基于树皮纹理特征识别的木材分类

王军敏,孙晓延

(平顶山学院 信息工程学院,河南 平顶山 467036)

摘 要:为了利用树皮的纹理特征对木材的种类进行识别,分别提出了基于手工设计的方法和基于深度学习的方法.基于手工设计的方法分别提取树皮纹理图像的精细纹理特征和粗略颜色信息,并用最近子空间分类器(Nearest Subspace Classifier,NSC)对提取的特征进行分类;基于深度学习的方法利用 VGG-16 模型预先设定训练的参数,并利用现有的纹理图像样本对模型进行微调,从而获得最佳的树皮纹理图像识别模型.最后,在New-BarkTex 树皮纹理库上进行仿真实验,实验结果表明这两种方法都取得了良好的识别效果,尤其是基于深度学习的方法具有更好的识别性能.

关键词:纹理图像识别;特征提取;树皮纹理;木材分类

中图分类号:TP391.413

文献标识码:A

文章编号:1673-1670(2021)05-0054-05

0 引言

纹理图像广泛存在于大自然中,在工业生产和 人类的日常生活中也处处可见,这使得纹理图像识 别技术具有广泛的应用领域和重要的应用价 值[1]. 例如,纹理特征是树皮表面最显著的视觉特 征,这些纹理特征是树木所具有的天然属性,可以 在一定程度上描述树木的性质. 因此,利用纹理图 像识别技术对树皮的纹理特征进行识别,可带来多 方面的益处,例如:1)森林中的树木种类非常繁 多,要对这些树木的种类进行准确识别需要进行相 关的专业学习和长期的经验积累,考虑到不同种类 的树木具有不同的树皮纹理特征,并目这些树皮纹 理特征具有很强的鉴别能力,因此,利用树皮的纹 理特征对树木的种类进行快速识别,能够帮助护林 人员快速、方便地识别森林中的树木种类:2)有助 于木材厂对木材进行工业化的自动分类,提高木材 分类的效率;3)对质量较好的木材,其树皮的纹理 特征通常呈现较好的规律性,而质量较差的木材可 能在树皮表面出现疤痕或凸凹,这些树皮表面的缺 陷会破坏原有的纹理规律特性,通过检测这些非正 常的纹理模式,可以对木材的品质进行辅助鉴定.

研究方法

笔者通过对树皮的纹理特征进行识别来实现

木材分类,提出如下两种方法:1)利用手工设计 (hand-crafted)的方法实现树皮纹理特征的提取和分类;2)利用深度学习(deep-learning)的方法自动提取树皮纹理图像的特征并实现分类.下面分别展示这两种方法的基本原理和实现方法.

1.1 方法一:手工设计方法

方法一首先利用手工设计的特征描述子分别 提取树皮纹理图像的粗略颜色信息和精细纹理特征,然后将这两种特征进行融合,最后送入手工设 计的特征分类器实现树皮纹理图像的识别.该方法 的基本原理如图 1 所示,具体的实现步骤如下:

Step 1 颜色特征空间转换. 将树皮的彩色纹理图像转换到 HSV 颜色空间,获得亮度分量 V、色调分量 H 和饱和度分量 S,其中,V 分量用于描述灰度纹理特征,H 和 S 分量用于描述颜色信息,从而实现了灰度纹理特征和颜色信息的分离,以便分别提取灰度纹理特征和颜色信息.

Step 2 精细纹理特征提取. 对 V 分量图像进行多次高斯滤波,从而构建 V 分量的多尺度空间. 然后利用式 (1) 分别计算每个高斯滤波图像的 S_{CLBC} M_{CLBC} 和 C_{CLBC} 分量 [2],即:

$$S_{\text{CLBC}} = \sum_{p=0}^{P-1} s(g_p - g_e),$$

$$M_{\text{CLBC}} = \sum_{p=0}^{P-1} s(m_p - c_m),$$

$$C_{\text{CLBC}} = s(g_e - c_I).$$
(1)

收稿日期:2021-01-30

基金项目:河南省科技厅科技攻关项目(202102210331)

作者简介:王军敏(1982—),男,河南省平顶山市人,工学博士,平顶山学院信息工程学院讲师,主要从事图像识别、机器学习研究.

其中, g_e 表示局部环形邻域中心点的灰度值, $g_p(p=0,1,\cdots,P-1)$ 表示 P 个邻域点的灰度值, $m_p=|g_p-g_e|$ 表示邻域点与中心点的灰度差, c_m 表示整个图像中 m_p 的均值, c_I 表示整个图像的平均灰度值, $s(x)=\begin{cases} 1,x\geq 0\\ 0,x<0 \end{cases}$ 表示阈值函数. 接着计算 3 个分量 S_{CLBC} 、 M_{CLBC} 和 C_{CLBC} 的联合直方图 CLBC_S/M/C,并对多个尺度的 CLBC_S/M/C 直方图按模式跨尺度取最大值. 最后将多个半径的最大直方图特征进行级联. 将其作为原始纹理图像的

光照、旋转和尺度稳健的精细纹理特征.

Step 3 粗略颜色信息提取. 将色调分量 H 和饱和度分量 S 进行粗略量化,并计算粗略量化后 H 分量和 S 分量的联合直方图,将其作为树皮纹理图像的粗略颜色信息.

Step 4 特征融合与分类. 最后将所提取的粗略颜色信息与灰度纹理特征进行融合,作为树皮纹理图像的最终特征描述,并送入 NSC 分类器^[3] 获得树皮纹理图像的类别标签.

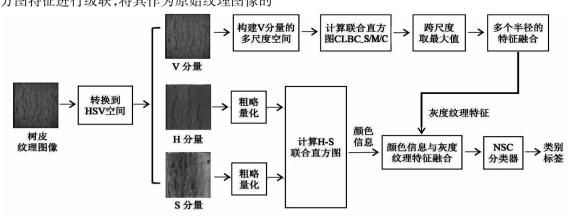


图 1 手工设计方法的基本原理

1.2 方法二:深度学习方法

近年来,深度学习方法成为图像识别领域的研究热点.其中,深度卷积神经网络(Convolutional Neural Network,CNN)是深度学习方法在图像识别领域获得成功应用的方法之一,它能够模拟人脑分层提取特征的机制,自动从样本中提取对分类有用的特征.但是,从头开始训练一个深度 CNN 模型存在以下不足之处:1)需要大规模的训练样本,以便对模型进行充分的训练,否则模型的识别性能不佳,但目前还没有一个大规模的纹理图像数据库,无法对深度 CNN 模型进行充分的训练;2)从头训练一个深度 CNN 模型进行充分的训练;2)从头训练一个深度 CNN 模型非常耗时;3)对硬件平台的计算能力和存储容量要求很高,而高性能的硬件平台通常价格昂贵.

为了解决深度 CNN 方法存在的不足,笔者采用在大规模图像数据集 ImageNet 上预先训练的 VGG-16 模型作为基础模型. VGG 模型^[4] 是 2014 年由牛津大学视觉几何组 (Visual Geometry Group, VGG)和 Google DeepMind公司研究员共同提出的, VGG 模型的结构是一种级联型的直筒结构,形式非常简洁. VGG-16 模型包含 13 个卷积层和3个FC层,即一共有16个卷积/FC层. 其中,前面的卷积层用于提取不同层次的图像特征,后面的

FC 层用于特征降维并输出分类概率.

笔者提出的基于深度 CNN 的系统结构如图 2 所示:首先利用 VGG-16 模型的卷积模块提取输入 纹理图像的特征,在训练阶段需要利用现有的纹理 图像样本对卷积模块的参数进行微调;然后再对卷 积模块提取的特征进行降维和分类识别,从而获得输入样本的类别标签.

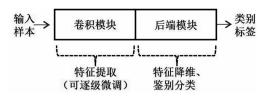


图 2 深度学习方法的系统结构

为了将 VGG-16 模型应用于树皮纹理图像的识别,并降低原始 VGG-16 模型的参数规模,笔者对原始 VGG-16 模型的结构进行改进,主要包括: 1) 用全局平均池化(Global Average Pooling,GAP) 层代替 FC 层,显著降低模型的参数规模;2) 仅在最后使用一个 FC 层,将输出端的个数调整为待识别纹理图像的类别个数,并用 Softmax 层输出范围为(0,1) 的分类概率值. 笔者构建的深度 GNN模型如表 1 所示:第 0 层是输入层,用于输入纹理图像;第 1~18 层为 VGG-16 模型前面的 5 个卷积模

· 56 ·

块, 其主要作用是提取输入图像的特征, 这些卷积 模块的参数已经在 ImageNet 图像数据集上经讨了 充分的预训练,已经具备了初步的特征提取能力: 第19~21 层用于特征降维,将输出端的个数调整 为目标类别的个数,并输出当前样本对所有类别的 归属概率值,根据分类概率值的大小,即可判断当 前样本所属类别的类别标签,

表 I 床皮 GNN 模型的方层结构							
层号	层名称	说明	层号	层名称	说明	_	
0	input_layer	输入层	11	block4_conv1	模块 4 卷积层 1		
1	block1_conv1	模块1卷积层1	12	block4_conv2	模块 4 卷积层 2		
2	block1_conv2	模块1卷积层2	13	block4_conv3	模块4卷积层3		
3	block1_maxpool	模块1最大池化层	14	block4_maxpool	模块 4 最大池化层		
4	block2_conv1	模块2卷积层1	15	block5_conv1	模块5卷积层1		
5	block2_conv2	模块2卷积层2	16	block5_conv2	模块5卷积层2		
6	block2_maxpool	模块2最大池化层	17	block5_conv3	模块5卷积层3		
7	block3_conv1	模块3卷积层1	18	block5_maxpool	模块5最大池化层		
8	block3_conv2	模块3卷积层2	19	GAP	全局平均池化层		
9	block3_conv3	模块3卷积层3	20	FC	输出分类得分值		
10	block3_maxpool	模块 3 最大池化层	21	Softmax	输出分类概率值		

深度 CNN 模型的分层结构

方法二的具体实现步骤如下:

对输入图像进行预处理,即输入图像 的 RGB 三个诵道分别减去 103.939.116.779. 123.680,并调整图像尺寸为224 × 224 像素.

Step 2 对训练样本进行数据增强(包括旋 转、缩放等),扩充训练样本的数量.

设置模型的初始超参数值,包括优化 器、学习率、批尺寸、损失函数等.

利用数据增强后的树皮纹理图像训 Step 4 练集对模型的参数进行微调训练. 当模型在验证集 上获得最佳结果时,保留此时的 CNN 模型参数.

利用训练所得的最佳 CNN 模型,对 测试样本进行测试,获得识别结果.

2 树皮纹理库和实验设置

为了评估笔者所提出方法的性能,利用 BarkTex 纹理库^[5] 提供的树皮纹理图像进行实验. BarkTex 纹理库由 6 个类别的树皮纹理图像组成, 即白桦树、山毛榉、挪威云杉、银松、栎树和槐树的 树皮纹理图像. 每个类别有68个样本图像,一共有 6×68 = 408 个样本图像,分辨率为 128×192 像 素. 图3展示了BarkTex纹理库的6个树皮类别,每 列是一个树皮类别的3个样本图像.从图3可以看 出,不同类别的树木,其树皮的纹理特征具有显著 的差异,因此,利用树皮的纹理特征对树木的种类 进行鉴别具有可行性.

由于 BarkTex 纹理库的原始样本个数较少,为 了方便开展实验,将每个原始的树皮纹理图像划分

为4个子图像,将其作为同一个类别的4个新的树 皮纹理样本,从而增加了树皮纹理样本的个数,从 而构建一个新的 BarkTex 纹理库.即 New-BarkTex 纹理库[5]. 在 New-BarkTex 纹理库中,同样含有 6 个树皮类别,每个类别含有68×4 = 272个子图像, 一共有272×6=1632个子图像,即1632个样本, 每个样本的图像分辨率为64×64像素. 在训练模 型时,用一半(816个)样本作为训练数据.

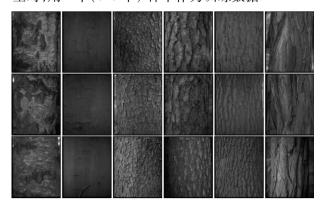


图 3 BarkTex 纹理库 6 个类别的树皮纹理图像

实验平台: 计算机 (Intel Core i5 CPU@3.10 GHz,16 GB RAM), Python 3.5, Tensor Flow 1.15.0, Keras 2.0, MATLAB R2016b 仿真软件.

在方法一中,树皮纹理图像特征提取系统的具 体参数设置为:高斯滤波次数n=2,高斯滤波器的 尺寸为 11 × 11 像素, 高斯滤波器的标准 $\sigma = 1.7$, CLBC 算法的参数 R = [1,3,5], P = [1,3,5][8,16,24].

在方法二中,超参数的初始设置为:1) 在数据

增强时,设最大缩放因子为 0.2 倍、最大旋转角度 为 60°;2)选择 Adam 算法作为优化器;3)初始学 习率设为 0.001,最大训练轮数设为 50,批尺寸设 为 10;4)模型的损失函数采用分类交叉熵函数.

3 实验与结果分析

3.1 最佳参数的确定

在方法一中,在对表示颜色信息的 H 分量和 S 分量进行粗略量化时,需要确定最佳的颜色量化等级. 因此,在 New-BarkTex 纹理库上进行实验,设色调分量 H 和饱和度分量 S 的量化等级个数为 L_e ,通过改变 L_e ,分别获得不同量化等级下的纹理识别精度.由于本文方法对颜色信息采用粗略量化的策略,所以主要分析 L_e 在区间[1,70] 的纹理识别精度,实验结果如图 4 所示.

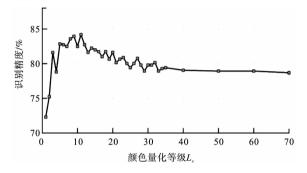


图 4 不同颜色量化等级对应的纹理识别精度

从图 4 可以看出:1) 当颜色量化等级个数 L_c = 11 时,方法一在 New-BarkTex 树皮纹理库上 获得最高的识别精度84.31%,表明此时对颜色信 息的量化程度最佳,这也体现出彩色纹理图像中颜 色信息呈现区域性分布,具有较低的空间频率,只需 进行粗略量化即可;2) 当颜色量化等级个数L。<11 时,随着 L。的不断增大,生成的颜色组合种类逐渐 增多,使得方法一的纹理识别精度快速提升,但此 时纹理识别精度仍没有达到最高,这是因为此时的 L_c 仍然偏小,生成的颜色组合种类仍然较少,还不 足以充分描述彩色纹理图像中的颜色信息;3) 当 颜色量化等级个数 $L_c > 11$ 时,方法一的纹理识别 精度呈现下降的趋势, 当L。>40 时识别精度基本 保持不变,继续增大L。的值并没有带来识别精度 的提高,这表明对颜色的过细量化是没有必要的, 并且过细量化会增大计算量. 综上所述, 为了同时 获得好的识别精度和实时性,方法一选择最佳的颜 色量化等级个数 $L_c=11$,即把色调分量 H 和饱和 度分量 S 都量化为 11 个等级.

在方法二中,用于提取图像特征的卷积模块可 逐级微调,以便在训练过程中获得最佳的深度 CNN 模型. 在微调训练 CNN 模型时,首先需要确定需冻结的层数 N,即对 N 层及其之前的层进行冻结(这些层的可训练属性设为 Trainable = False),只微调训练 N 层之后的模型参数(这些层的可训练属性设为 Trainable = True). 对于笔者构建的 CNN模型,以卷积模块为基本单位进行微调,从表 1 可以看出,第 1 层至第 18 层一共有 5 个卷积模块,对应的冻结层数为 N = 0,3,6,10,14,18. 不同的冻结层数 N 对应不同的可训练卷积模块个数:例如,当 N = 0 时,表示对全部 5 个卷积模块进行微调训练;而当 N = 18 时,表示将全部 5 个卷积模块的参数进行冻结. 在 New-BarkTex 树皮纹理库上开展实验,不同的冻结层数对应的测试集识别精度如表 2 所示.

表 2 不同的冻结层数对应的测试集识别精度

	** ** *** ****
冻结层数 N	测试集识别精度/%
0	91.34
3	91.50
6	93.46
10	92.81
14	91.18
18	59.80

从表 2 可以看出: 当冻结层数 N=6 时,模型的性能达到最佳,此时能获得最高的识别精度93. 46%; 当 N=18 时,全部的卷积模块都被冻结,仅能调节模型最后 FC 层的参数,此时的识别精度较差,仅为 59. 80%. 这表明将 VGG-16 模型的初始参数直接用于纹理图像识别不能取得好的识别结果,必须利用现有的纹理图像样本对 CNN 模型的参数进行微调训练,才能使模型获得更好的纹理图像识别能力. 所以,笔者选择最佳的冻结层数为 N=6.

3.2 实验结果分析

为了进一步展示本文方法的性能,将笔者提出的两种方法与其他先进的算法进行对比,它们在New-BarkTex 纹理库上的识别精度如表 3 所示.

从表3可以看出:1)笔者提出的两种方法分别取得了84.31%和93.46%的识别精度,一致超过了其他方法的识别精度.这表明本文方法能够很好地提取树皮表面的纹理特征,具有很强的鉴别能力.2)笔者所提出的手工设计方法和深度学习方法相比,深度学习方法取得了93.46%的识别精度,显著超过了手工设计方法84.31%的识别精度.这体现出深度学习方法具有更强的识别能力.

表 3 在 New-BarkTex 纹理库上的识别精度

对比方法	识别精度 /%
RGB-DRLBP ^[6]	70.83
Porebski, et al. [5]	75.90
NLBP-HSS ^[7]	81.37
$3\text{D-ASDH}^{[8]}$	82.10
Kabbai, et al. [9]	76.60
方法一	84.31
方法二	93.46

另外,New-BarkTex 纹理库中的树皮纹理图像的尺寸非常小,只有64×64像素,所含的纹理信息比较有限,并且容易受到树皮表面缺陷(例如:疤痕或凸凹)特征的干扰,这在一定程度上限制了对木材种类的识别精度.因此,在实际的工程应用中,可以采集更大尺寸的树皮纹理图像(例如:100×100像素、200×200像素),以便进一步提高识别精度,使本文方法在木材分类中具有更好的应用价值.

4 结论

笔者通过对树皮纹理图像的识别实现了木材分类,具有重要的应用价值.同时,笔者分别采用手工设计方法和深度学习方法实现木材分类,并对这两种方法的性能进行了对比分析,展示了深度学习方法在图像识别领域的巨大优势,为进一步解决复杂的纹理图像识别问题提供了新的发展思路.

参考文献:

- [1]刘丽,赵凌君,郭承玉,等. 图像纹理分类方法研究进展和展望[J]. 自动化学报,2018,44(4):584-607.
- [2] ZHAO Y, HUANG D S, JIA W. Completed local binary count for rotation invariant texture classification [J]. IEEE Transactions on Image Processing, 2012, 21 (10):4492 – 4497.
- [3] GUO Z H, WANG X Z, ZHOU J, et al. Robust texture image representation by scale selective local binary patterns [J]. IEEE Transactions on Image Processing, 2016, 25(2):687-699.
- [4] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. San Diego: 3rd International Conference on Learning Representations, 2015.
- [5] POREBSKI A, VANDENBROUCKE N, MACAIRE L, et al. A new benchmark image test suite for evaluating colour texture classification schemes [J]. Multimedia Tools and Applications, 2014, 70;543 556.
- [6] MEHTA R, EGIAZARIAN K. Dominant rotated local binary patterns (DRLBP) for texture classification [J]. Pattern Recognition Letters, 2016, 71:16 22.
- [7] KALAKECH M, POREBSKI A, VANDENBROUCKE N, et al. A new LBP histogram selection score for color texture classification [C]. Orléans:5th International Conference on Image Processing Theory, Tools and Applications, 2015: 242 – 247.
- [8] SANDID F, DOUIK A. Robust color texture descriptor for material recognition [J]. Pattern Recognition Letters, 2016, 80:15-23.
- [9] KABBAI L, ABDELLAOUI M, DOUIK A. Image classification by combining local and global features [J]. The Visual Computer, 2019, 35:679 - 693.

(责任编辑:王彦江)

Wood Classification Based on Recognition of Bark Texture Feature

WANG Junmin, SUN Xiaoyan

(School of Information Engineering, Pingdingshan University, Pingdingshan, Henan 467036, China)

Abstract: To implement wood classification based on the recognition of bark texture feature, this paper proposes a hand-crafted-feature based method and a deep-learning based method, respectively. The hand-crafted-feature based method first extracts the fine texture features and coarse color information, and then discriminates the extracted features by nearest subspace classifier to classify the wood. The deep-learning based method uses the pre-trained VGG-16 model, and then fine-tunes the model with the bark texture images to obtain the best model. The experimental results on the New-BarkTex database demonstrate that the proposed method can achieve high performance in terms of recognition accuracy, with superior performance of the deep learning based method.

Key words: texture image recognition; feature extraction; bark texture; wood classification