



移动扫码阅读

王培珍,余晨,薛子邯,等.基于迁移学习的煤岩壳质组显微组分识别模型[J].煤炭科学技术,2022,50(1): 220-227.

WANG Peizhen, YU Chen, XUE Zihan, *et al.* Transfer learning based identification model for macerals of exinite in coal[J]. Coal Science and Technology, 2022, 50(1): 220-227.

基于迁移学习的煤岩壳质组显微组分识别模型

王培珍^{1,2,3}, 余晨¹, 薛子邯¹, 张代林⁴

(1.安徽工业大学 电气与信息工程学院 安徽 马鞍山 243032; 2.安徽工业大学 工程实践与创新教育中心; 3.安徽工业大学 煤的洁净转化与综合利用安徽省重点实验室; 4.安徽工业大学 冶金减排与资源综合利用教育部重点实验室, 安徽 马鞍山 243032)

摘要:为了提高煤岩壳质组显微组分的识别准确率,避免分类器构建中特征提取阶段的人工干预,采用深度学习的方法实现煤岩壳质组显微组分类别的自动识别。由于煤岩壳质组样本数有限,采用传统的卷积神经网络构建分类器对其识别容易产生过拟合,泛化能力较差。为解决该问题,提出了一种基于迁移学习的煤岩壳质组显微组分识别模型(分类器)。该模型在传统的卷积神经网络模型基础上,通过迁移学习共享预训练网络模型中卷积层和池化层的权值系数,并结合煤岩壳质组显微图像样本,优化网络模型结构和全连接层参数,进而构建适合于煤岩壳质组显微组分识别的深度学习网络模型。试验结果表明:与由传统神经网络直接构成的深度学习模型相比,本文构建的基于迁移学习的煤岩壳质组识别模型性能和效果均明显提高,尤其是以 VGG16 作为预训练模型构建的分类器在本文数据集上性能表现最优,其对测试样本识别准确率可达 98.10%;由于模型的训练参数减少,模型的训练时间明显缩短,且在较短的训练周期内达到收敛且训练集的识别准确率保持稳定,表明了以 VGG16 作为预训练模型的分类器在煤岩壳质组识别中具备较好的性能,更适合于小样本数据集的识别。

关键词:煤;显微组分;壳质组;迁移学习;卷积神经网络

中图分类号:TP391.4;TQ533.6

文献标志码:A

文章编号:0253-2336(2022)01-0220-08

Transfer learning based identification model for macerals of exinite in coal

WANG Peizhen^{1,2,3}, YU Chen¹, XUE Zihan¹, ZHANG Dailin⁴

(1.School of Electrical Engineering & Information, Anhui University of Technology, Maanshan 243032; 2.Engineering Practice and Innovation Center Anhui University of Technology, Maanshan 243032, China; 3.Anhui Key Laboratory of Clean Conversion and Utilization, Anhui University of Technology, Maanshan 243032, China; 4.Key Laboratory of Metallurgical Emission Reduction & Resources Recycling Ministry of Education, Anhui University of Technology, Maanshan 243032, China)

Abstract: To improve the identification accuracy of exinite macerals in coal and avoid the manual intervention in the feature extraction stage of classifier construction, the deep learning method was employed for the automatic identification of macerals of exinite in coal. Owing to the limiting of sample number of exinite maceral in coal, the classifier constructed with the conventional convolutional neural network tends to be over-fitting and the poor generalization ability. To solve this problem, an identification model (classifier), which is based on transfer learning, was proposed. Based on conventional convolution neural network model, this method shared the weight parameters of convolution layer and pooling layer with the pre-training network model by transfer learning, optimized the network model structure and full connection layer parameters with samples of exinite macerals, and constructed a new deep learning network model for the maceral identification of exinite of coal. The experimental results show that, compared with that of the conventional neural network, the transfer learning based identification model proposed in this paper is more effective, and the classifier with VGG16 as pre-training network is of best performance on this dataset, with identification accuracy of 98.10% for test samples; owing to the reduction of parameter number, the training time is obviously shortened, and the convergence is achieved in a short training period with a stable identification accuracy, indi-

收稿日期:2021-10-12; **责任编辑:**郭鑫

基金项目:国家自然科学基金资助项目(51574004);安徽省教育厅自然科学研究重点资助项目(KJ2019A0085);安徽省高校学科拔尖人才学术重点资助项目(gxbjZD2016041)

作者简介:王培珍(1966—),女,安徽泾县人,教授,博士,研究生导师。Tel: 0555-2315690, E-mail: pzhwang@ahut.edu.cn

cating that the classifier based on VGG16 as the pre training model has better performance in the identification of macerals of exinite in coal, and is more suitable for the identification of small sample data sets. The proposed approach can be applied to classification or identification of other macerals of coal that also belong to small samples.

Key words: coal; maceral; exinite; transfer learning; convolution neural network

0 引言

煤岩显微组分的组成影响煤的反应性、热破碎性质、黏结性和对 CO 的吸附性等^[1-2]。壳质组是煤岩三大组别之一,实现对煤岩壳质组中显微组分的自动分类与识别对煤的清洁高效利用具有重要意义^[3-4]。目前国内外对于煤岩显微组分识别大多采用人工观测法,自动化程度低,结果易受主观因素影响。针对上述问题,已有研究者尝试采用图像处理技术对煤岩显微组分进行分析与识别,如: BRIENA 等^[5]利用反射光与 SEM 图像系统测量煤显微组分区域面积等参量; SKIBA 等^[6]提出一种结合多层感知机和 Haralick 纹理特征的煤岩惰质组显微组分识别方法。笔者课题组也对煤岩显微组分自动识别作了一定的研究^[7-11],分别采用多重分形去趋势波分析、轮廓波变换等方法对煤岩显微图像的纹理特征进行分析,进一步采用主成分分析法(PCA)、局部保留投影(SLPP)等对特征量进行抽取,并构建基于径向基函数的支持向量机(RBF-SVM),使用极限学习机等分类器对煤岩显微组分进行分类,并取得了一定的效果。但是采用这些方法提取煤岩显微组分特征量需要大量的人工参与,难以实现完整的自动分类。

卷积神经网络能自动学习图像特征从而可以避

免传统方法中特征提取环节的人工参与。2012 年 AlexNet 网络在 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)中的卓越表现确立了深度学习在计算机视觉领域中的地位^[12],此后新的卷积神经网络优化模型陆续出现,典型的如 VGG 网络模型^[13]、GoogleNet 模型^[14]及 ResNet 模型^[15]等,其在大型数据集 ImageNet 上识别准确率不断提高。由于煤岩显微组分样本数较少,由此独立地训练上述网络模型易产生过拟合,难以达到预期效果。迁移学习可以利用在大型数据集上已经训练好的网络参数根据目标数据集进行再次优化,对小样本数据识别问题是较好的解决方案。基于此,采用深度学习技术构建预训练网络模型,在 ImageNet 数据集上完成预训练网络的训练,结合煤岩壳质组显微组分样本对模型进行迁移学习,实现壳质组显微组分特征量的自动提取,由此实现对煤岩壳质组显微组分的自动识别。

1 特征分析及数据集的构建

依据煤岩显微组分的分类标准^[3],壳质组共含 10 种显微组分,其中某些组分较为罕见。因此,选择较为典型的孢粉体、角质体、沥青质体、木栓质体、树皮体、碎屑壳质体和藻类体 7 种显微组分为研究对象,其在油浸反光下典型显微图像^[16]如图 1 所示。




图 1 部分壳质组分反射光下显微图像

Fig.1 Microscopic images of some exinite macerals under reflected light

由图 1 所知,孢粉体含大孢子体、小孢子体 2 类亚显微组分,大孢子体多为压扁长环形,呈封闭状态,小孢子体呈扁环形、蠕虫状等(图 1a);角质体多呈长条状,且外缘平滑、内缘呈锯齿状(图 1b);沥青质体来源于藻类、细菌等降解物,常分布于其他组分之间,没有固定的形态和结构(图 1c);木栓质体常为叠瓦状(图 1d);树皮体多呈扁平的长方形,排列比较规则(图 1e);碎屑壳质体大多呈棱角状或不规

则形态(图 1f);藻类体呈纺锤形或不规则形态(图 1g)。壳质组中不同显微组分形态各不相同,亮度、纹理具有一定差异,但某些类别间又存在一定的相似性,若用传统方法从亮度、纹理、形状等角度提取特征信息,存在大量信息冗余,特征量间存在较强的相关性,影响识别准确率。

鉴于此,选取壳质组 7 种类显微组分共 315 幅显微图像作为样本,从中随机抽取 210 幅构成训练

集,其余 105 幅为测试集。由于训练集样本数有限,采用数据增强技术对样本数据进行扩充,用于迁移学习的参数再次训练。根据样本特点,扩充主要采用随机缩放、随机平移等方法,扩充后的训练样本集图像数为 1 260 幅。

2 网络模型的构建

2.1 迁移学习

深度学习是一类含有多隐藏层、多感知器的网络结构,通过多层处理对外部输入的数据进行更抽象、更深层次的特征提取与表示,更适合于完成复杂的分类任务^[17]。卷积神经网络作为深度学习重要方法之一,在解决拥有大数据集的图像分类与识别问题时具有明显优势;但对于小样本条件,样本数据量不足其训练出的分类器易过拟合,且较差。迁移学习可以将在大型数据集上训练完成的网络模型,结合新的数据集经过微小的修改与调整,在另一数据集上得到模型权重参数的复用^[18]。

迁移学习的方法主要有 2 类:特征迁移和模型微调。特征迁移方法在训练新的模型时,移除在大型数据集上训练好的预训练模型网络的最后一层,将预训练模型卷积基(池化层和卷积层)中所提取的特征向量移植至新的分类器进行训练。模型微调方法需要新的数据集上重新训练分类器,且在预训练好的网络模型上微调网络的权值;为防止过拟

合,该方法仅对靠近顶部的权值进行微调,其优点在于可大幅度降低时间消耗;模型经由大数据集预训练,具备较强的泛化能力。

因此,采用微调模型迁移学习方法构建分类器,对煤岩壳质组显微组分进行分类识别。

2.2 预训练网络模型的选择

卷积神经网络的基本结构^[19]由输入层、卷积层、池化层、全连接层及输出层构成。卷积层为特征提取层,通过图像与卷积核的卷积运算实现。池化层对由卷积得到的特征图进行降维,减少计算量。全连接层将由卷积层和池化层学习得到的特征量映射至样本的标记空间,最终经过 Softmax 分类器计算出各样本所属类别的概率。

模型构建阶段的重点工作是在预训练网络模型的基础上,根据壳质组的训练样本数据对模型参数进行微调,所以选择适合的预训练网络(基础网络)至关重要。通过对现有卷积神经网络性能的初步分析与比较,选择 VGG16、InceptionV3、ResNet50 这 3 种具有良好性能的网络进行分析与尝试。

2.2.1 VGG16 网络

VGG16 网络^[13]的核心思想,是通过 3×3 的小卷积核来提取更细小的特征,并通过对多个 3×3 卷积核的组合达到与 7×7 卷积核的同等效果。小视野卷积核具有更好的非线性表达能力,且可减少训练参数。网络由 13 个卷积层和 3 个全连接层(共 16 个权重层)组成,结构如图 2 所示。

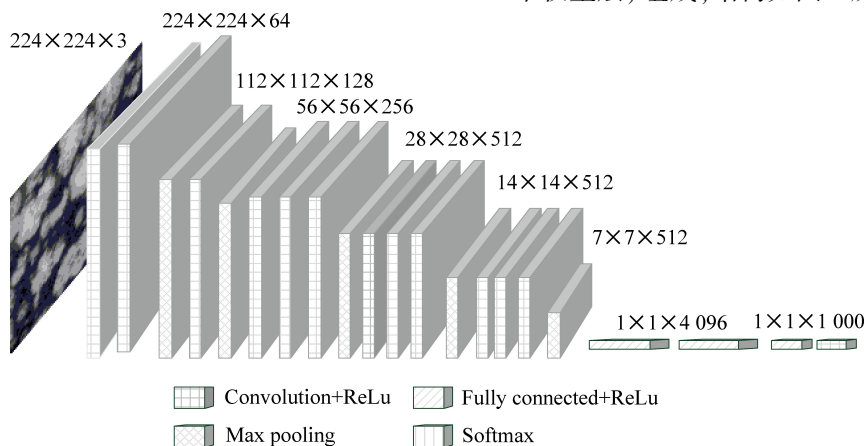


图 2 VGG16 网络结构

Fig.2 Architecture of VGG16 network

2.2.2 InceptionV3 网络

InceptionV3 网络^[14]在 VGGNet 的基础上继续加深网络结构,其主要创新点在于其进行全卷积运算的 inception 块。该模型将较大尺寸的 $n \times n$ 维卷积核分解成分别为 $1 \times n$ 和 $n \times 1$ 的 2 个一维卷积核,从而减少网络参数。此方法在加快训练时间的

同时,可以将 1 个卷积层分成 2 个卷积层,增加网络的深度,以增强网络的非线性特征。Inception V3 模型的典型 inception 块结构如图 3 所示,其中 Base 的大小是 17×17 。

2.2.3 ResNet50 网络

随着网络深度的不断增加,梯度消失问题越来越




图3 InceptionV3 模型的典型 inception 块结构

Fig.3 Typical inception structure of Inception V3

越严重,数据的初始化和正则化可以在一定程度上解决梯度消失问题,但会致使网络的性能退化。ResNet50^[15]在现有深度网络模型的基础上引入跨层连接,提出深度残差学习框架,以解决退化和梯度问题,其残差结构如图4所示。

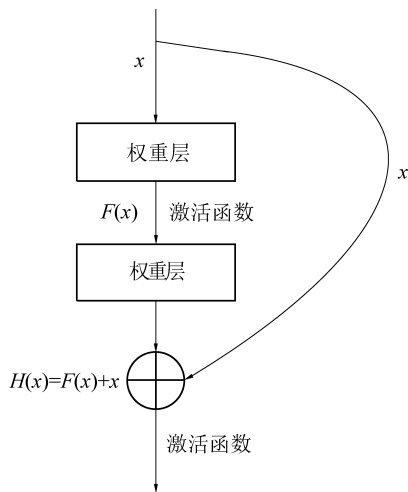


图4 ResNet50 的残差结构

Fig.4 Residual structure of ResNet50

跨层结构中, $H(x)$ 和 $F(x)$ 之间的关系为

$$H(x) = F(x) + x \quad (1)$$

式中: x 为输入图像; $F(x)$ 为经过卷积运算之后的输出; $H(x)$ 为理想映射输出。

为解决上述问题,需找到一个拟合函数,使 $H(x) = x$ 成立。由式(1)可得,当 $F(x)$ 趋近于0,恒等映射关系式 $H(x) = x$ 成立,问题转换为残差函数 $F(x) = H(x) - x$ 。

虽然 InceptionV3 与 ResNet50 网络直接训练大型数据集能够获得较好的识别效果^[19],但加深了网

络深度,使其用作煤岩显微组分识别的预训练网络模型时,微调过程较为复杂。VGG16 模型结构简单,泛化能力强,深度特征学习能力较强,其中卷积层对图像中曲线、边缘、轮廓等特征具有较强的提取能力^[20],这些优势适合于煤岩壳质组显微图像的形貌特征,且 VGG16 拥有大量可以用来移植的已经训练好的权重参数。

因此,将在 ImageNet 数据集上训练好的 VGG16 网络作为壳质组显微组分识别的预训练模型,通过微调迁移学习的方式,将预训练模型的参数共享至本文模型,结合壳质组显微图像样本数据进一步优化模型的全连接层参数,训练顶部的卷积层和全连接层继而更新模型的权值参数,最终完成对壳质组样本的识别。

2.3 基于迁移学习的分类器构建及模型训练

2.3.1 分类器构建

根据上述分析,以 VGG16 为预训练模型,构建基于迁移学习的微调模型,包括输入层、特征提取层(池化层与卷积层)及分类层(图5)。首先,为了减少模型的训练时间和参数,将输入图像尺寸调整为 128×128 。然后,从预训练模型中导入第5个卷积块(conv block 5)之前各层的权重。最后,利用本文壳质组训练样本图像对模型中微调部分进行训练。

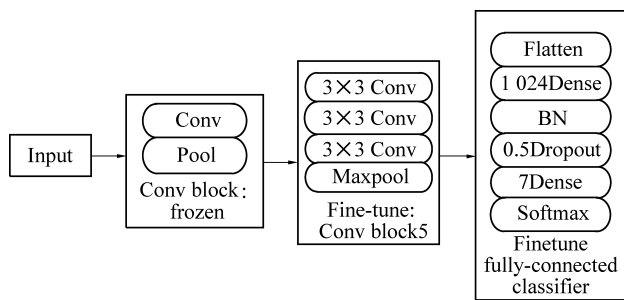


图5 以 VGG16 为基础的微调网络结构

Fig.5 Architecture of fine-tune network based on VGG16

VGG16 原模型是为 1 000 个分类类别而设计的,而本文壳质组显微组分样本仅有 7 类,因此,在分类器构建中设置 2 个全连接层,第 1 个全连接层的神经元个数为 1 024,第 2 个全连接层神经元个数为 7。由于煤岩样本数有限,加入 Dropout 层以避免过拟合现象的发生。同时在结构中引入 BN 层,以提高网络的收敛速度。

2.3.2 模型训练

训练基于 Keras 深度模型框架,在 Windows 10 系统下,搭载 Intel(R) Core(TM) i5-8300H CPU 及 GeForce GTX 1050Ti 显卡。采用模型的收敛速度、识别准确率、混淆矩阵等作为评价指标,训练过程中

采用交叉熵作为损失函数。

交叉熵定义为：

$$E = - \sum_j \sum_i p_i(j) \log q_i(j) \quad (2)$$

式中： $p_i(j)$ 和 $q_i(j)$ 分别为第 j 个训练样本在第 i 个类别下的真实值和分类器输出值。

基于 VGG16 的网络模型训练过程如图 6 所示。获取在 ImageNet 大型数据集上预训练的基础网络模型,进而采用迁移学习的技术结合煤岩壳质组训练样本数据对模型参数进行微调。




图 6 VGG16 模型训练流程

Fig.6 Training flow of VGG16 model

参数微调步骤如下:①样本预处理。以 2:1 比例将壳质组显微组分样本分为训练集和测试集,对训练集采用随机缩放、随机平移等方式进行数据扩充。②初始识别模型构建。随机初始化模型参数,将 3 个全连接层优化为 2 个全连接层。③模型迁移。通过微调迁移学习方法,将预训练网络中的模型参数迁移至本识别模型中,确定卷积层和池化层的参数。④煤岩壳质组识别模型构建。设定学习率和训练次数,通过式(2)进行迭代,固定相应的卷积层与池化层参数,在壳质组训练样本集上重新训练第 5 个卷积块和全连接层的参数,得最终分类器。

3 试验与结果

试验用煤样来源于河南平顶山煤田、东升煤矿和山西大同矿区及山西河东、霍西煤田。制样后采用光学显微镜油浸反射光下获取显微图像,放大 400 倍。分别选取壳质组 7 种显微组分图像各 45 幅,其中训练样本各 30 幅,测试样本各 15 幅,原始样本大小为 224×224 。为防止模型过拟合,利用数据增强将每类训练样本扩充至 180 幅,共计 1 260 幅。

为验证基础网络选择的合理性,分别以 VGG16、InceptionV3、ResNet50 网络为预训练网络,根据壳质组显微图像训练样本对模型参数进行微调,比较采用不同预训练模型迁移学习时模型的收敛性。在此过程中,模型权值参数的更新采用 Adam 优化算法, batchsize 的大小设置为 8,初始学习率为 10^{-5} ,训练周期为 60。

此外,试验对比了采用迁移学习与不采用迁移学习构建的网络识别模型的性能及对本文研究问题的适应性。不采用迁移学习的方法(原模型)用壳质组样本直接对模型进行训练,即卷积神经网络每一层权值系数都在本文研究对象样本数据集上训练而得。

3.1 模型参数比较

分别以 VGG16、InceptionV3、ResNet50 直接学习(原模型)和以这 3 种网络为预训练模型进行迁移学习,网络训练参数及训练时间见表 1。

表 1 不同模型训练参数个数及时间

Table 1 Training parameters number and time of different models

模型	迁移学习		原模型	
	参数个数	训练时间/s	参数个数	训练时间/s
VGG16	15 478 279	670	65 058 631	3 300
InceptionV3	2 105 351	900	22 750 286	1 760
ResNet50	2,105,351	800	25 693 063	2 410

由表 1 看出,相比于 VGG16、InceptionV3、ResNet50 原模型,本文构建的 3 种迁移学习网络模型参数量有效减少、训练时间均缩短 45% 以上。新构建的迁移学习网络模型中,以 VGG16 为基础的网络模型其训练时间缩短约 80%,训练时间最短。

3.2 收敛速度

将采用不同预训练网络模型迁移学习后所得模型分别记为 F-VGG16、F-InceptionV3 和 F-ResNet50,对其收敛性进行比较分析。从图 7 看出,F-VGG16 模型在第 7 个周期基本达到收敛,训练样本的识别准确率稳定在 90% 以上;F-InceptionV3、F-ResNet50 模型震荡明显,且准确率相对较低。上述结果表明,F-VGG16 网络性能优于其他 2 种网络。

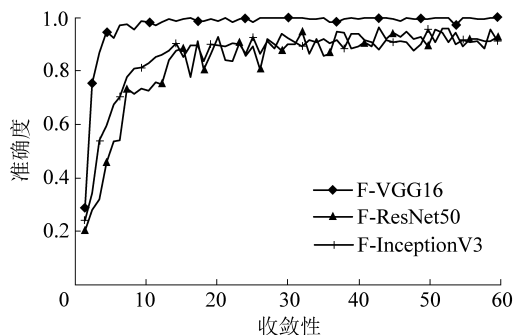


图 7 不同模型收敛性

Fig.7 Convergence properties of different models

3.3 识别准确率

识别准确率 A 定义为

$$A = N_c / N \tag{3}$$

式中： N 为测试集中所有样本图像的个数； N_c 为被正确识别的样本数。

表 2 是传统深度学习（原模型）和与其对应的迁移学习网络模型在测试样本中的识别准确率。

表 2 不同模型对测试样本识别准确率

Table 2 Identification accuracy for test samples with different models

网络模型	识别准确率/%
VGG16	88.57
InceptionV3	85.71
ResNet50	92.38
F-VGG16	98.10
F-InceptionV3	93.33
F-ResNet50	96.19

从表 2 看出,相比于迁移学习模型,传统深度学习模型在壳质组显微组分识别中准确率较低,其中 InceptionV3 原模型准确率仅为 85.71%。3 种迁移学习模型的识别准确率均达到 90% 以上,相比于原模型均有较大幅度提升。其中,以 VGG16 为基础模型的迁移学习模型 F-VGG16 准确率可达 98.10%,比 VGG16 原模型其识别准确率提高了 9.53%;相比于以 InceptionV3 和 ResNet50 为基础的迁移学习模型,其识别准确率亦有明显提高。

3.4 混淆矩阵分析

为更深入地分析模型对每类显微组分的识别

准确性,利用混淆矩阵对本文构建的迁移学习网络模型进行对比分析,结果见表 3—表 5。表中行表示样本真实类别,列表示识别结果。采用 F-VGG16 模型,孢粉体、角质体、沥青质体、木栓质体、藻类体和碎屑壳质体均被正确识别,树皮体有 2 个样本被错误识别(表 3)。采用 F-ResNet50 模型,孢粉体、角质体、木栓质体、藻类体识别均正确,树皮体有 2 个样本分别被错分至孢粉体和碎屑壳质体,沥青质体、碎屑壳质体均有 1 个样本被错分(表 4)。采用 F-InceptionV3 模型,角质体、沥青质体识别正确,树皮体中 3 个样本被错分至角质体与沥青质体中,其余组分均有 1 个样本被错分(表 5)。

图 8 为采用 3 种迁移学习模型对壳质组 7 类显微组分测试样本识别准确率的分布直方图,可以直观地看出 F-VGG16 网络有 6 种显微组分可以被正确识别,F-ResNet50 正确识别 4 种组分,而 F-InceptionV3 仅有 2 种组分被正确识别。结果显示,以 VGG16 为基础网络的迁移学习模型 F-VGG16 在组分数和样本数的正确识别上均优于另 2 种迁移学习模型。

综上所述,本文构建的以 VGG16 为基础的迁移学习方法具有一定的优越性,一方面可以较好地实现煤岩壳质组显微组分的自动识别,另一方面采用深度学习方法可以避免传统方法在特征提取阶段所需的大量先验知识和人工干预。

表 3 F-VGG16 模型的混淆矩阵

Table 3 Confusion matrix of F-VGG16 model

类别	孢粉体	角质体	沥青质体	木栓质体	树皮体	碎屑壳质体	藻类体
孢粉体	15	0	0	0	0	0	0
树皮体	0	15	0	0	0	0	0
沥青质体	0	0	15	0	0	0	0
木栓质体	0	0	0	15	0	0	0
角质体	0	0	0	0	13	0	2
碎屑壳质体	0	0	0	0	0	15	0
藻类体	0	0	0	0	0	0	15

表 4 F-ResNet50 模型的混淆矩阵

Table 4 Confusion matrix of F-ResNet50 model

类别	孢粉体	角质体	沥青质体	木栓质体	树皮体	碎屑壳质体	藻类体
孢粉体	15	0	0	0	0	0	0
角质体	0	15	0	0	0	0	0
沥青质体	0	0	14	0	0	1	0
木栓质体	0	0	0	15	0	0	0
树皮体	1	0	0	0	13	1	0
碎屑壳质体	0	1	0	0	0	14	0
藻类体	0	0	0	0	0	0	15

表 5 F-InceptionV3 模型的混淆矩阵

Table 5 Confusion matrix of F-Inception V3 model

类别	孢粉体	角质体	沥青质体	木栓质体	树皮体	碎屑壳质体	藻类体
孢粉体	14	1	0	0	0	0	0
角质体	0	15	0	0	0	0	0
沥青质体	0	0	15	0	0	0	0
木栓质体	0	1	0	14	0	0	0
树皮体	0	2	1	0	12	0	0
碎屑壳质体	0	0	0	1	0	14	0
藻类体	0	0	1	0	0	0	14

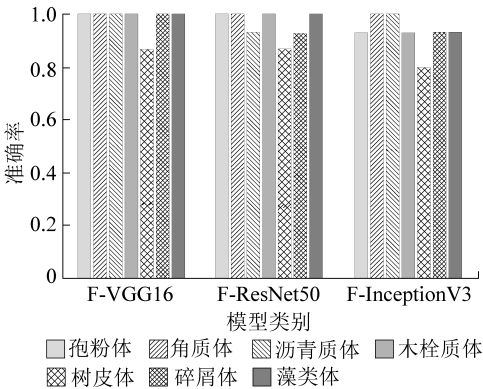


图 8 各组测试样本的识别准确率

Fig.8 Identification accuracy on test samples for each component

4 结 论

1)与传统的直接训练深度学习网络的方法相比,采用迁移学习训练机制构建的模型其网络参数少,训练速度快,其中 F-VGG16 模型耗时最短。

2)采用不同的基础模型进行迁移学习,网络模型在煤岩壳质组数据集上的收敛性有明显差异,其中 F-VGG16 模型收敛速度最快,识别准确率高且相对稳定。

3)与直接训练的深度学习方法相比,本文迁移学习方法在测试样本上识别准确率明显提高;F-VGG16模型的识别准确率可达 98.10%,优于其他方法,且可以避免传统分类方法在特征提取阶段需要的大量先验知识和人工干预,更适用于解决煤岩壳质组显微组分自动识别问题。

参考文献 (References) :

[1] 丁 华,姜 英,李文华.煤及其显微组分热解特性研究[J]. 煤质技术,2009(S1): 1-5.
DING Hua, JIANG Ying, LI Wenhua. Study on pyrolysis of coal and macerals concentrates[J]. Coal Quality Technology, 2009 (S1): 1-5.

[2] 付艳红,李 振,周安宁,等.煤中矿物及显微组分分离特性的 MLA 研究[J]. 中国矿业大学学报, 2017, 46(6): 1357-

1363.
FU Yanhong, LI Zhen, ZHOU Anning, *et al.* Liberation characterization of minerals and macerals in coal by using MLA [J]. Journal of China University of Mining & Technology, 2017, 46 (6): 1357-1363.

[3] 全国煤岩标准化技术委员会. 烟煤显微组分分类:GB/T 15588-2013[S].北京:中国标准出版社, 2014.

[4] 闫兰英,赵 伟,周安宁. 煤岩显微组分的浮选分离及其对活性炭性能影响[J]. 煤炭科学技术, 2016(S2): 197-201.
YAN Lanying, ZHAO Wei, ZHOU Anning. Effect of coal macerals concentrated by flotation separation on properties of activated carbon[J]. Coal Science and Technology, 2016(S2):197-201.

[5] BRIENA G O, GUB Y, ADAIRB B J I, *et al.*The use of optical reflected light and SEM imaging systems to provide quantitative coal characterization[J]. Minerals Engineering, 2011, 24(12): 1299-1304.

[6] SKIBA M, MLYNARCZUK M. Identification of macerals of the inertinite group using neural classifiers, based on selected textural features[J]. Archives of Mining Sciences, 2018, 63(4): 827-837.

[7] LIU M, WANG P, CHEN S, *et al.* The classification of inertinite macerals in coal based on the multifractal spectrum method[J]. Applied Sciences, 2019, 9(24): 5509.

[8] 王培珍,刘婕梅,汪文艳,等. 基于轮廓波变换的煤壳质组显微组分分类[J]. 煤炭学报, 2018, 43(S2): 641-645.
WANG Peizhen, LIU Jiemei, WANG Wenyan, *et al.* Classification of macerals in exinite of coal based on contourlet transform [J]. Journal of China Coal Society, 2018, 43(S2): 641-645.

[9] 王培珍,殷子皖,王 高,等. 一种基于 PCA 与 RBF-SVM 的煤岩显微组分镜质组分类方法[J]. 煤炭学报, 2017, 42(4): 977-948.
WANG Peizhen, YIN Zihuan, WANG Gao, *et al.* A classification method of vitrinite for coal macerals based on the PCA and RBF-SVM[J]. Journal of China Coal Society, 2017, 42(4): 977-948.

[10] 王培珍,王 慧,刘 曼,等. 一种基于流形学习的 PCA-SLPP 特征空间降维方法[J]. 安徽工业大学学报(自然科学版), 2018, 35(4): 352-359.
WANG Peizhen, WANG Hui, LIU Man, *et al.* A method of PCA-SLPP dimensionality reduction for feature space based on manifold learning[J]. Journal of Anhui University of Technology (Natural Science), 2018, 35(4):352-359.

- [11] 王培珍, 刘 曼, 王 高, 等. 基于改进极限学习机的焦煤惰质组分类方法[J]. 煤炭学报, 2020, 45(9): 3262-3268.
WANG Peizhen, LIU Man, WANG Gao, *et al.* Classification Approach for Inertinite of Coking Coal Based on an Improved Extreme Learning Machine [J/OL]. Journal of China Coal Society, 2020, 45(9): 3262-3268.
- [12] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems. New York: Curran Associates, 2012: 1097-1105.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]//ICLR Cornell University, 2015.
- [14] SZEGEDY C, LIU W, JIA Y, *et al.* Going deeper with convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 1-9.
- [15] HE K, ZHANG X, REN S, *et al.* Deep Residual Learning for Image Recognition[C]//In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [16] 中国煤田地质总局. 中国煤岩学图鉴[M]. 徐州: 中国矿业大学出版社, 1996: 212-229.
China National Administration of Coal Geology. Atlas for coal petrography of China[M]. Xuzhou: China University of Mining & Technology Press, 1996: 212-229.
- [17] 何雪英, 韩忠义, 魏本征. 基于深度学习的乳腺癌病理图像自动分类[J]. 计算机工程与应用, 2018, 54(12): 121-125.
HE Xueying, HAN Zhongyi, WEI Benzhen. Breast cancer histopathological image auto-classification using deep learning[J]. Computer Engineering and Applications, 2018, 54(12): 121-125.
- [18] 庄福振, 罗 平, 何 清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
ZHUANG Fuzhen, LUO Ping, HE Qing, *et al.* Survey on transfer learning research [J]. Journal of Software, 2015, 26(1): 26-39.
- [19] 周飞燕, 金林鹏, 董 军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural networks[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [20] 张建华, 孔繁涛, 吴建寨, 等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. 中国农业大学学报, 2018, 23(11): 161-171.
ZHANG Jianhua, KONG Fantao, WU Jianzhai, *et al.* Cotton disease identification model based on improved VGG convolution neural network [J]. Journal of China Agricultural University, 2018, 23(11): 161-171.