

多尺度特征融合的壁画多光谱图像颜料 3D-CNN 分类方法

丁云乐¹, 王慧琴^{1*}, 王可¹, 王展², 甄刚²

¹西安建筑科技大学信息与控制工程学院, 陕西 西安 710055;

²陕西省文物保护研究院, 陕西 西安 710075

摘要 颜料的分类识别是古代壁画进行保护修复的基础,多光谱成像方法能够无损快速地获取壁画颜料的光谱图像数据并进行分析。传统利用卷积神经网络进行特征提取的算法中连续的卷积和池化操作会丢失壁画多光谱图像的部分特征信息,使得图像细节无法重建,导致分类图像边界不平滑。针对该问题,提出了一种基于多尺度特征融合的三维空洞卷积残差神经网络对壁画多光谱图像进行颜料分类。首先,在卷积核中引入空洞结构提高卷积核的感受野来提取不同尺度信息,避免池化操作所导致的部分特征丢失;其次,使用特征融合的方法融合不同尺度的特征图,增加多尺度特征的结构层次;最后,引入残差学习模块避免网络层数加深导致的梯度消失问题,重建完整的边缘信息。实验结果表明,所提方法在模拟壁画多光谱图像数据集上的总体精度和平均精度分别达到了 98.87% 和 96.89%,与各对照组相比,不仅具有更好的分类精度,而且得到了边界更清晰的分类图像。

关键词 光谱学; 多光谱图像分类; 空洞卷积; 多尺度特征融合; 残差学习

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP202259.2230001

Three dimensional-CNN Classification Method of Mural Multispectral Image Pigments Based on Multiscale Feature Fusion

Ding Yunle¹, Wang Huiqin^{1*}, Wang Ke¹, Wang Zhan², Zhen Gang²

¹School of Information and Control Engineering, Xi'an University of Architecture and Technology,
Xi'an 710055, Shaanxi, China;

²Shaanxi Provincial Institute of Cultural Relics Protection, Xi'an 710075, Shaanxi, China

Abstract The classification and recognition of pigments is the basis of ancient mural protection and restoration. The multispectral imaging method can quickly obtain and analyze the spectral image data of mural pigments without damage. Continuous convolution and pooling operations in the traditional convolutional neural network feature extraction algorithm will lose part of the feature information of the fresco multispectral image, making the image details unable to be reconstructed, resulting in an unsmooth boundary of the classified image. To solve this problem, a three-dimensional hole convolution residual neural network based on multiscale feature fusion is proposed to classify multispectral mural images. To begin, the hole structure is introduced into the convolution kernel to improve the receptive field and extract different scale information to avoid the loss of some features caused by the pooling operation. Second, the feature fusion method is used to combine images of different scales. Finally, a multilevel gradient of the feature map is introduced to prevent the edge from disappearing. On the multispectral image dataset of simulated murals, the experimental results show that the proposed method's overall accuracy and average accuracies are 98.87% and 96.89%, respectively. The proposed method not only outperforms the control groups in classification accuracy, but it also produces classification images with clearer boundaries.

Key words spectroscopy; multispectral image classification; hole convolution; multiscale feature fusion; residual learning

1 引言

古代壁画是我国文化遗产的重要组成部分,具有丰富的历史价值和文化价值。由于自然及人为因素的影响,古代壁画颜料层的褪色、脱落日益加重。为解决此问题,文物工作者致力于壁画保护修复的工作^[1]。壁画颜料信息的识别是壁画保护修复的先行工作,可以给修复和数字存档工作提供理论指导^[2]。因此,如何科学高效准确识别壁画颜料信息具有重要的研究意义。

受检测分析技术限制,早期的壁画颜料信息识别分析以微损取样分析为主,虽然是极小量取样,但对不可再生的壁画来说,损失仍无法弥补。多光谱技术由于其丰富的信息量和非接触性,能够在不破坏物体的情况下收集其特定的光谱信息进行分析,非常适合壁画颜料信息的分类识别^[3-5]。传统的多光谱图像分类方法按照有无先验知识一般分为有监督和无监督两大类。无监督算法主要有K均值法、聚类算法等。有监督算法主要有支持向量机(SVM)、K-邻近算法等^[6-8]。上述算法均为浅层模型,只能对多光谱图像中浅层特征进行学习,优势是算法结构简单,但是分类精度不高,并且无法学习到多光谱图像中复杂的深层特征。

近年来,以卷积神经网络为代表的深度学习方法代替传统方法成为多光谱图像分类的主流趋势。Hu等^[9]提出了一种基于光谱信息一维卷积神经网络(1D-CNN)的多光谱图像分类方法,该方法只利用多光谱图像的光谱特征对数据进行分类,但在壁画颜料多光谱图像分类问题中,丰富的空间特征对壁画的细节和边缘识别有很大的影响。Yang等^[10]利用1D-CNN和二维卷积神经网络(2D-CNN)分别提取多光谱图像中的空间特征与光谱特征,再将两种特征融合后送入分类器。这种方法虽然可以同时利用多光谱图像的空间特征和光谱特征,但破坏了多光谱数据原有的三维结构,而且过多的预处理步骤也增加了算法的

复杂度。Zhong等^[11]将多光谱图像立方体作为输入,利用三维卷积核同时提取空间和光谱特征,避免了对数据降维等复杂的预处理操作,图像分类精度较传统算法有很大提升。但上述算法在壁画多光谱图像颜料分类问题中,均存在分类结果图像边缘不平滑、部分细节信息无法精细分类、甚至误分类等问题。

针对以上问题,本文提出了一种基于多尺度特征融合的壁画多光谱图像颜料三维空洞卷积残差网络分类的方法(MFAC-Res3D-CNN)。输入为多光谱图像立方体数据,充分利用了多光谱图像的三维结构特性。引入空洞卷积的方法在不丢失特征的同时增大卷积核的感受野,以获取不同尺度的特征图。利用多尺度特征融合模型对不同尺度空间特征进行融合^[12]提升了分类精度,最后加入残差结构来避免网络层数加深带来的梯度消失问题。所提方法减少了误分类、提高了分类精度,同时也得到了边界更清晰的壁画分类图像。

2 所提算法基本原理

2.1 三维卷积神经网络

绝大多数卷积神经网络算法最初都是针对二维图像识别所设计的,其最大的优势在于可以直接将二维图像作为输入,建立从底层映射到高层语义的映射关系^[13]。2D-CNN在提取图像的空间特征上表现出极佳的效果,但是在处理多光谱图像这种三维数据时,2D-CNN需要引入大量参数,可能会产生过拟合的现象。同时,多光谱图像数据不仅仅包含光谱信息,而且包含大量的空间信息,2D-CNN的卷积核不利于同时提取多光谱图像数据的光谱和空间信息^[14]。

3D-CNN最早被运用于视频分析^[15],可以利用三维卷积核从视频的不同帧中同时提取空间特征和时间特征,而视频中的时间维度对应到多光谱图像数据就是光谱维度的增加。图1为2D-CNN和3D-CNN示意图。

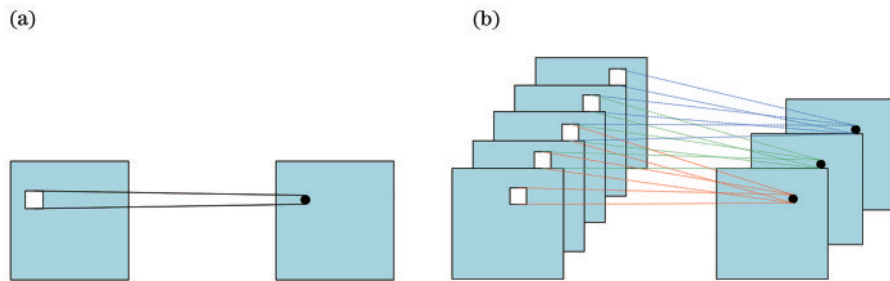


图1 2D-CNN和3D-CNN示意图。(a) 2D-CNN; (b) 3D-CNN

Fig. 1 Schematic diagrams of 2D-CNN and 3D-CNN. (a) 2D-CNN; (b) 3D-CNN

3D-CNN相对于2D-CNN最大的区别在于3D-CNN会在多光谱数据的三个维度同时进行卷积操作,使其在提取空间特征的同时可以提取到光谱维度的特征,更适用于处理多光谱图像数据^[16]。3D-CNN第*i*层

中的第*j*个特征图在点(*x*, *y*, *z*)位置的值 v_{ij}^{xyz} 的表达式为

$$v_{ij}^{xyz} = f \left(\sum_{l=0}^{L_{j-1}} \sum_{m=0}^{W_{j-1}} \sum_{h=0}^{H_{j-1}} W_{i,j,m}^{lch} \cdot V_{i-1,m}^{(x+l)(y+w)(z+h)} + b_{i,j} \right), \quad (1)$$

式中： L_i 与 W_i 分别表示 3D-CNN 三维卷积核的长度和宽度； H_i 表示卷积核在光谱维度上的大小； $f(\bullet)$ 为激活函数； $W_{i,j,m}^{fwh}$ 代表与 $i-1$ 相连的第 m 个特征图的权值； $b_{i,j}$ 代表第 i 层第 j 个特征图的偏置。

2.2 残差学习

与传统的模式识别算法相比,深度卷积神经网络拥有更多非线性的映射结构,具有更多的隐藏层和较为复杂的模型结构,可以获得更深层更抽象的特征,提取更完整的语义信息^[17]。因此,深度学习网络模型的深度对最后的识别和分类的效果有着很大的影响。然而,随着网络层数的加深,梯度在反向传播中会逐渐衰减,最终会导致梯度消失的现象。而且,网络越深,梯度消失的现象就越来越明显,导致分类精度在达到饱和后随之下降。残差模块可以有效解决随着网络深度的增加导致的梯度消失问题^[18-19]。

残差网络采用跳远连接,打破了传统的神经网络 $n-1$ 层的输出只能给 n 层作为输入的惯例,使某一层的输出可以直接跨过几层作为后面某一层的输入。残差学习示意图如图 2 所示。

假设神经网络某一层的输入为 x ,期望的输出为 $H(x)$, $F(x)$ 为需要学习的目标函数。如果将输入 x 直接传到输出作为初始结果,则所需要学习的目标函数 $F(x)$ 可以表示成 $H(x)-x$,这就是一个残差学习单元,残差学习改变了学习目标,不再是学习一个完整的输出 $H(x)$,而是输出和输入的差 $H(x)-x$,即残差。

在残差单元训练中,其输出为输入向量与矩阵变化的结果相加得到的,不会给网络增加额外的参数和计算量,也不影响网络的复杂度,却可以增加模型的训练速度、提高训练效果,并且当模型的层数加深时,能够有效解决梯度消失的问题,使深层网络的训练变得更容易。

2.3 空洞卷积

多光谱图像数据是典型的高维图像数据,在光谱

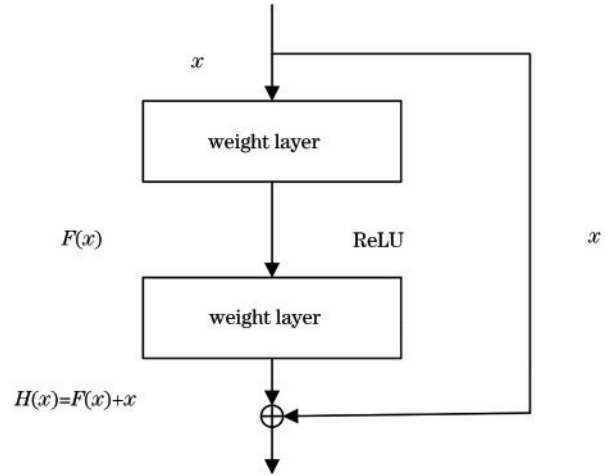


图 2 残差学习

Fig. 2 Residual learning

和空间维度都包含丰富的信息。虽然利用大的三维卷积核更有利于提取空谱特征,但同时会增加网络模型的计算负荷,若要利用较小、层数较少的卷积层获取多光谱图像特征,则需要通过扩大卷积核或利用池化操作来提升卷积核的感受野,但池化操作会丢失掉一部分信息,使得一些图像细节无法重建,在此情况下,利用空洞卷积结构替池化层,可以在避免信息损失的同时扩大卷积核的感受野。

空洞卷积在卷积层中引入了一个叫作扩张率 r 的超参数,该参数定义了卷积核处理数据时各值之间的距离,如图 3 所示。在原始卷积核的基础上,在值与值之间插入权重为 0 的行与列来扩大卷积核的感受野,并用扩张率来控制权重为 0 的行与列数量,若用 K 代表原卷积核长度,则膨胀后的卷积核感受野范围的长度则变成 $K \times (K-1) \times (r-1)$ 。例如,原始卷积核大小为 3×3 , $r=2$ 时在卷积核大小不变的情况下,可以使感受野扩张至 5×5 。




图 3 空洞卷积核示意图。(a) $r=1$; (b) $r=2$; (c) $r=3$

Fig. 3 Schematic diagrams of atrous convolution kernel. (a) $r=1$; (b) $r=2$; (c) $r=3$

3 MFAC-Res3D-CNN 模型

3.1 串行空洞卷积模块

深度神经网络在特征提取阶段,会在一个或多个连续卷积层后添加池化层,池化层可以对输出特征降

维以此来减少网络的计算负荷并扩大卷积核的感受野,但同时池化操作也会牺牲一部分特征信息,使得一些壁画图像细节无法重建,不利后续于修复工作。针对以上问题,所提方法引入空洞卷积结构代替池化层,空洞卷积通过膨胀率来增大卷积核感受野,使每个卷

积层输出包含更大范围的特征信息。不同膨胀率的连续空洞卷积组成串行空洞卷积模块,更有利于提取壁

画多光谱图像中的全局信息来提高分类精度,其结构如图 4 所示。

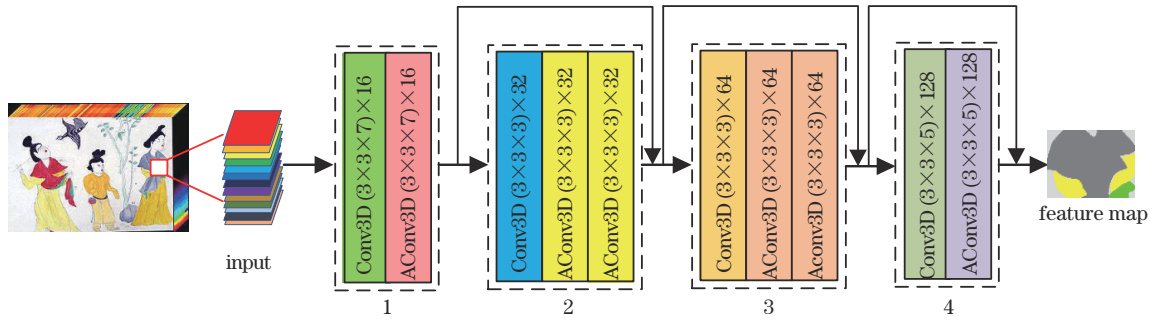


图 4 串行空洞卷积模块

Fig. 4 Sserial hole convolution module

串行空洞卷积模块共分为 4 个部分:第 1 部分包含 2 个卷积核大小均为 $3 \times 3 \times 7$ 、卷积核通道数为 16 的 3D 卷积层,其中 1 个为空洞卷积;第 2 和第 3 部分包含了 6 个大小为 $3 \times 3 \times 3$ 、卷积核通道数为 32 和 64 的 3D 卷积层,其中有 4 个为 3D 空洞卷积层;第 4 部分由 2 个卷积核大小为 $3 \times 3 \times 5$ 、通道数为 128 的 3D 卷积层组成,其中 1 个为空洞卷积层,所有卷积层的模式为 same,输出经过批归一化(BN)层之后使用 ReLU 函数激活。壁画多光谱数据经过空洞卷积后输出特征图长宽的表达式为

$$H_{out} = \frac{H_{in} + 2 \times p[0] - r[0] \times \{k[0] - 1\}}{\text{stride}[0]} + 1, (2)$$

$$W_{out} = \frac{W_{in} + 2 \times p[1] - r[1] \times \{k[1] - 1\}}{\text{stride}[1]} + 1, (3)$$

式中: H_{in} 和 W_{in} 分别为输入特征长宽; p 表示卷积模式为 same 的 0 填充数; k 表示卷积层卷积核的大小; r 表示空洞卷积的膨胀率;stride 为卷积步长,当设置步长大于 1 时也可以对特征降维,减少网络计算负荷提高计算效率。

3.2 多尺度特征融合模块

利用深度神经网络对壁画多光谱图像分类时,池化以及其他下采样操作会导致壁画图像部分边缘信息丢失,引入空洞卷积代替池化操作虽然可以避免信息的丢失,但串行空洞卷积随着网络层数加深膨胀率不断增大时,卷积核中的有效权值不断减少,当膨胀率足够大时,只有卷积核最中间的权重有效,即退化为 1×1 的卷积核。因此,本实验组设计了一种基于空间金字塔池化的多尺度特征融合模块,该模块利用不同膨胀率的并行空洞卷积结构代替传统的池化或者其他连续下采样操作,在不丢失特征的同时获得不同尺度上下文信息,更容易重建出边缘完整平滑的壁画颜料分类图像,其结构如图 5 所示。

多尺度特征融合模块包括一个卷积核大小为 1×1 的卷积层和卷积核大小均为 3×3 但膨胀率分别为 6、12、18 的 3 个空洞卷积,各层卷积核个数相同,输出通道数均为 256,输出步长为 2,且卷积层后含一个 BN

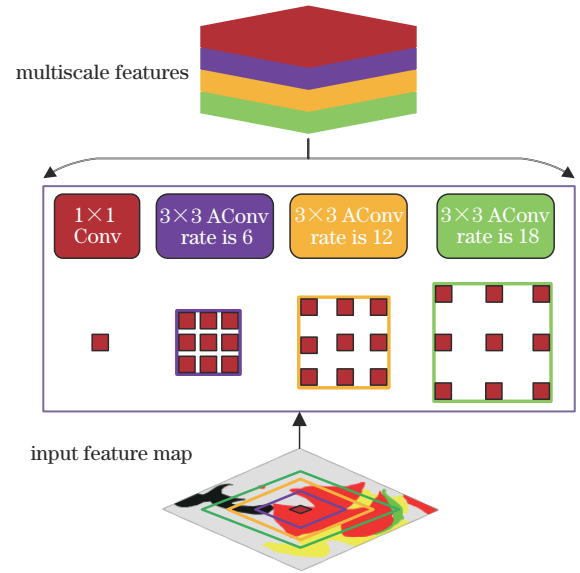


图 5 多尺度特征融合模块

Fig. 5 Multiscale feature fusion module

层。在对壁画多光谱图像的多尺度信息融合时,先采用不同膨胀率空洞卷积对输入特征图进行特征提取,再将提取的多尺度信息进行线性融合。进行特征提取时,第 n 个卷积的输出为

$$Y^n = W^n \times X^n + b^n, (4)$$

式中: X^n 为模块中第 n 个卷积的输入; W^n 为权值; b^n 为偏置。将 4 个并行卷积的输出 Y 线性相加融合为特征 C ,最后将多尺度信息 C 作为深层信息输入解码网络中。

3.3 整体网络模型

MFAC-Res3D-CNN 整体模型共由编码和解码两个主体构成,编码阶段首先将光谱立方体作为输入送入串行空洞卷积模块,并取出第 3 部分的输出特征图作为浅层特征信息送入解码阶段,此时特征图分辨率较低但包含较为完整的全局信息。经过连续采样的特征图送入多尺度融合模块后,分别与 4 个不同尺度的卷积核进行卷积操作,并将不同尺度的特征融合为特征 C ,再利用卷积核大小为 1×1 的卷积层对 C 调整通道后送入解码阶段。

解码阶段为了保证浅层特征与多尺度融合特征大小通道数均相同,对接收到的浅层特征 S 利用 1×1 卷积进行通道调整,同时利用双线性插值法对接收的多尺度融合特征进行 4 倍上采样,并将通道数和大小相

同的浅层特征 S 和多尺度融合特征 C 线性相加得到特征 A ,将 A 送入卷积大小为 3×3 的卷积层后,再经过 4 倍上采样恢复出与原图大小相同的预测图像。MFAC-Res3D-CNN 结构如图 6 所示。

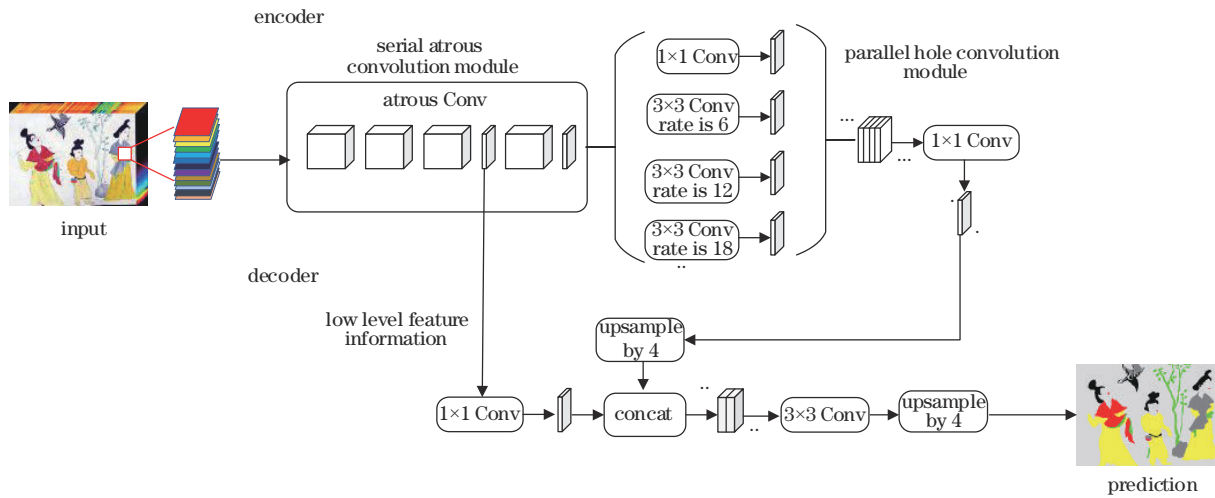


图 6 MFAC-Res3D-CNN 示意图
Fig. 6 Schematic of MFAC-Res3D-CNN

4 实验与结果分析

4.1 实验环境及实验数据

实验使用的硬件平台配置为 16 GB 运行内存、i5-9400F 处理器、GTX 2060 super 8 GB 显卡。软件平台均采用 Windows 系统下的 Python3. 6. 0 和谷歌深度学习开源库 TensorFlowGPU-1. 14. 0 实现。

壁画多光谱图像数据采集系统主要包括以下设备单元:PC 处理端、CCD 多光谱相机、16 个窄带干涉滤光片和 HL-2000 卤钨灯光源。壁画多光谱图像采集系统如图 7 所示。

为了验证所提算法的有效性,根据真实壁画绘制模拟壁画,利用壁画多光谱图像采集系统对模拟壁画进行多光谱图像数据采集,获取模拟壁画 16 个光谱通

道的多光谱图像数据。光谱覆盖范围为 400~900 nm,滤光片带宽为 50 nm,波段间隔基本为 20~40 nm,所获得的壁画多光谱图像经过配准操作后图像尺寸为 1370 pixel \times 1030 pixel。图 8 为各波段模拟壁画多光谱图像,模拟壁画图的伪彩色图和真值图像如图 9 所示。

数据集共对银朱 (Mercuric sulfide)、铬黄 (Chrome yellow)、青金石 (Lazurite) 等 6 种壁画颜料类别和 1 个背景类别进行了标注,其中标记的颜料类别共 539478 个像元,背景类别共 871622 个像元。表 1 给出了 6 种颜料和背景的像元详细信息。

4.2 参数设置

使用 SGD 优化器进行网络训练,初始的学习率设置为 0.001,学习率采用自适应调整。由于数据量有限,模型的 batch size 设置为 8,网络训练迭代次数设置为 50,Dropout 设置为 0.5。数据准备阶段,在整幅模拟壁画图像中随机选取中心点并裁取出 500 张 256 \times 256 的图像作为网络训练的输入图像,并随机打乱每类样本,确保实验数据的随机性。实验数据的训练集、测试集分配比例为 3:7。

4.3 评价标准

使用基于混淆矩阵中的总体精度(OA)、平均精度(AA)和 Kappa 系数等 3 个指标对壁画多光谱图像分类精度进行评价。混淆矩阵也称为误差矩阵,是用来表示精度评价的一种标准格式,用 n 行 n 列的矩阵形式来表示。在图像精度评价中,主要用于比较分类结果和实际测得值,可以把分类结果的精度显示在一个混淆矩阵里面。

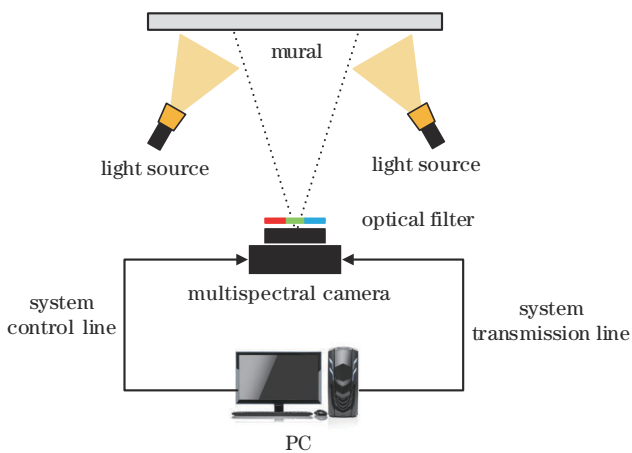


图 7 壁画多光谱图像采集系统

Fig. 7 Multispectral image acquisition system of murals

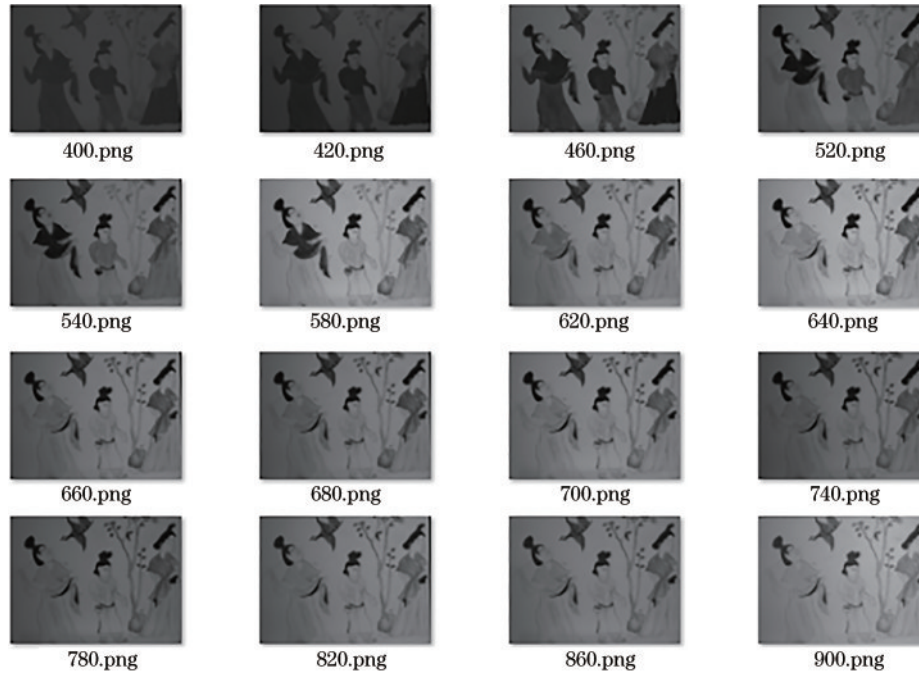


图 8 各波段壁画多光谱图像
Fig. 8 Multispectral images of murals in each band



图 9 模拟壁画。(a)模拟壁画图像;(b)伪彩色图像;(c)真值图像
Fig. 9 Simulated mural. (a) Simulated mural image; (b) pseudo color image; (c) truth image

表 1 模拟壁画多光谱图像数据集样本
Table 1 Sample of multispectral image dataset of simulated murals

Number	Category	Color	Number of samples
0	Background		871622
1	Mercuric sulfide		57778
2	Mineral green		49641
3	Chrome yellow		294816
4	Graphite		58765
5	Lazurite		77061
6	Minium		1417

OA 表示分类计算正确的像素数量与它们总像素数量之间的比率,其表达式为

$$A_{OA} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (5)$$

式中: N_{TP} 代表模型预测为真、实际也为真的数量; N_{TN} 代表模型预测为假,实际也为假的数量; N_{FP} 代表模型预测为真、实际为假的数量; N_{FN} 代表模型预测为假、实际为真的数量。

AA 表示模型对每一类计算正确的像素数量与该类总像素数量的比值,求和再平均的结果。

$$A_{AA} = \frac{\sum_{i=1}^n \frac{N_{TP_i}}{N_{TP_i} + N_{FN_i}}}{n}, \quad (6)$$

式中: n 代表样本类别总数。

Kappa 系数的计算是基于混淆矩阵的,一般用于一致性的检验,也可以用于衡量分类精度。Kappa 系数的取值范围为 $[-1, 1]$, 一般为正值,值越接近于 1, 代表算法分类性能就越好。所提模型的分混淆矩阵如表 2 所示。

表 2 所提模型分类混淆矩阵
Table 2 Classification confusion matrix of article model

Category	Background	Mercuric sulfide	Mineral green	Chrome yellow	Graphite	Lazurite	Minium
Background	865044	1036	1677	2548	1082	215	20
Mercuric sulfide	573	57166	22	17	0	0	0
Mineral green	1677	100	47859	5	0	0	0
Chrome yellow	2692	91	1	292031	0	1	0
Graphite	2049	0	7	136	56573	0	0
Lazurite	1452	0	22	52	18	75517	0
Minium	135	0	0	1	0	0	1281

4.4 实验分析

将所提算法与多光谱图像分类常见的 SVM、CNN 和 Res-3D-CNN 算法进行了比较。为了更好地对比分类效果,所有算法均使用相同的训练集、测试集

及验证集,对比实验数据集的分配比例也与所提算法相同。CNN 与 Res-3D-CNN 的 epoch 数、权值初始化、学习率及优化器的选择也均与所提算法相同。表 3 为 3 种算法在自建数据集上的分类精度比较。

表 3 数据集分类精度比较
Table 3 Comparison of dataset classification accuracy results unit: %

Category	SVM	2D-CNN	Res-3D-CNN	MFAC-Res3D-CNN
Background	84.36	97.49	97.34	99.24
Mercuric sulfide	92.36	91.05	95.43	98.94
Mineral green	78.53	92.34	94.25	96.41
Chrome yellow	88.53	99.32	97.50	99.05
Graphite	80.31	99.88	94.64	96.26
Lazurite	86.72	84.90	97.01	97.99
Minium	63.78	82.63	89.87	90.40
OA	84.72	91.45	97.57	98.87
AA	82.08	92.51	95.14	96.89
Kappa	78.60	89.98	95.41	98.04

由表 3 可知:在对壁画颜料多光谱图像分类时,CNN 通过多层次非线性的特征学习,OA、AA 和 Kappa 系数均优于传统的多光谱图像分类算法 SVM;而包含了 3D 卷积核的 Res-3D-CNN、MFAC-Res3D-CNN 的分类精度与 Kappa 系数均高于传统的 2D-CNN,这表明 3D 结构的卷积核相比于 2D 卷积核在针对高维数据特征提取时具有优势,更适用于壁画颜料多光谱图像分类问题。而在网络参数一致的情况下,

MFAC-Res3D-CNN 相较于 2D-CNN,OA、AA 和 Kappa 系数分别提升了 7.42 个百分点、4.38 个百分点和 8.06 个百分点,相较于 Res-3D-CNN,OA、AA 和 Kappa 系数分别提升了 1.3 个百分点、1.75 个百分点和 2.63 个百分点,说明空洞卷积和多尺度融合特征可以提高网络的分类性能。

图 10 和图 11 为各个不同对照组的分类效果图。从图中可以看出,传统的 SVM 算法分类效果明显差



图 10 不同网络分类结果对比。(a)真值图;(b) SVM;(c) 2D-CNN;(d) Res-3D-CNN;(e) MFAC-Res3D-CNN
Fig. 10 Comparison of different network classification results. (a) Truth image; (b) SVM; (c) 2D-CNN; (d) Res-3D-CNN; (e) MFAC-Res3D-CNN




图 11 不同网络分类细节对比。(a)真值图;(b) SVM;(c) 2D-CNN;(d) Res-3D-CNN;(e) MFAC-Res3D-CNN
 Fig. 11 Comparison of different network classification details. (a) Truth image; (b) SVM;(c) 2D-CNN;(d) Res-3D-CNN;
 (e) MFAC-Res3D-CNN

于神经网络。Res-3D-CNN、MFAC-Res3D-CNN 与 2D-CNN 的分类效果相比,前两者由于使用三维卷积核,错分情况要少于 2D-CNN。Res-3D-CNN 和 MFAC-Res3D-CNN 相比, MFAC-Res3D-CNN 的分

类边界更加清晰,像素分类精度更高,分类图像更加贴近真值图。表 4 为不同算法训练和测试时间对比。从表 4 可以看出,所提算法的训练和测试时间均有所增加。

表 4 不同算法训练和测试时间对比

Table 4 Comparison of training and testing time of different algorithms

unit: s

Time	SVM	2D-CNN	Res-3D-CNN	MFAC-Res3D-CNN
Train	678.5	1037.8	1265.6	1301.5
Test	7.98	10.75	15.95	17.05

5 结 论

研究了卷积神经网络在壁画多光谱图像分类中的应用,提出了一种基于多尺度特征融合和三维空洞卷积残差神经网络的壁画多光谱图像颜料分类方法。所提模型包含了编码和解码两个主要部分,编码部分通过引入串行空洞卷积模块,提高了壁画图像分类精度,使用多尺度特征融合模型,得到了边缘更清晰的分类图像,残差结构避免了网络结构加深时引起的梯度消失现象。在相同数据集中进行了 4 种分类方法的对比,实验结果表明,所提方法的 OA 达到 98.87%,AA 达到 96.89%,Kappa 系数达到了 98.04%,在对照实验中具有最好的分类精度,为实际应用古代壁画颜料多光谱图像分类提供了有效的方法。

虽然所提方法有效地提高了壁画多光谱颜料图像分类精度,但由于网络模型框架优化问题,空洞结构仍会提高网络计算复杂度,从而降低计算效率,使得网络模型训练和测试时间均有所增加。在下一步研究中,将利用深度可分离卷积结构,在模型框架不变的情况下降低参数数量提高计算效率,使其更适用于后期实

际应用工作。

参 考 文 献

- [1] 刘晓琴,侯妙乐,董友强,等. 基于高光谱影像的瞿县寺壁画颜料层脱落病害评估[J]. 地理信息世界, 2019, 26(5): 22-28.
Liu X Q, Hou M L, Dong Y Q, et al. Extraction and evaluation of the disease of the mural paint loss[J]. Geomatics World, 2019, 26(5): 22-28.
- [2] 李俊锋,万晓霞. 可见光谱法无损识别壁画文物矿物质颜料的研究[J]. 光谱学与光谱分析, 2018, 38(1): 200-204.
Li J F, Wan X X. Non-destructive identification of mineral pigments in ancient murals by visible spectroscopy[J]. Spectroscopy and Spectral Analysis, 2018, 38(1): 200-204.
- [3] 柴勃隆,肖冬瑞,苏伯民,等. 莫高窟壁画颜料多光谱数字化识别系统的研发与应用[J]. 敦煌研究, 2018(3): 123-130.
Chai B L, Xiao D R, Su B M, et al. Research and application of the multispectral digital system for identifying the pigments of Mogao murals[J]. Dunhuang Research, 2018(3): 123-130.
- [4] 徐文娟. 无损光谱技术在纸质文物分析中的应用研究进

- 展[J]. 文物保护与考古科学, 2012, 24(S1): 41-44.
- Xu W J. Research progress of non-destructive spectroscopic methods used on paper relics[J]. Sciences of Conservation and Archaeology, 2012, 24(S1): 41-44.
- [5] 周霄, 高峰, 张爱武, 等. VIS/NIR 高光谱成像在中国云冈石窟砂岩风化状况分布研究中的进展[J]. 光谱学与光谱分析, 2012, 32(3): 790-794.
- Zhou X, Gao F, Zhang A W, et al. Advance in the study of the powdered weathering profile of sandstone on China Yungang grottoes based on VIS/NIR hyperspectral imaging[J]. Spectroscopy and Spectral Analysis, 2012, 32(3): 790-794.
- [6] 包健, 厉小润. K均值算法实现遥感图像的非监督分类[J]. 机电工程, 2008, 25(3): 77-80.
- Bao J, Li X R. Unsupervised classification of remote images using K-mean algorithm[J]. Mechanical & Electrical Engineering Magazine, 2008, 25(3): 77-80.
- [7] 朱建华, 刘政凯, 俞能海. 一种多光谱遥感图像的自适应最小距离分类方法[J]. 中国图象图形学报, 2000, 5(1): 21-24.
- Zhu J H, Liu Z K, Yu N H. Remote sensing image classification using an adaptive Min distance algorithm[J]. Journal of Image and Graphics, 2000, 5(1): 21-24.
- [8] 王燕妮, 朱丹娜, 王慧琴, 等. 基于卷积神经网络的壁画颜料多光谱图像分类[J]. 激光与光电子学进展, 2019, 56(22): 221001.
- Wang Y N, Zhu D N, Wang H Q, et al. Multispectral image classification of mural pigments based on convolutional neural network[J]. Laser & Optoelectronics Progress, 2019, 56(22): 221001.
- [9] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015, 2015: 258619.
- [10] Yang J X, Zhao Y Q, Chan J C W, et al. Hyperspectral image classification using two-channel deep convolutional neural network[C]//2016 IEEE International Geoscience and Remote Sensing Symposium, July 10-15, 2016, Beijing, China. New York: IEEE Press, 2016: 5079-5082.
- [11] Zhong Z L, Li J, Luo Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 847-858.
- [12] 杨州, 慕晓冬, 王舒洋, 等. 基于多尺度特征融合的遥感图像场景分类[J]. 光学精密工程, 2018, 26(12): 3099-3107.
- Yang Z, Mu X D, Wang S Y, et al. Scene classification of remote sensing images based on multiscale features fusion[J]. Optics and Precision Engineering, 2018, 26(12): 3099-3107.
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [14] 赵扬, 杨清洁. 基于改进的三维卷积神经网络的高光谱遥感影像分类技术研究[J]. 信息技术与网络安全, 2019, 38(6): 46-51.
- Zhao Y, Yang Q J. Research on hyperspectral remote sensing image classification based on 3D convolutional neural network[J]. Information Technology and Network Security, 2019, 38(6): 46-51.
- [15] 李冠东, 张春菊, 高飞, 等. 双卷积池化结构的 3D-CNN 高光谱遥感影像分类方法[J]. 中国图象图形学报, 2019, 24(4): 639-654.
- Li G D, Zhang C J, Gao F, et al. Double convpool-structured 3D-CNN for hyperspectral remote sensing image classification[J]. Journal of Image and Graphics, 2019, 24(4): 639-654.
- [16] 刘冰, 余旭初, 张鹏强, 等. 联合空-谱信息的高光谱影像深度三维卷积网络分类[J]. 测绘学报, 2019, 48(1): 53-63.
- Liu B, Yu X C, Zhang P Q, et al. Deep 3D convolutional network combined with spatial-spectral features for hyperspectral image classification[J]. Acta Geodaetica et Cartographica Sinica, 2019, 48(1): 53-63.
- [17] Singh G, Mittal A, Aggarwal N. ResDNN: deep residual learning for natural image denoising[J]. IET Image Processing, 2020, 14(11): 2425-2434.
- [18] 颜铭靖, 苏喜友. 基于三维空洞卷积残差神经网络的高光谱影像分类方法[J]. 光学学报, 2020, 40(16): 1628002.
- Yan M J, Su X Y. Hyperspectral image classification based on three-dimensional dilated convolutional residual neural network[J]. Acta Optica Sinica, 2020, 40(16): 1628002.
- [19] 廖明哲, 吴谨, 朱磊. 基于 ResNet 和 RF-Net 的遥感影像匹配[J]. 液晶与显示, 2020, 35(9): 972-980.
- Liao M Z, Wu J, Zhu L. Remote sensing images matching based on ResNet and RF-Net[J]. Chinese Journal of Liquid Crystals and Displays, 2020, 35(9): 972-980.