法的分类效果图和原壁画图的对比,可见所提出的加入 dropout 的 CNN 模型在壁画颜料的多光谱图像分类方向上有一定的适用性,分类效果也比其他两种方法更好,其整体分类正确率相比统计流形-SVM 模型有大幅提高,与未加入 dropout 的 CNN 模型相比也有一定增长。但该方法在边缘处理上对一些细节的处理能力稍差,这是由于壁画原图的边缘是铅笔描画的,该类数据难以采集,这就导致边缘像素点数据无法被模型学习分类,故 CNN 分类模型在壁画中人物、植物、动物边缘的分类上仍存在着一定的误差。

表 2 CNN 模型(加入 dropout)分类效果的混淆矩阵

Table 2 Confusion matrix of classification effect of CNN model (with dropout)

Category	Mercuric sulfide	Coal black	Tetra green	First green	Lazurite	Minium	Chrome yellow	Gypsum
Mercuric sulfide	93.48	0	0	0.75	1.72	3.65	0	0
Coal black	0	81.13	0	2.95	15.52	0	0	0
Tetra green	0	0	90.37	9.63	0	0	0	0
First green	0	0	29.26	70.74	0	0	0	0
Lazurite	2.16	1.38	0	5.87	90.59	0	0	0
Minium	13.04	0	0	0	0	86.96	0	0
Chrome yellow	3.67	0	0	0	1.12	0	95.21	0
Gypsum	0	0	0	3.02	6.24	0	2.52	88.22

表 3 三种模型对每种颜料的分类精度对比

Table 3 Comparison of classification accuracy of each pigment for three models

Category	SVM	CNN(no-dropout)	CNN(dropout)
Mercuric sulfide	93.37	93.49	93.48
Coal black	80.01	80.15	81.13
Tetra green	90.42	90.35	90.37
First green	67.65	70.71	70.74
Lazurite	86.21	90.57	90.59
Minium	63.78	89.92	86.96
Chrome yellow	88.02	95.18	95.21
Gypsum	84.36	88.06	88.22

练过程中发现,一些波段下颜料多光谱的图像相似度较大、光谱特征极为相似,这导致 CNN 模型学习效果不佳。为此,设计了一种基于光谱特征重组的数据预处理方法。通过该方法对壁画颜料多光谱数据进行预处理,在一定程度上提高了 CNN 模型的自学习能力,并使得模型能够深入挖掘壁画颜料多光谱图像更多的自身特征。实验结果表明,所设计的 CNN 模型(加入 dropout 层)与 CNN 模型(无 dropout 层)和统计流形-SVM 方法相比,虽然在壁画颜料的多光谱图像分类问题中能够更加有效地提高分类的精度,达到高效识别壁画中颜料的的目的,但在以下方面仍需要加以改进完善:1)选择的 CNN 是个概率模型,调节参数只能凭借经验,并没有严格的理论支撑,还需开展多组实验进行对比以选择最优参数;2)样本量越大时,CNN 模型学习的效果越好,所以需克服在制作和拍摄标准颜料样本库过程中遇到的难题,扩大标准壁画颜料库的规模;3)待样本量更大时,可尝试将更深

5 结 论

针对传统机器学习法处理壁画颜料多光谱图像时效率低下、分类精度低的问题,提出一种新的基于 CNN 的壁画颜料多光谱图像分类方法,该方法可实现对壁画中每种颜料进行像素级识别的目的。在训



图 11 不同模型分类效果图。(a)壁画原图;(b)统计流形-SVM 模型;(c) CNN 模型(无 Dropout); (d) CNN 模型(加入 Dropout)

Fig. 11 Classification renderings of different models. (a) Original mural; (b) statistical manifold-SVM model; (c) CNN model (without dropout); (d) CNN model (with dropout)

层的卷积神经网络模型,如将 VGGNet 应用在壁画颜料的多光谱图像分类的问题上。

参 考 文 献

- [1] Chai B L, Su B M, Zhang W Y, *et al.* Standard multispectral image database for paint materials used in the Dunhuang murals [J]. *Spectroscopy and Spectral Analysis*, 2017, 37(10): 3289-3306.
柴勃隆, 苏伯民, 张文元, 等. 敦煌壁画绘画材料多光谱图像标准数据库的建立和应用[J]. *光谱学与光谱分析*, 2017, 37(10): 3289-3306.
- [2] Yang W Z, Zhang Y Y, Wang J. Analysis and investigation on protection situation of Han xiu tomb mural of the tang dynasty [J]. *Cultural Relics of Central China*, 2017(1): 122-128.
杨文宗, 张媛媛, 王佳. 唐韩休墓壁画保护现状调查与分析[J]. *中原文物*, 2017(1): 122-128.
- [3] Yang C, Yang B, Huang G Y. Remote sensing image fusion based on multispectral image super-resolution [J]. *Laser & Optoelectronics Progress*, 2016, 53(2): 021001.
杨超, 杨斌, 黄国玉. 基于多光谱图像超分辨率处理的遥感图像融合[J]. *激光与光电子学进展*, 2016, 53(2): 021001.
- [4] Zhao G L, Zhu Q B, Huang M. Apple mealiness detection using supervised isometric feature mapping and support vector machine based on hyperspectral scattering image [J]. *Laser & Optoelectronics Progress*, 2011, 48(10): 101002.
赵桂林, 朱启兵, 黄敏. 高光谱的有监督 Isomap-SVM 苹果粉质化分类[J]. *激光与光电子学进展*, 2011, 48(10): 101002.
- [5] Wang K, Wang H Q, Long Y Q, *et al.* Spectral reflectance reconstruction based on dimension reduction regularization polynomials [J]. *Laser & Optoelectronics Progress*, 2018, 55(5): 053004.
王可, 王慧琴, 龙艳群, 等. 基于降维正则化多项式的光谱反射率重建方法[J]. *激光与光电子学进展*, 2018, 55(5): 053004.
- [6] Zhao W Z, Du S H, Emery W J. Object-based convolutional neural network for high-resolution imagery classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(7): 3386-3396.
- [7] Rehman A, Naz S, Razzak M I, *et al.* Automatic visual features for writer identification: a deep learning approach [J]. *IEEE Access*, 2019, 7: 17149-17157.
- [8] Schmidt-Hieber J. Nonparametric regression using deep neural networks with ReLU activation function [J/OL]. (2019-03-16)[2019-07-10]. <https://arxiv.org/abs/1708.06633>.
- [9] Nagler T. Asymptotic analysis of the jittering kernel density estimator [J]. *Mathematical Methods of Statistics*, 2018, 27(1): 32-46.
- [10] Bell J S, Wilson R I. Behavior reveals selective summation and max pooling among olfactory processing channels [J]. *Neuron*, 2016, 91(2): 425-438.
- [11] Zubair S, Yan F, Wang W W. Dictionary learning based sparse coefficients for audio classification with max and average pooling [J]. *Digital Signal Processing*, 2013, 23(3): 960-970.
- [12] Jiang T T, Cheng J Y, Lu W P. Target recognition based on multilayer feature extraction of convolution neural network [J]. *Computer Systems & Applications*, 2017, 26(12): 64-70.
江彤彤, 成金勇, 鹿文鹏. 基于卷积神经网络多层特征提取的目标识别[J]. *计算机系统应用*, 2017, 26(12): 64-70.
- [13] Alom M Z, Taha T M, Yakopcic C, *et al.* The history began from AlexNet: a comprehensive survey on deep learning approaches [J/OL]. (2018-09-12)[2019-07-10]. <https://arxiv.org/abs/1803.01164>.
- [14] Dominguez-Sanchez A, Cazorla M, Orts-Escolano S. Pedestrian movement direction recognition using convolutional neural networks [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(12): 3540-3548.
- [15] Ghazi M M, Yanikoglu B, Aptoula E. Plant identification using deep neural networks via optimization of transfer learning parameters [J]. *Neurocomputing*, 2017, 235: 228-235.
- [16] Sutskever I, Hinton G, Krizhevsky A, *et al.* Dropout: a simple way to prevent neural networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.