

# 迁移学习在废钢压块识别中的研究

郑翔, 朱正海\*, 肖紫轩

安徽工业大学冶金工程学院, 马鞍山 243032

## Research of Transfer Learning in Scrap baling blocks Recognition

Zheng Xiang\*, Zhu Zhenghai, Xiao Zixuan

School of Metallurgical Engineering, Anhui University of Technology, Ma'anshan, 243032, China

### 1. 前言

废钢是一种节能、低碳的战略性资源<sup>[1-3]</sup>, 据世界钢铁协会预计, 2030 年我国废钢资源产生量将达到 3 亿吨, 2050 年将到达 4 亿吨。未来我国的废钢铁资源可能不仅能够供应国内钢铁企业的生产制造, 也能成为世界钢铁工业发展必不可少的重要原料<sup>[4]</sup>。其中废钢压块具有外形规则、存储便利、熔化迅速等优点, 受到炼钢厂关注。但在压块的生产过程中又容易掺杂造假, 导致炼钢厂产生重大损失。所以, 如何能使各钢铁企业能够随时随地识别出压块的相关信息, 从而确保压块的质量情况, 是亟需解决的问题。

随着卷积神经网络技术的快速发展, 众多学者开始尝试将其应用在冶金钢铁领域中。马威<sup>[5]</sup>等构建了一种深度前馈神经网络轧制力模型, 实现了轧制力的高精度预测。李维刚<sup>[6]</sup>等提出了适用于钢铁材料微观组织辨识的改进模型, 在某实验室收集的 6 类微观组织图像的数据集上识别率精度最高可达到 100%。韩冰<sup>[7]</sup>等提出了一种基于深度学习、快速获取技术和数理统计的高通量表征方法, 用于耐候钢微观组织的识别、分割和量化, 其中夹杂物和珠光体相的分割准确率分别达到 89.95%和 90.86%。然而以上研究均建立在已有的、相对完善的数据集上, 且需要较长的时间来进行模型训练<sup>[8]</sup>。当输入网络的数据量不够时, 卷积深度学习也很难拥有令人满意的性能<sup>[9]</sup>。此外, 为了提升卷积神经网络的泛化性能, 也需要大量的数据进行训练支撑<sup>[10]</sup>。而运用了迁移学习技术<sup>[11]</sup>的卷积神经网络可以在小样本的训练集上发挥出不错的性能, 并且可以大幅度降低训练所需时间。但是, 在废钢压块智能识别领域尚未有相关报道。本文基于卷积神经网络, 采用 Parameter-transfer 的形式对模型开展研究, 探索废钢压块智能识别模型, 以为废钢压块的智能识别提供理论基础。

### 2. 实验准备和网络改进

#### 2.1. 实验准备

由于在废钢打包块识别领域, 尚还没有公开的、相对完善的数据集, 所以首先要从建立数据集开始。某废钢资源厂拥有废钢打包机一台, 回收的废钢种类较为丰富, 从形貌上分析大致分为钢筋类, 管类(窄带)和板块类。经过长期的图像采集, 完成了废钢压块数据集的建立。目前一共分为两个数据集, 其中数据集 sbbimage602 (Scrap baling blocks) 侧重采集尽可能多的废钢打包块, 目前拥有 602 个打包块的图像, 分为三个大类, 分别是钢筋类, 管类(窄带)和板块类, 大约各占三分之一, 共计 12990 张图片, 图片 size 为 4032x3024, 占用硬盘内存 52.9GB。数据集 sbbimage81 侧重采集每个废钢打包块尽可能多的图像, 目前拥有 81 个打包块的图像, 同样分为钢筋类, 管类(窄带)和板块三个大类, 大约各占三分之一, 共计 26262 张图片, 图片 size 为 1280x720, 占用硬盘内存 44.8GB, 两个数据集共计拥有约四万张图片数。

在进行模拟实验后发现，在 `sbbimage602` 上训练的模型泛化性比 `sbbimage81` 更好。分析认为压块特征相比较来说不会有很大的变化，一般也只有角度、光线和拍摄倾斜程度等变化。`sbbimage602` 中的压块数据是多次采集的结果，角度、光线和拍摄倾斜程度都有较大的不同，而 `sbbimage81` 是使用视频拍摄模式进行采集的，有大量过于相似的重复图片，所以导致其训练的网络泛化性相对较差。本次实验主要是在 `sbbimage602` 数据集上进行。

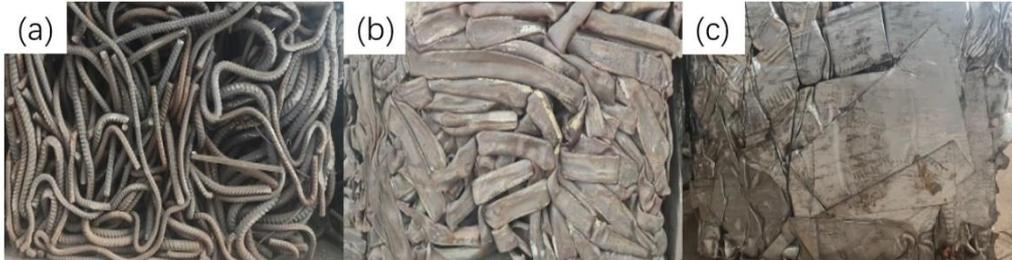


图 1 数据集中所涵盖的废钢压块宏观形貌

Fig. 1 Macroscopic shape of Scrap baling blocks covered in the dataset

## 2.2. 网络改进

在众多的卷积神经网络模型中，本文选择了以下 CNN 模型进行迁移学习模型的改进实验。考虑到目前没有与废钢压块类似的数据集，所以预训练模型的训练集选择了 ImageNet<sup>[12]</sup>数据集。在该数据集上训练的网络具有一定的泛化性，模型的浅层能够学习到识别图像所需的关键特征，在识别效果上比随机初始化网络的权重参数要更好<sup>[13]</sup>。以下 CNN 模型的权重参数均采用 PyTorch 框架中提供的最新模型权重。

具体选择的 CNN 模型：VGG16\_BN、GoogLeNet、DenseNet121、DenseNet169、ResNet18、ResNet34、ResNet50、Wide\_ResNet50\_2、ResNeXt50\_32X4D、EfficientNet\_B1、EfficientNet\_V2、RegNet\_Y\_1\_6GF、ShuffleNet\_V2\_X2、MobileNet\_V3\_Large。

迁移学习网络模型的具体改进步骤如下：

- 1) 首先对数据集进行图像变换和数据增强，按照 6: 2: 2 的比例划分训练集、验证集和测试集；
- 2) 删除模型的顶层分类结构，然后把多维数组的数据展成一维数组的数据，再连接到所需的类别数；
- 3) 将预训练模型中 Flatten layer 和 Linear layer 前的网络参数进行冻结，只训练其他层的权重参数；
- 4) 每训练一个 epoch，就进行一次验证集精度的计算，保存验证精度最高的模型，等指定次数的 epoch 完成后，用验证精度最高的模型对测试集的数据进行计算，得出最后的测试准确率。具体的基于 CNN 的迁移学习网络模型对废钢压块的识别流程如图 2 所示。

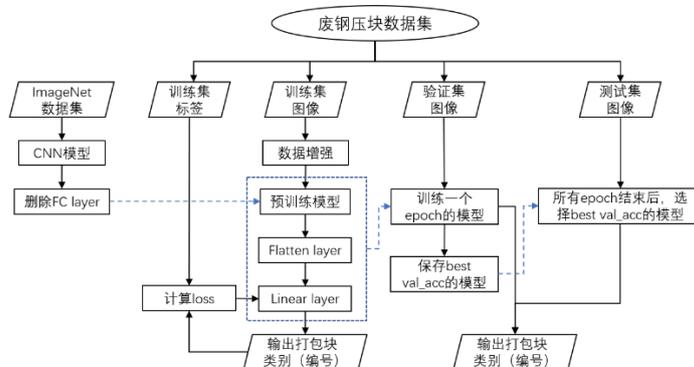


图 2 基于 CNN 的迁移学习网络模型对废钢压块的识别流程

Fig. 2 CNN-based transfer learning model for the recognition process of scrap baling blocks

### 3. 结果与分析:

实验运行环境为 Windows10 (64) 位操作系统, 编程语言选择 python 3.8, 采用 PyTorch 深度学习开源框架。实验平台的处理器配置为英特尔酷睿 i5 12400F, 性能核主频最高可达 4.4GHz, 显卡配置为英伟达 RTX 3080 12GB 显存版, 拥有 8960 个流处理器, 显存位宽为 384-bit, 内存配置为 16GBx2。

本次实验所采用的所有 CNN 模型在 sbimage602 数据集的三次平均测试准确率对比如图 3(a)所示, 三次平均训练一个 epoch 的耗时对比如图 3(b)所示。

从图 3(a)中可以分析出:

1)在本次实验中,大多数 CNN 模型在同种网络的纵向对比中,选择层数相对浅,结构相对简单的模型可以取得更好的测试准确率。说明本次实验所采用的应用场景对于这些流行的 CNN 模型来说,相对简单一些,数据集的量也较小,使用过深或者过于复杂的网络可能会导致过拟合现象的产生。但在迁移学习技术的改进下,大多数网络的测试准确率也都达到本次实验的预期要求。

2)相较于其他 CNN 模型来说,DenseNet 模型可能不太适用于本次实验的废钢压块智能识别应用场景。不管是较深的 DenseNet169 模型还是较浅的 DenseNet121 模型,在数据集上的平均测试准确率都相对较低。作为复杂模型的代表,DenseNet 模型可能需要更大的数据集,才能表现出更好的模型性能。

3)在本次实验中,大多数 CNN 模型在为数不多的迭代训练中所取得的测试准确率成绩都要好于预期,这得益于采用了迁移学习中预训练和微调技术改进后的 CNN 模型。其中 MobileNet\_V3\_Large、EfficientNet\_B1 和 ResNet18 模型的表现相对来说更好。

从图 3(b)中可以分析出:作为轻量级网络的 MobileNet\_V3\_Large 和 ShuffleNet\_V2\_X2 模型训练耗时最短,在 RSBL\_10 和 RSBL 数据集上训练一个 epoch 的平均时长不超过 100s。层数相对浅,结构相对简单的 RegNet\_Y\_1\_6GF、GoogLeNet、EfficientNet\_B1、ResNet18、ResNet34 模型耗时次之,其他模型耗时都相对较长。

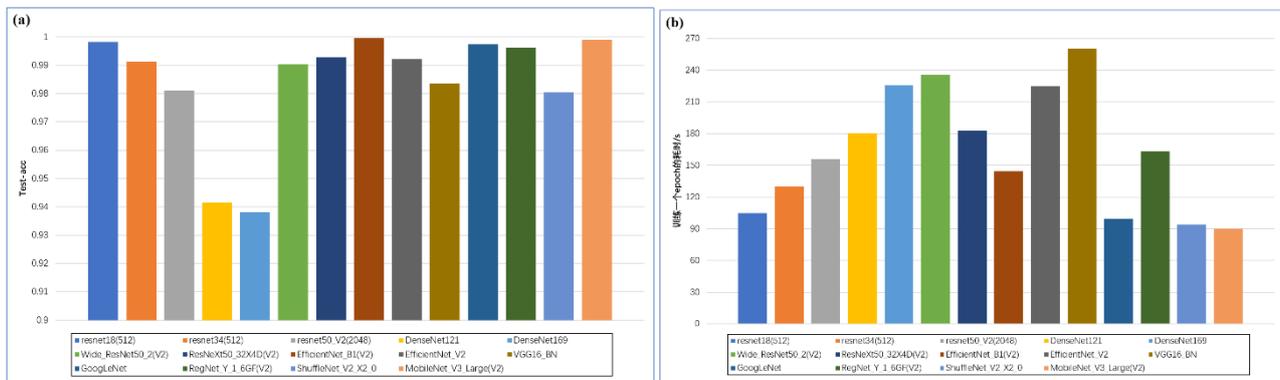


图 3 CNN 模型的测试准确率(a)和训练一个 epoch 的耗时对比(b)

Fig. 3 Comparison of the test accuracy(a) and the time taken to train an epoch (b)for CNN models

### 4. 结论

本文针对废钢压块识别这一问题,建立了数据集。在卷积神经网络的基础上,采用 Parameter-transfer 这一迁移学习的形式对 CNN 模型进行改进,然后通过实验探究了经迁移学习改进后的 CNN 模型在废钢压块智能识别场景下的性能优劣,以此来找寻最适合废钢压块智能识别这一应用场景的 CNN 模型。

试验的结果表明: MobileNet\_V3\_Large 模型在本次废钢压块智能识别场景的表现更好,其在数据集上训练一个 epoch 的时长为 89.78s,平均测试准确率为 99.8%。综合考虑模型的测试准确率和训练耗时,经

迁移学习改进后的 MobileNet\_V3\_Large 模型是废钢压块唯一性识别技术的最优算法模型。使用 MobileNet\_V3\_Large 模型对废钢压块进行识别，有利于提高转炉炼钢静、动态模型的 CT 命中率。

## 致谢

感谢国家自然科学基金项目（Nos. 51974003）的支持。

## 参考文献

- [1] 姚同路, 吴伟, 杨勇, 等. “双碳”目标下中国钢铁工业的低碳发展分析 [J]. 钢铁研究学报, 2022, 34: 505-13.
- [2] 赵亚军, 郑玉荣, 张有余. 废钢产业政策及前景分析 [J]. 再生资源与循环经济, 2019, 12(08): 18-21.
- [3] Deng S, Xu A-j. Steel scrap melting model for a dephosphorisation basic oxygen furnace [J]. Journal of Iron and Steel Research International, 2020, 27(8): 972-80.
- [4] 李云. 废钢铁在钢铁行业中应用前景研究 [J]. 再生资源与循环经济, 2020, 13(01): 23-9.
- [5] 马威, 李维刚, 赵云涛, 等. 基于深度学习的热连轧轧制力预测 [J]. 钢铁研究学报, 2019, 31: 805-15.
- [6] 李维刚, 谌竟成, 范丽霞, 等. 基于卷积神经网络的钢铁材料微观组织自动辨识 [J]. 钢铁研究学报, 2020, 32: 33-43.
- [7] Bing H, hao W W, dan S D, et al. A deep learning-based method for segmentation and quantitative characterization of microstructures in weathering steel from sequential scanning electron microscope images [J]. Journal of Iron and Steel Research International, 2022, 29(5): 836-45.
- [8] 董萍, 卫梦华, 时雷, 等. 迁移学习在玉米叶片病害识别中的研究与应用 [J]. 中国农机化学报, 2022, 43: 146-52.
- [9] 唐志国, 曹智, 何宁辉. 卷积神经网络迁移学习在局部放电类型诊断中的应用 [J]. 高压电器, 2022, 58(04): 158-64.
- [10] Pinto N, Cox D D, DiCarlo J J. Why is real-world visual object recognition hard? [J]. PLoS Comput Biol, 2008, 4(1): e27.
- [11] 赵凯琳, 靳小龙, 王元卓. 小样本学习研究综述 [J]. 软件学报, 2021, 32(02): 349-69.
- [12] Deng J, Dong W, Socher R, et al. Imagenet: A large-scale hierarchical image database; proceedings of the 2009 IEEE conference on computer vision and pattern recognition, F, 2009 [C]. Ieee.
- [13] Yosinski J, Clune J, Bengio Y, et al. How transferable are features in deep neural networks? [J]. CoRR, 2014, abs/1411.1792: 1411.792.