

文章编号: 1671-251X(2022)08-0050-07

DOI: 10.13272/j.issn.1671-251x.2022050026

基于改进反馈神经网络的煤矸石图像分类模型

闫洪霖

(西安科技大学 电气与控制工程学院, 陕西 西安 710054)

摘要: 现有的基于深度学习的图像分类方法存在分类模型参数量大、耗时长、分类精度低,难以在模型轻便和分类精度上达到折衷。针对上述问题,提出了一种基于改进反馈神经网络(Feedback-Net)的煤矸石图像分类模型。在 ResNet50 模型的基础上搭建 Feedback-Net 模型,通过在 ResNet50 模型搭建反馈通路,将高低阶信息进行融合,从而提升特征的表现能力。针对搭建的 Feedback-Net 模型在分类准确率提升的同时耗时有所增加的问题,将 Feedback-Net 模型中的方形卷积核改进为非对称卷积块(ACB),通过叠加融合的方式增加卷积核的特征提取能力;将参数量最多的全连接层转换为全局协方差池化(GCP),以降低网络参数量。通过模拟煤矿井下煤矸石分拣环境,以验证 Feedback-Net 模型和改进 Feedback-Net 模型(Feedback-Net+ACB 和 Feedback-Net+ACB+GCP)的性能。结果表明:① Feedback-Net 模型在精度上高于 ResNet50 模型,损失值略低于 ResNet50 模型。② Feedback-Net 模型训练精度较 ResNet50 模型提升了 1.20%,测试精度提升了 1.21%,但训练耗时较 ResNet50 模型增加了 0.22%。③ Feedback-Net+ACB+GCP 模型精度高于 Feedback-Net 和 Feedback-Net+ACB 模型,其收敛速度在 3 个模型中 fastest,具有最优性能。④ Feedback-Net+ACB 模型测试精度、训练精度均较 Feedback-Net 模型提升了 1.39%,且耗时减少了 15.53 min,Feedback-Net+ACB+GCP 模型训练精度、测试精度较 Feedback-Net 模型分别提升了 1.62%,1.59%,耗时缩短了 1.12%;Feedback-Net+ACB+GCP 模型耗时较 Feedback-Net+ACB 模型减少了 50.38 min,性能更加优越。

关键词: 煤矸石分类; 图像分类; 反馈神经网络; 图像特征提取; Feedback-Net; 非对称卷积; 全局协方差池化

中图分类号: TD948

文献标志码: A

Coal and gangue image classification model based on improved feedback neural network

YAN Honglin

(College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: The existing image classification methods based on deep learning have the problems of the large number of classification model parameters, long time consumption and low classification precision. It is difficult to achieve a compromise between the portability of the model and the classification precision. In order to solve the above problems, a coal and gangue image classification model based on improved Feedback-Net is proposed. The Feedback-Net model is built on the basis of the ResNet50 model. The high-order information and the low-order information are fused by building a feedback path in the ResNet50 model. Therefore, the representation capability of the features is improved. The constructed Feedback-Net model consumes more time while improving the classification accuracy. In order to solve this problem, the square convolution block in the Feedback-Net model is improved into an asymmetric convolution block (ACB). The feature extraction capability of the convolution kernel is increased by superposition and fusion. The full connection layer with the largest number of parameters is replaced by global covariance pooling (GCP) to reduce the number of network parameters. By simulating the

收稿日期: 2022-05-10; 修回日期: 2022-08-08; 责任编辑: 王晖, 郑海霞。

作者简介: 闫洪霖(2001—), 男, 陕西富平人, 主要研究方向为智能机器人、电力系统及自动化, E-mail: 1344827177@qq.com。

引用格式: 闫洪霖. 基于改进反馈神经网络的煤矸石图像分类模型[J]. 工矿自动化, 2022, 48(8): 50-55, 113.

YAN Honglin. Coal and gangue image classification model based on improved feedback neural network[J]. Journal of Mine Automation, 2022, 48(8): 50-55, 113.



扫码移动阅读

environment of coal and gangue sorting in coal mines, the performance of the Feedback-Net model and the improved Feedback-Net model (Feedback-Net + ACB and Feedback-Net + ACB + GCP) is verified. The results show the following points. ① The precision of the Feedback-Net model is higher than that of the ResNet50 model, and the loss value is slightly lower than that of the ResNet50 model. ② Compared with the ResNet50 model, the training precision of the Feedback-Net model is improved by 1.20%. The testing precision is improved by 1.21%, but the training time is increased by 0.22%. ③ The precision of the Feedback-Net + ACB + GCP model is high than that of the Feedback-Net and Feedback-Net + ACB model. The Feedback-Net + ACB + GCP model's convergence rate is the fastest among the three models. It has the best performance. ④ Compared with the Feedback-Net model, the testing precision and training precision of the Feedback-Net + ACB model are improved by 1.39%. The time consumption is reduced by 15.53 minutes. Compared with the Feedback-Net model, the training precision and testing precision of the Feedback-Net + ACB + GCP model are improved by 1.62% and 1.59% respectively. The time consumption is reduced by 1.12%. Compared with the Feedback-Net+ACB model, the time consumption of the Feedback-Net+ACB+GCP model is reduced by 50.38 minutes. The performance of the Feed-Net+ACB+GCP model is better.

Key words: coal and gangue classification; image classification; feedback neural network; image feature extraction; Feedback-Net; asymmetric convolution; global covariance pooling

0 引言

煤炭是我国的主要能源,在能源结构中长期占据主导地位^[1-2]。煤炭开采过程中,依靠工人经验控制采煤机掘进角度时,易产生矸石。煤矸石混合后会影响煤炭的热值,降低利用率;矸石燃烧后会产生大量有害气体,加重大气环境污染。因此,在煤炭利用前,必须对煤矸石进行分类。常用的煤矸石分类方法以密度、硬度、纹理等为分类特征^[3-6],但此类方法成本高、辐射大、维修难,不适宜大规模投入使用。

随着深度学习的快速发展,尤其是卷积神经网络的发展,基于深度学习的图像处理方法在目标分类领域应用广泛。文献[7]提出的 ResNet 网络通过残差连接方式解决了卷积层数加深后的梯度消失问题,在保证图像分类准确率的同时使神经网络层数不断加深。文献[8]提出的 DenseNet 网络以前馈连接方式将每一层卷积与该层前面的所有卷积层相连,并将网络中连接层数设置较小,降低了模型冗余,网络模型所需参数少。文献[9]提出的 MobileNet 网络基于流线型架构,使用深度可分离卷积来构建轻量级深度神经网络。然而,上述方法存在分类耗时长、参数量大、分类精度较低等缺点,难以在模型轻便和分类精度上达到折衷。

反馈神经网络(Feedback-Net)具有较强的计算能力,能够不加深网络层数、不添加大量参数的情况下进行模型的高效计算,这一特性有利于实现模型的轻量化^[10-11]。因此,本文提出了基于改进 Feedback-Net 的煤矸石图像分类模型。以 ResNet50 模型作为基本网络搭建 Feedback-Net 模型,在 ResNet50 模型

基础上搭建反馈通路,将高低阶信息进行融合,提升 Feedback-Net 模型的分类准确率,但网络耗时会有所增加。为了降低网络耗时,对 Feedback-Net 模型进行改进,在 Feedback-Net 模型中加入非对称卷积块(Asymmetric Convolution Block, ACB),ACB 可在不增加网络耗时的同时提取更丰富的图像特征;采用全局协方差池化(Global Covariance Pooling, GCP)替换 Feedback-Net 模型中的全连接层,以降低网络参数量,改进后的 Feedback-Net 模型在图像分类的任务中性能有明显提升。

1 Feedback-Net 模型

1.1 ResNet50 模型结构

本文选择 50 层残差网络作为煤矸石分类实验的基本网络,ResNet50 模型结构如图 1 所示^[12-15]。




图 1 ResNet50 模型结构

Fig. 1 ResNet50 model structure

首先,将煤矸石原始采集图像输入 ResNet50 模型。然后,通过 stage0, stage1, stage2, stage3, stage4 5 个阶段对输入图像进行特征提取。最后,将经过特征提取的图像输入 softmax 函数进行分类和输出。stage 结构如图 2 所示。stage0 主要是对输入图像作卷积和池化操作,广泛提取原始图像特征;stage1, stage2, stage3, stage4 分别由不同个数的 Bottleneck 结构组成,更加精细化地提取图像特征;stage1 和 stage4 包含了 3 个 Bottleneck 结构,stage2 和 stage3 则

包含更多。网络层数的增加和模型结构的复杂化, 会增加模型分类耗时。




图 2 stage 结构

Fig. 2 Stage structure

1.2 Feedback-Net 模型结构

本文在 ResNet50 模型的基础上进行 Feedback-Net 模型的搭建。以 stage1 为例, stage1 反馈连接

结构如图 3 所示, 其中 T 为模型运行时间 ($T=1, 2, \dots, t$), t 为运行过程中某一时刻。




图 3 stage1 反馈连接结构

Fig. 3 Stage1 feedback connection structure

Bottleneck 结构有 2 条分支, 一条分支包含 3 层卷积, 另一条分支包含 1 层卷积, 2 条分支的特征共同经过激活函数得到输出结果。为了增加网络提取特征的代表能力, 在 stage 的最后一层 Bottleneck 和第 2 层 Bottleneck 之间搭建一条通路进行信息反馈。将高低阶信息进行有效融合, 进而提升网络表征能力, 在不添加网络参数的情况下提取更多的图像特征。

每个 stage 块的输入是来自同一时刻中上个

stage 块的输出和上一时刻同一个 stage 块的输出, 二者进行高低阶信息融合 (如: $T=2$ 时刻, stage2 的输入为 $T=2$ 时刻 stage1 的输出与 $T=1$ 时刻 stage2 的输出融合)。

2 改进 Feedback-Net 模型

Feedback-Net 在进行特征融合的过程中耗时较长, 因此对网络结构中卷积核和全连接层进行改进, 以获取更好的煤矸石分类效果。

2.1 模型原理

采用 ACB 替代 Feedback-Net 中的方形卷积核, 用正交的卷积加强标准卷积层, 将 3 个分支卷积核进行相加, 从而提取更丰富的特征。ACB 通过叠加融合的方式来增强卷积核提取特征的能力, 在整个神经网络的计算过程中, ACB 无需引入额外的计算, 减少了推理时间。

ACB 结构如图 4 所示。设 Feedback-Net 模型中卷积核 $F = [F_1 F_2 \cdots F_c] \in \mathbf{R}^{d \times d \times C}$, 其中 F_c 为卷积层第 c 个通道卷积核, C 为卷积层通道总数, $d \times d$ 为卷积核大小。将卷积层中所有卷积核进行融合, 得到融合后的卷积层, 则该卷积层的卷积核为

$$F_{\text{fusion}}^1 = \begin{bmatrix} \frac{\gamma_1}{\sigma_1} F_1 & \frac{\gamma_2}{\sigma_2} F_2 & \cdots & \frac{\gamma_c}{\sigma_c} F_c \end{bmatrix} \quad (1)$$

式中: γ_c 为卷积层第 c 个通道的标准差; σ_c 为卷积层第 c 个通道的拟合标准差。




图 4 ACB 结构

Fig. 4 Asymmetric convolution block structure

将融合后并行的 3 个卷积层合并, 得到 1 个新的卷积层, 该卷积层卷积核为

$$F_{\text{fusion}}^2 = F_{\text{fusion}}^1 \oplus \bar{F}_{\text{fusion}}^1 \oplus \hat{F}_{\text{fusion}}^1 \quad (2)$$

式中: $\bar{F}_{\text{fusion}}^1$ 为 ACB 中的横向卷积核; $\hat{F}_{\text{fusion}}^1$ 为 ACB 中的纵向卷积核。

传统的平均池化和最大池化只能利用特征图之间的一阶信息, 而 GCP 更关注卷积层输出的特征图之间的关联性。相比于全连接层, GCP 能够提升收敛速度, 加速学习率的衰减, 对不同视觉任务有良好的泛化能力。因此, 采用 GCP 替代反馈网络中的全连接层。

采用协方差矩阵表示不同特征图 G_i 各通道间关联性的, 特征图 G_i 的协方差矩阵为

$$\Sigma = \begin{bmatrix} \text{cov}(g_1, g_1) & \text{cov}(g_1, g_2) & \cdots & \text{cov}(g_1, g_j) \\ \text{cov}(g_2, g_1) & \text{cov}(g_2, g_2) & \cdots & \text{cov}(g_2, g_j) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(g_i, g_1) & \text{cov}(g_i, g_2) & \cdots & \text{cov}(g_i, g_j) \end{bmatrix} \quad (3)$$

式中 $\text{cov}(g_i, g_j)$ 为 g_i 与 g_j 之间的协方差, $g_i (i=1, 2, \dots,$

$C), g_j (j=1, 2, \dots, C, j \neq i)$ 为特征图 G_i 拉直后的列向量。

2.2 模型设计

采用 ResNet50 模型作为基本模型, 对 Feedback-Net 模型中卷积核和全连接层进行改进。

(1) 加入 ACB。在 ResNet50 模型中加入传统的方形卷积核, 得到 Feedback-Net 模型(图 5)。若要提取丰富的特征就要不断加深网络层数, 这样不但会增加网络的计算量, 还会增加网络耗时。因此, 本文采用 ACB 代替方形卷积核, 在不增加网络耗时的同时使整个网络能够提取更丰富的特征。




图 5 Feedback-Net 模型

Fig. 5 Feedback-Net model

(2) 采用 GCP 代替 Feedback-Net 模型中的全连接层, 可大大降低网络中的参数量。Feedback-Net 模型存在 2 次池化, 第 1 个是 stage0 后的 3×3 最大池化, 第 2 个是 stage4 后的平均池化。保持 Feedback-Net 模型第 1 个池化(stage0 后的 3×3 最大池化)不变, 在 Feedback-Net 模型基础上加入 GCP(图 6), 在降低网络耗时的同时可进一步提升模型的表现。




图 6 改进 Feedback-Net 模型

Fig. 6 Improved Feedback-Net Model

3 实验结果

3.1 数据采集

为了验证 Feedback-Net 模型和改进 Feedback-Net 模型的性能, 通过模拟煤矿井下煤矸石分拣环境, 采集 6 861 张煤矸石图像作为数据集, 训练集和测试集按比例 8:2 进行划分。煤矸石数据集如图 7 所示。

整个训练迭代次数为 200, 学习率为 0.001, 并在每次迭代时将此学习率乘以一个常数因子 0.2, 来探寻最佳学习率。在 Feedback-Net 模型训练过程中不同卷积层级特征提取如图 8 所示。

3.2 Feedback-Net 模型实验结果

Feedback-Net 模型与 ResNet50 模型训练精度收



图 7 煤矸石数据集




图 8 Feedback-Net 模型中不同卷积层级特征提取

Fig. 8 Feature extraction of different convolution levels in the Feedback-Net model

收敛过程如图 9 所示。可看出 Feedback-Net 模型对于煤矸石图像分类的准确率有所提升。在前 50 轮迭代时, Feedback-Net 模型训练精度提升较快, 这是因为 Feedback-Net 通过反馈通路将高低阶信息进行融合, 提升了特征图的表征能力。




图 9 Feedback-Net 模型与 ResNet50 模型训练精度收敛过程

Fig. 9 Training precision convergence process of the feedback-Net model and the ResNet50 model

Feedback-Net 模型与 ResNet50 模型的损失值收敛过程如图 10 所示。可看出在前 50 轮迭代中损失值下降较快, 二者均在约 100 轮迭代处收敛。




图 10 Feedback-Net 模型与 ResNet50 模型的损失值收敛过程

Fig. 10 The Loss value convergence process of the Feedback-Net model and the ResNet50 model

实验结果表明, Feedback-Net 模型在精度上高于 ResNet50 模型, 损失值略低于 ResNet50 模型。

采用训练耗时、训练精度、测试精度作为性能指标, 综合评价各模型性能。Feedback-Net 模型与 ResNet50 模型性能对比见表 1。可看出 Feedback-Net 模型训练精度较 ResNet50 模型提升了 1.20%, 测试精度提升了 1.21%; Feedback-Net 模型的训练耗时较 ResNet50 模型增加了 0.22%。这是由于 Feedback-Net 模型在特征融合时需要时间处理, 增加了网络的整体训练耗时。

表 1 Feedback-Net 模型与 ResNet50 模型性能对比

Table 1 Performance comparison between the Feedback-Net model and the ResNet50 model

模型	评价指标		
	训练耗时/min	训练精度	测试精度
ResNet50	9 963.42	0.934 5	0.934 5
Feedback-Net	9 985.35	0.945 7	0.945 7

3.3 改进 Feedback-Net 模型实验结果

在 Tensorflow 框架中分别搭建 Feedback-Net 模型搭载 ACB(Feedback-Net+ACB) 和 Feedback-Net 模型搭载 ACB、GCP(Feedback-Net+ACB+GCP) 2 个模型。并对上述模型进行训练, 调整模型参数, 取得最优结果。设批尺寸为 16, 整个训练迭代次数为 500, 学习率为 0.001。

各模型在训练过程中的损失值与精度收敛过程分别如图 11、图 12 所示。可看出 Feedback-Net+ACB+GCP 模型在训练过程中精度高于其他 2 个模型, 其收敛速度在 3 个模型中最高; 同时 Feedback-Net+ACB+GCP 模型的损失值在训练过程中低于其他 2 个模型, 其损失值曲线率先趋于稳定并长期低于 Feedback-Net 模型, 说明 Feedback-Net+ACB+GCP 模型具有最优性能。这是因为采用 ACB 代替 Feedback-Net 模型中的方形卷积核后, 增强了卷积内核, 在不增加网络耗时的情况下提取更丰富的特征。




图 11 各模型损失值收敛过程

Fig. 11 Convergence process of the loss value for each model




图 12 各模型训练精度收敛过程

Fig. 12 Training precision convergence process of each model

Feedback-Net 模型、Feedback-Net+ACB 模型与 Feedback-Net+ACB+GCP 模型性能对比见表 2。可看出 Feedback-Net+ACB 模型测试精度、训练精度均较 Feedback-Net 模型提升了 1.39%, 且耗时减少了 15.53 min; Feedback-Net+ACB+GCP 模型训练精度、测试精度较 Feedback-Net 模型分别提升了 1.62%, 1.59%, 耗时缩短了 1.12%; Feedback-Net+ACB+GCP 模型耗时较 Feedback-Net+ACB 模型减少了 50.38 min, 这是因为采用 GCP 替代全连接层, 参数量降低, 运行速度提升, 性能更加优越。

表 2 各模型性能对比

Table 2 Performance comparison of each model

模型	评价指标		
	训练耗时/min	训练精度	测试精度
Feedback-Net	5 869.73	0.962 8	0.963 1
Feedback-Net+ACB	5 854.20	0.976 2	0.976 5
Feedback-Net+ACB+GCP	5 803.82	0.978 4	0.978 4

4 结语

为了实现煤矸石图像的快速高效分类, 在 ResNet50 模型的基础上搭建 Feedback-Net 模型构成反馈通路, 将高低阶信息进行融合, 提升了特征图的表现能力, 但该模型分类耗时有所增加。在 Feedback-Net 模型基础上进行改进, 引入 ACB 与 GCP 得到性能更好的改进 Feedback-Net 模型。实验结果表明: Feedback-Net 模型训练精度较 ResNet50 模型提升了 1.20%, 测试精度提升了

1.21%, 但训练耗时较 ResNet50 模型增加了 0.22%。Feedback-Net+ACB 模型测试精度、训练精度均较 Feedback-Net 模型提升了 1.39%, 且耗时减少了 15.53 min; Feedback-Net+ACB+GCP 模型训练精度、测试精度较 Feedback-Net 模型分别提升了 1.62%, 1.59%, 耗时缩短了 1.12%; Feedback-Net+ACB+GCP 模型耗时较 Feedback-Net+ACB 模型减少了 50.38 min, 性能更加优越。

参考文献(References):

[1] 赵志成, 柳群义. 中国能源战略规划研究——基于能源消费、能源生产和能源结构的预测[J]. 资源与产业, 2019, 21(6): 1-8.
ZHAO Zhicheng, LIU Qunyi. China's energy strategic planning based on prediction of energy consumption, production and structure[J]. Resources & Industry, 2019, 21(6): 1-8.

[2] 谢和平, 吴立新, 郑德志. 2025 年中国能源消费及煤炭需求预测[J]. 煤炭学报, 2019, 44(7): 1949-1960.
XIE Heping, WU Lixin, ZHENG Dezhi. Prediction on the energy consumption and coal demand of China in 2025[J]. Chinese Journal of Coal, 2019, 44(7): 1949-1960.

[3] 曹现刚, 李莹, 王鹏, 等. 煤矸石识别方法研究现状与展望[J]. 工矿自动化, 2020, 46(1): 38-43.
CAO Xiangang, LI Ying, WANG Peng, et al. Research status of coal-gangue identification methods and its prospect[J]. Industry and Mine Automation, 2020, 46(1): 38-43.

[4] 曹现刚, 费佳浩, 王鹏, 等. 基于多机械臂协同的煤矸石分拣方法研究[J]. 煤炭科学技术, 2019, 47(4): 7-12.
CAO Xiangang, FEI Jiahao, WANG Peng, et al. Study on coal-gangue sorting method based on multi-manipulator collaboration[J]. Coal Science and Technology, 2019, 47(4): 7-12.

[5] 高新宇. 基于机器视觉的煤矸智能识别分选系统设计[D]. 太原: 太原理工大学, 2021.
GAO Xinyu. Design of intelligent separation system for coal and gangue based on machine vision[D]. Taiyuan: Taiyuan University of Technology, 2021.

[6] 孙立新. 基于卷积神经网络的煤矸石识别方法研究[D]. 邯郸: 河北工程大学, 2020.
SUN Lixin. Research on coal gangue recognition method based on convolutional neural network[D]. Handan: Hebei University of Engineering, 2020.

[7] HE Kaiming, ZHANG Xiangyu, REN Shaoping, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 2016: 770-778.