

机器学习在白血细胞图像识别中的应用

臧宇

(惠州市第一人民医院)

摘要: 人工识别白细胞效率低且易受人为因素影响, 传统计算机辅助算法则需人为的提取白细胞特征, 在编程提取这些特征时, 效率较低。机器学习方法可自动的提取图像特征, 可提高识别效率。本文将三种机器学习模型: AlexNet、ResNet 与 MobileNet 用于白细胞图像识别当中, 最后的实验结果表明, ResNet 在三种模型中识别率最高。

关键词: 机器学习; 医学图像处理; 目标识别

Abstract: Manual identification of leukocytes is inefficient and susceptible to human factors, while traditional computer-aided algorithms need to manually extract leukocyte features, which is inefficient when programming to extract these features. The machine learning method can automatically extract image features, which can improve the recognition efficiency. This paper uses three machine learning models: AlexNet, ResNet and MobileNet for white blood cell image recognition. The final experimental results show that ResNet has the highest recognition rate among the three models.

Key words: machine learning; medical image processing; target recognition

白细胞是人体内的免疫细胞, 是人体免疫系统重要的组成部分[1]。白细胞一般被分为五大类: 嗜中性粒细胞、嗜碱性粒细胞、嗜酸性粒细胞、淋巴细胞和单核细胞[2]。健康的人体中各类白细胞的含量一般处于一个正常范围内, 当某种白细胞的含量超出或低于正常值时, 预示着人体可能产生疾病[3]。所以各类白细胞的识别与计数有着重要的社会价值与临床意义。

传统的白细胞分类计数方法依赖人工, 一般是将细胞染色, 然后在显微镜下人工的分类, 该方法效率低、且分类效果容易收到人为因素的影响[3]。计算机辅助方法有着效率高、不受人为因素影响的优点, 早期的计算机辅助方法主要是基于形态学的, 人为的分析出白血细胞的特征, 使用形态学的方法将白血细胞从背景中分割出来, 达到分类的目的[4-5]。随着机器学习技术的发展, 机器学习技术在图像处理领域的优势慢慢显现出来, 相较于传统的基于形态学的图像处理方法, 机器学习技术可以替代人工提取图像特征, 有着更高的效率[6]。本文将比较由影响力的几种的机器学习图像处理模型: AlexNet、ResNet 与 MobileNet 应用于白血细胞图像识别, 为后续算法的改进提供思路。

1 机器学习模型

1.1 AlexNet 模型

AlexNet 由 Alex Krizhevsky 等人[7]提出, 在 ILSVRC-2012 竞赛中获得了第一名, 该模型对机器学习技术的发展有着很深的影响。该模型使用两块 GPU 进行计算, 大大提高了运算效率, 其结构见图 1。




图 1 AlexNet 模型结构图

由上图可看出, 该模型分为上下两部分, 一共 8 层。上下两部分分别对应两块 GPU, 第一层输入 $224 \times 224 \times 3$ 的图像, 卷积核的数量为 96, 每片 GPU 分别计算 48 个核, 卷积核大小为 $11 \times 11 \times 3$, stride (步长) 为 4, padding=0 (边缘填充数量)。第二层卷积核的数量为 256, 每个 GPU 计算 128 个卷积核, 卷积核大小为 $5 \times 5 \times 48$, stride=1, padding=2, 然后进行局部归一化处理, 最后通过一个最大池化层处理, 池化尺寸为 (3,3), stride=2。第三层与第四层的卷积核数量均为 384, 卷积核大小为 $3 \times 3 \times 192$, padding=1, 均没有做局部归一化处理与最大池化层。第五层为 256 个卷积核, 卷积核大小为 $3 \times 3 \times 128$, padding=1, 然后直接进行最大池化, 池化尺寸为 3×3 , stride=2。第六至第八层为全连接层, 每一层的神经卷个数为 4096, 并使用了 Dropout (抑制过拟合), 最终输出为 1000。该模型的激活函数为 Relu。

1.2 ResNet 模型

ResNet 模型由 Kaiming He 等人[8]提出, 该模型学习形成的残差函数, 可以使网络层数大大增加, 成功训练除了 152 层的神经网络, 并在 ILSVRC2015 比赛中取得冠军。




图 2 残差学习单元

ResNet 模型的残差学习单元见图 2, 其主要思想是将输入与经过两个权重层处理后的输出做比较, 即学习上一个网络输出的残差。比较常用的是 50-layer、101-layer、152-layer, 其网络配置见表 1。

层名	输出尺寸	50-layer	101-layer	152-layer
conv1	112*112		7*7,64,stride 2	
conv2_x	56*56		3*3 max pool, stride 2	
		$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} * 3$	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} * 3$	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} * 3$
conv3_x	28*28	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} * 4$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} * 4$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} * 8$

conv4_x	14*14	$\begin{bmatrix} 1*1 & 256 \\ 3*3 & 256 \\ 1*1 & 1024 \end{bmatrix} * 6$	$\begin{bmatrix} 1*1 & 256 \\ 3*3 & 256 \\ 1*1 & 1024 \end{bmatrix} * 23$	$\begin{bmatrix} 1*1 & 256 \\ 3*3 & 256 \\ 1*1 & 1024 \end{bmatrix} * 36$
conv5_x	7&7	$\begin{bmatrix} 1*1 & 512 \\ 3*3 & 512 \\ 1*1 & 2048 \end{bmatrix} * 3$	$\begin{bmatrix} 1*1 & 512 \\ 3*3 & 512 \\ 1*1 & 2048 \end{bmatrix} * 3$	$\begin{bmatrix} 1*1 & 512 \\ 3*3 & 512 \\ 1*1 & 2048 \end{bmatrix} * 3$
	1*1		average pool, 1000-d fc, softmax	
FLOPs		$3.8*10^9$	$7.6*10^9$	$11.3*10^9$

表 1 不同深度的 ResNet 配置

1.3 MobileNet 模型

MobileNet 是由 Andrew 等人[9]提出,使用深度可分离卷积来构建轻量级深度神经网络。主要思想是把标准卷积分解成深度卷积和逐点卷积,分解过程如图 3。




图 3 a 中的标准卷积过滤器被替换为两层: b 中的深度卷积过滤器与 c 中的逐点卷积过滤器,以此构建深度可分离卷积过滤器

深度卷积的计算公式见式 1, 其中 \$\hat{K}\$ 是深度卷积, 卷积核为 \$(D_c, D_s, 1, M)\$, 其中 \$m_n\$ 个卷积核应用在 \$F\$ 中第 \$m_n\$ 个通道上, 产生 \$\hat{G}\$ 上第 \$m_n\$ 个通道输出。深度分离卷积结构见图 4。

$$\hat{G}_{k,i,m} = \sum_{i,j} \hat{K}_{i,j,m} * F_{k+i-1,j-1,m(1)}$$




图 4 深度间距结构

2 实验

本次实验使用的数据是 BCCD 数据集, 该数据集共包含 12447 张白血细胞加强图像, 使用其中 9957 张用于训练模型, 2490 张用于验证模型分类效果。该数据集包含了四种白血细胞类型: 嗜酸性细胞、淋巴细胞、单核细胞与中性粒细胞, 训练集有 2497 张嗜酸性细胞图片, 2483 张淋巴细胞图片, 2458 张单核细胞图片与 2499 张中性粒细胞图片。测试集有 623 张嗜酸性细胞图片, 620 张淋巴细胞图片, 620 张单核细胞与 624 张中性细胞图片。因数据集中没有提供嗜碱性粒细胞图, 所以本文未对嗜碱性粒细胞进行识别。AlexNet、ResNet 与 MobileNet 三种模型的学习率为 0.0005, 迭代次

数均为 30 次, 取验证准确率最高的值代表该模型分类效果, 实验结果见表 2。

	AlexNet	ResNet	MobileNet
嗜酸性细胞	0.236	0.732	0.534
淋巴细胞	0.264	0.718	0.561
单核细胞	0.253	0.701	0.550
中性粒细胞	0.251	0.705	0.519
平均值	0.251	0.714	0.541

表 2 三种模型实验结果

由表 2 可看出, 使用 ResNet 模型对白血细胞图像进行分类的效果最好。

3 总结

本文首先介绍了三种比较有影响力的机器学习模型, 然后将这三种模型应用于白血细胞图像的识别中, 实验得到三种模型中 ResNet 模型对白血细胞图片分类效果最好, 但是识别效果距人工识别仍有较大差距, 后续可对 ResNet 模型进行优化, 达到更好的效果。

参考文献

- [1] 杨勇超. 基于卷积神经网络的白细胞分类识别算法研究[D]. 西安科技大学, 2021, 1.
- [2] Khamael AL-Dulaimi, Jasmine Banks, Vinod Chandran, Inmaculada Tomeo-Reyes, Kien Nguyen. Classification of White Blood Cell Types from Microscope Images: Techniques and Challenges[J]. ResearchGate, 2018, 11, 17-25.
- [3] Li Ma, Renjun Shuai, Xuming Ran, Wenjia Liu, Chao Ye. Combining DC-GAN with ResNet for blood cell image classification[J]. Medical&Biological&Engineering&Computing, 2020, 58, 1251-1264.
- [4] Azam B, Qureshi RJ, Jan Z, Khattak TA. Color based segmentation of white blood cells in blood photomicrographs using image quantization[J]. Res J Recent Sciences, 2014, 2277: 2502 - 9.
- [5] Zahra Khandan Khadem Alreza, Alireza Karimian. Design a new algorithm to count white blood cells for classification Leukemic Blood Image using machine vision system[J]. IEEE Xplore, 2017.
- [6] Khamael Abbas, Jasmine Banks, V.Chandran, Inmaculada Tomeo-Reyes. ImageNet Classification with Deep Convolutional Neural Networks[J]. Microscopy Science, 2018, 17-25.
- [7] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. ImageNet classification with deep convolutional neural networks. Commun[J]. ACM 60, 2017, 84 - 90.
- [8] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)[J], 2016, pp. 770-778.
- [9] Howard A.G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications[J]. 2017.