

# 基于卷积神经网络与迁移学习的 碳钢石墨化自动评级研究

谢小娟, 杨宁祥

(广东省特种设备检测研究院 珠海检测院, 广东 珠海 519002)

**摘要:** 为实现碳钢石墨化的智能化评级, 基于卷积神经网络与迁移学习的方法构建了碳钢金相图像的自动分类模型; 首先通过几何变换和像素调整的数据增强方法建立了碳钢石墨化图像数据集; 然后采用统一扩展网络宽度、深度和分辨率方式来协调精度与效率的轻量级 EfficientNet 网络作为主干特征提取网络, 构建碳钢石墨化图像评级模型, 并在训练阶段利用迁移学习与参数微调的方法来提高模型的训练效率; 最后使用测试数据集对模型的分类精度与复杂度进行了验证实验, 结果表明该模型能快速准确地对碳钢石墨化程度进行自动评级, 在仅需 12 MB 内存的情况下, 便可实现 97.01% 的评级准确率, 单幅金相图像的平均检测时间也仅需 10.27 ms, 满足现场检测的精度与实时性要求。

**关键词:** 碳钢石墨化; 金相图像; 卷积神经网络; 迁移学习; 自动评级

## Automatic Evaluation Study of Carbon Steel Graphitization Based on Convolutional Neural Network and Transfer Learning

Xie Xiaojuan, Yang Ningxiang

(Zhuhai Branch, Guangdong Institute of Special Equipment Inspection and Research, Zhuhai 519002, China)

**Abstract:** In order to realize the intelligent evaluation of carbon steel graphitization, an automatic classification model of carbon steel metallographic images is constructed based on convolutional neural network and transfer learning. The carbon steel graphitization image dataset was firstly established by the data enhancement methods of geometric transformation and pixel adjustment. Then the lightweight EfficientNet network that uniformly expands the network width, depth and resolution to coordinate accuracy and efficiency was used as the backbone feature extraction network to construct a carbon steel graphitization image evaluation model, and transfer learning and parameter fine-tuning methods were used in the training phase to improve the training efficiency of the model. Finally, a test data set was used to verify the classification accuracy and complexity of the model. The results show that the model can quickly and accurately grade the degree of graphitization of carbon steel automatically. With only 12 MB of memory, it can achieve a 97.01% accuracy, and an average detection time of only 10.27 ms for a single metallographic image, which meets the accuracy and real-time requirements of on-site detection.

**Keywords:** carbon steel graphitization; metallographic image; convolutional neural network; transfer learning; automatic evaluation

## 0 引言

碳钢由于可加工性良好且性价比较高而广泛应用在压力锅炉、蒸汽管道及高温高压机组的有关部件中。在长期服役过程中, 碳钢在一定的温度和压力作用下会产生石墨化现象, 降低材质的强度与韧性, 最终导致脆性爆管等严重事故。目前, 关于碳钢石墨化的检测方法主要依赖金相分析法, 即采用人工目测的方法, 通过金相显微镜观察试样的金相组织图像, 然后与标准图谱相对照进行石墨化评级<sup>[1-2]</sup>。这种评级结果带有很强的主观性, 误差较大, 且重复性不好。

随着计算机视觉技术与神经网络算法的发展, 研究人

员开始应用图像处理技术与机器学习方法进行金相组织分析。例如, 樊丁等人<sup>[3]</sup>采用 canny 图像边缘检测算法及 8-链码目标轮廓跟踪的方法对钴基合金金相组织进行了定量分析。吴伟等人<sup>[4]</sup>以 ImageJ 软件为工具, 采用图像增强、分割等技术提取 TC4 钛合金金相组织的特征参数。姜博等人<sup>[5]</sup>基于图像处理技术结合数学形态学的方法, 对铸造镁合金 AM50 进行金相分析, 得到了晶粒尺寸在整个试样上的分布规律。此外, 还有针对 AL-Ti-B 中间合金<sup>[6]</sup>、GCr15 轴承钢<sup>[7]</sup>等材料进行金相图像识别的研究。总结起来, 这类方法大都首先基于图像处理技术获取试样的颜色、纹理、形状等特征, 再根据特征向量利用神经网络、支持

收稿日期: 2020-10-29; 修回日期: 2020-11-21。

基金项目: 广东省特种设备检测研究院科技项目(2020CY13)。

作者简介: 谢小娟(1988-), 女, 河北唐山人, 硕士, 工程师, 主要从事特种设备安全与故障诊断、智能信息处理等方向的研究。

引用格式: 谢小娟, 杨宁祥. 基于卷积神经网络与迁移学习的碳钢石墨化自动评级研究[J]. 计算机测量与控制, 2021, 29(2): 234-237, 245.

向量机等方法进行图像分类。虽然图像识别准确率有了一定的提高,但是由于本质上依然依赖人工设计与选择特征,难以获得最接近试样属性特征的自然表达,导致训练时间长且误差率较高。

卷积神经网络 (CNN, convolutional neural network) 通过引入局部连接、权值共享、最大池化、非线性激活等方法,允许神经网络从图像中自动学习特征,避免对图像进行复杂的边缘检测、阈值分割等前期预处理,比传统机器学习方法具有更强大的特征学习和表达能力,因而在图像分类、目标检测等方面得到了越来越广泛应用<sup>[8-11]</sup>。对于神经网络模型而言,为获得更好的精度,需要具有更宽、更深或更高的图像分辨率,导致模型参数增多,训练时间增长,在此背景下各种紧凑型 CNN 被提出,以寻求在模型精度与计算成本之间的最佳平衡点。Tan 和 Le<sup>[12]</sup>提出的 EfficientNet 网络采用复合缩放方法,通过平衡网络的深度、宽度和图像分辨率,已被证实大幅减少模型参数数量的前提下,可以获得更好的计算性能和模型精度。因此,本研究基于 EfficientNet 网络构建碳石墨化金相图像的自动评级模型,以期实现通过直接输入原始图像,便能快速获得评级结果。同时,为避免碳石墨化金相图像样本过少带来的模型过拟合问题,采用迁移学习及数据增强的方法来提高模型的准确率,以更好地满足实际检验的需要。

## 1 碳石墨化图像采集与数据增强

### 1.1 金相图像采集

根据《碳石墨化检验及评级标准》(DL/T786—2001)<sup>[13]</sup>中的规定,在对试样进行机械或化学抛光后,利用 CCD 摄像机通过光学显微镜对待检验部位进行成像,获得金相组织图像,如图 1 所示。

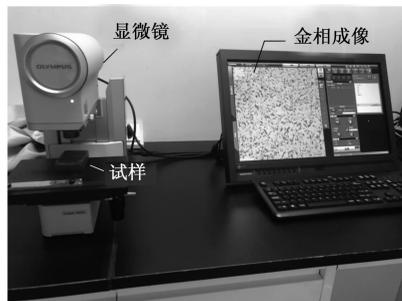


图 1 金相图像采集系统

根据金相组织中石墨面积百分比、石墨链长度以及石墨形态将碳钢材料石墨化程度分为 1~4 级,分别对应“轻度石墨化”、“明显石墨化”、“显著石墨化”和“严重石墨化”,如图 2 所示。

### 1.2 图像数据增强

图像样本的数量和质量直接影响深度神经网络的检测精度,为获得具有更好泛化能力的模型,提高分类的准确率,卷积神经网络需要大量的训练样本,而目前碳石墨化图像并没有诸如 ImageNet 等庞大的公共图像数据库,因

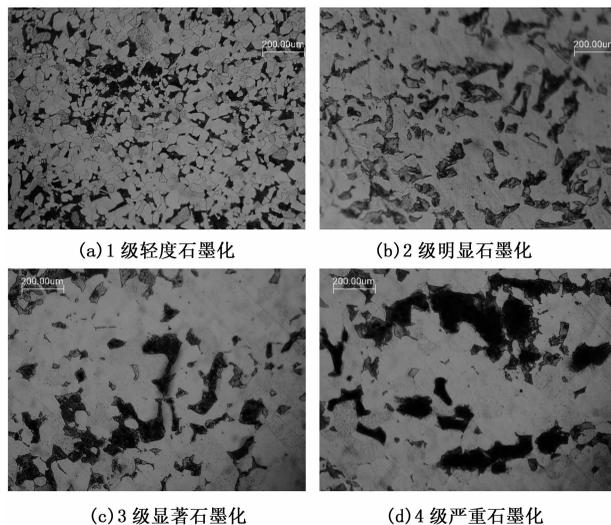


图 2 碳钢材料不同石墨化程度图

此对试验数据集进行图像增强,以扩充数据样本。

本研究采用现场检验所收集与积累的 450 张碳钢金相图像作为用于模型的训练和测试的原始数据集,包括正常与不同石墨化程度的图片。图像增强的方法为几何变换(包括旋转、翻转和平移等)、像素调整(亮度调节、对比度调节和添加噪声等),通过增加数据本来提高模型的鲁棒性与泛化能力,最终样本图像被扩充为 3 210 张。再将这些图像的尺寸归一化为  $224 \times 224 \times 3$ ,完成训练样本集的构建。最后按照通用数据集划分策略,将数据集随机分配成训练集(70%)、测试集(25%)和验证集(5%)。

## 2 基于 EfficientNet 的碳石墨化评级系统

根据金相组织图像的特点以及现场检验所需的快速高精度要求,本研究采用 EfficientNet 网络用于特征提取,构建碳石墨化图像评级系统结构如图 3 所示。该网络在 ImageNet 数据集上获得了 84.4% 的 Top-1 精度和 97.1% 的 Top-5 精度,并且参数量减少了 8.4 倍,速度快了 6.1 倍<sup>[12]</sup>。

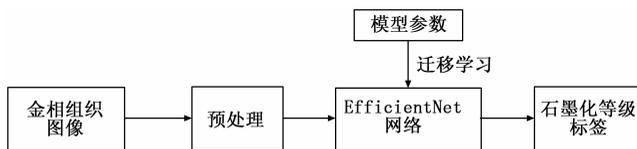


图 3 系统结构图

首先对输入的金相组织图像进行降噪、矫正等预处理;然后将图像映射到 EfficientNet 主干网络进行特征提取;最后经 Softmax 层输出石墨化等级的标签。同时,为了优化模型训练效率,将 ImageNet 数据集训练得到的模型参数作为网络的初始化参数,迁移到金相数据集上进行训练。

### 2.1 EfficientNet 分类模型

在卷积神经网络中,通过提高网络深度(depth)、网络宽度(width)和输入图像分辨率(resolution)大小都可以获

得更好的精度。但是三者的组合空间太大，人力难以穷举。EfficientNet 提出基于复合模型缩放的方法实现三个维度上的平衡，使用复合系数来从深度、宽度和分辨率三个维度统一扩展网络，在实现较高准确率的同时又充分节省计算资源，如式 (1) 所示：

$$\begin{cases} d = \alpha^\phi \\ w = \beta^\phi \\ r = \gamma^\phi \end{cases} \quad (1)$$

$$s. t. \begin{cases} \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{cases}$$

式中， $d$ 、 $w$  和  $r$  分别代表网络的深度、宽度和分辨率。 $\alpha$ 、 $\beta$  和  $\gamma$  分别代表网络深度、宽度和分辨率的分配系数，也是需要求解的参数。 $\phi$  的大小根据型可用资源进行调节，对应着消耗资源的大小。 $\beta$  和  $\gamma$  在约束上有平方，是因为如果宽度或分辨率增加 1 倍，其计算量  $F_{LOPs}$  增加 4 倍，而深度增加 1 倍，其计算量  $F_{LOPs}$  只会增加 2 倍。

$\alpha$ 、 $\beta$  和  $\gamma$  可以通过网络搜索得到最优解。EfficientNet 以 MobileNetV2<sup>[14]</sup> 中的反向残差结构和压缩-激励优化<sup>[15]</sup> 为基础构建 MBConv (mobile inverted bottleneck convolution) 作为网络的基本模块，在  $3 \times 3$  或者  $5 \times 5$  卷积网络前利用  $1 \times 1$  卷积升维，之后增加了一个关于 SE 通道的注意力机制，最后利用  $1 \times 1$  卷积降维后增加一个残差边，如图 4 所示。在限制目标  $F_{LOPs}$  和存储空间的情况下，不同的  $\phi$  参数可搜索得到一系列网络 EfficientNet B0-B7。

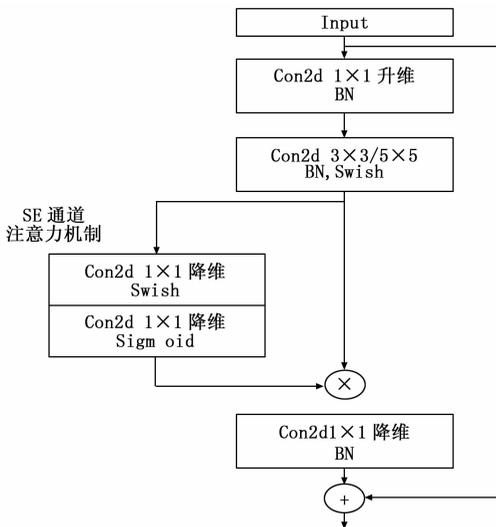


图 4 MBConv 结构图

本文采用 EfficientNet-B0 作为模型的主干网络，如图 5 所示。该网络包括 16 个 MBConv 层，2 个 Conv 层，1 个

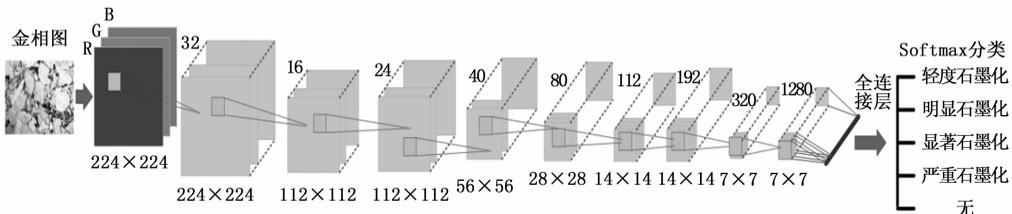


图 5 碳钢石墨化评级模型

全局平均池化层 (Global average pooling) 和 1 个 FC 全连接层，各参数如表 1 所示。考虑到模型对底层特征的依赖，在开始阶段只采用步长为 2 的卷积操作，未使用最大池化，以减少细节特征的丢失。另外，网络中的多个卷积阶段采用了  $5 \times 5$  的卷积核，是因为 MBConv $5 \times 5$  的浮点运算次数比 MBConv $3 \times 3$  要少，计算效率较高。

表 1 EfficientNet-B0 网络参数

卷积阶段	卷积类型	分辨率	通道数	层数
1	Conv $3 \times 3$	$224 \times 224$	32	1
2	MBConv1, $k3 \times 3$	$112 \times 112$	16	1
3	MBConv6, $k3 \times 3$	$112 \times 112$	24	2
4	MBConv6, $k5 \times 5$	$56 \times 56$	40	2
5	MBConv6, $k3 \times 3$	$28 \times 28$	80	3
6	MBConv6, $k5 \times 5$	$14 \times 14$	112	3
7	MBConv6, $k5 \times 5$	$14 \times 14$	192	4
8	MBConv6, $k3 \times 3$	$7 \times 7$	320	1
9	Conv $3 \times 3$ , Pooling, FC	$7 \times 7$	1280	1

在全连接层之后，使用 Softmax 函数将网络输出结果映射为分类概率，如式 (2) 所示。最后选择概率最大值作为图像的分类结果。

$$y_i = \text{softmax}(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (2)$$

$$z_j = w_j \cdot x + b_j \quad (3)$$

$$s. t. \begin{cases} 0 < y_i < 1 \\ \sum_j y_i = 1 \end{cases}$$

式中， $y_i$  表示 softmax 输出的该图像属于第  $i$  类的概率， $x$  为全连接层的输入， $b_j$  为偏置项， $w_j$  可视作该图像属于第  $j$  类的特征权重，体现的是每维特征的重要程度，通过加权求和得出计算结果，再经 Softmax 函数转换为概率值。

同时，由于在实际检验中，获取大规模金相图像用于模型训练并不现实，因此在模型中，为避免图像样本数量不足而导致网络训练过拟合和不稳定的问题，采用批标准化 (BN, batch normalization) 和 dropout<sup>[16]</sup> 优化方法来减小卷积层之间的依赖，降低部分神经元在训练过程中的活性，抑制过拟合的发生，进而提高网络的泛化能力，增强模型分类的鲁棒性。

### 2.2 迁移学习

卷积神经网络的参数训练需要大量的标记样本数据，而对于碳钢石墨化评估来说，缺少大规模的金相组织图像样本，本文引入迁移学习<sup>[8]</sup> 的方法，借助已经训练好的模

型权重进一步学习。ImageNet 数据集十分庞大, 包括 120 余万张图片 and 1 000 个分类, 因此本文将在 ImageNet 数据集上进行训练得到预训练 (Pre-trained) 权重, 将其作为 EfficientNet 网络的初始参数, 然后在此基础上进行参数微调 (Finetune), 使得模型一方面继承了从 ImageNet 数据集上学习到的特征提取能力, 另一方面节省模型训练时间, 提高模型的泛化能力。

### 3 实验结果与分析

#### 3.1 实验平台与模型训练

碳石墨化评级模型使用 Python 编程语言及 PyTorch 深度学习框架实现, 模型训练的硬件环境为 Intel i7 CPU, 64G RAM, NVIDIA 2080Ti GPU。

模型训练采用两种方式进行, 一种从零开始直接训练, 另一种采用预训练权重和微调的方法进行迁移训练。迁移训练主要分为两个阶段: 首先加载预训练权重, 冻结主干网络训练; 然后冻结归一化层, 训练其他的网络层。设置模型训练的超参数学习率为 0.001, 批尺寸为 16, 最大迭代数 (epochs) 为 10。不同训练方法的损失值及准确率曲线如图 6、7 所示。

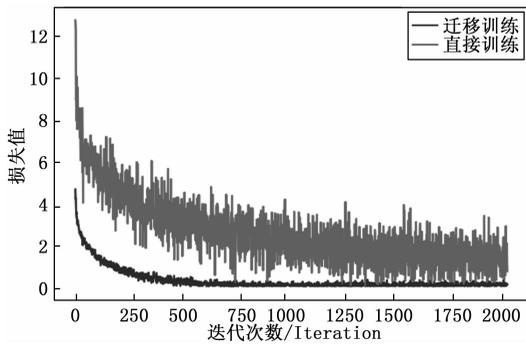


图 6 训练损失值曲线

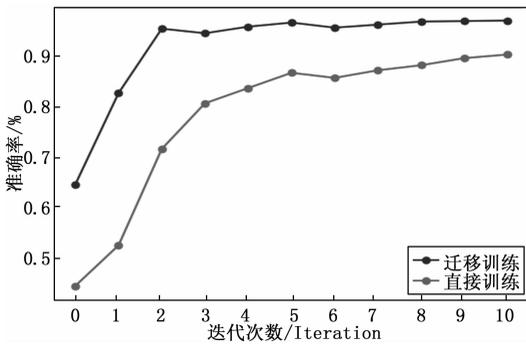


图 7 不同训练方法的准确率曲线

从图中可以看出, 相较于直接训练, 利用迁移训练的损失值在迭代 482 次之后就收敛并且毛刺波动较小, 经过三轮训练后准确率也达到了 95.7%。这也进一步证明了迁移学习能有效提高模型的训练效率。

#### 3.2 模型性能评价

为准确分析评级模型的性能, 除使用准确率  $A$  (Accuracy) 作为评价指标外, 针对每一类采用精确率  $P$  (Preci-

sion)、召回率  $R$  (Recall) 以及  $F_1$  值对评价结果进行全面评估, 具体计算标准如式 (4) ~ (6) 所示, 其中  $F_1$  值是精确率和召回率的调和均值。上述指标的取值范围均在 0~100% 之间, 并且越大越好。

$$P_i = \frac{TP_i}{TP_i + FP_i} \quad (4)$$

$$R_i = \frac{TP_i}{TP_i + FN_i} \quad (5)$$

$$F1_i = 2 \times \frac{P_i \cdot R_i}{P_i + R_i} \quad (6)$$

式中,  $TP_i$  为样本实际属于  $i$  类且模型评级为  $i$  类;  $FP_i$  为样本实际不属于  $i$  类但模型评级为  $i$  类;  $FN_i$  为样本实际属于  $i$  类但模型评级不为  $i$  类。

将测试集样本输入评级模型, 根据分类结果得到混淆矩阵如图 8 所示, 进而计算出模型处理金相图像的性能指标如表 2 所示。

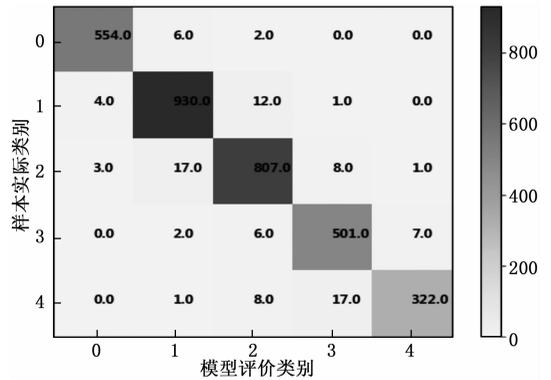


图 8 金相图像评级的混淆矩阵

表 2 碳石墨化评级模型的精度性能指标

评级	精确率 $P$ /%	召回率 $R$ /%	$F_1$ 值	准确率 $A$ /%
0	98.75	98.58	0.987	97.01
1	97.38	98.20	0.978	
2	96.64	96.53	0.966	
3	93.30	96.91	0.951	
4	97.50	92.53	0.950	

注: 0 代表无石墨化

通过表 2 可以发现, 各类石墨化程度的预测精确率在 93% 以上, 召回率在 92% 之上, 整体准确率达到 97.01%, 满足碳石墨化现场检测的精度要求。

为了进一步评价模型的实用性, 对 EfficientNet 算法处理金相图像的平均检测时间  $T$ 、算法的浮点运算数 FLOPs 和算法的参数量  $P$  及占用内存  $M$  进行统计分析, 以衡量模型的复杂程度, 如表 3 所示。

表 3 碳石墨化评级模型的计算复杂度指标

算法	平均检测时间 $T$ /ms	浮点运算数 FLOPs	参数量 $P$	内存 $M$ /MB
EfficientNet	10.27	$2.914 \times 10^5$	$3.569 \times 10^6$	12

(下转第 245 页)