

基于改进卷积神经网络的毛发显微图像自动分类

姜晓佳, 高树辉*

中国人民公安大学刑事科学技术学院, 北京 102623

摘要 利用卷积神经网络对毛发物证显微图像进行自动分类, 为进一步提高显微检验技术的自动化程度和毛发物证检验提供技术参考。采用徕卡 DVM6 数码显微镜在 1400 倍放大条件下采集 6 类毛发共 60000 张样本图像, 构建毛发分类数据集。基于卷积神经网络搭建 Hair-Net 模型, 通过该模型对毛发分类数据集进行样本训练和测试验证。实验研究表明, 经过参数调试和优化手段的改进后, 新的 Hair-Net 分类精度最高可达 97.82%, 成功实现了毛发物证显微图像的自动分类, 增强了稳健性。

关键词 图像处理; 毛发物证; 卷积神经网络; 显微图像; 图像分类

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.231002

Automatic Classification of Microscopic Hair Images Based on Improved Convolutional Neural Network

Jiang Xiaojia, Gao Shuhui*

Institute of Forensic Science, People's Public Security University of China, Beijing 102623, China

Abstract This paper uses a convolutional neural network to automatically classify microscopic images of hair evidence with the aim of enhancing the automation of microscopic technology and providing technical reference for test efficiency. Six kinds of microscopic hair images are collected via Leica DVM6 microscope and are magnified 1400 times to form the sample image dataset which contains 60000 images. The network model Hair-Net based on the convolutional neural network is used to conduct sample training and testing using different parameters. Experimental results show that the classification accuracy of improved Hair-Net can reach 97.82% after parameter testing and optimization, demonstrating that this method can realize automatic classification of microscopic hair images and enhance the robustness.

Key words image processing; hair evidence; convolutional neural network; microscopic image; image classification

OCIS codes 100.2000; 100.5010; 100.4996; 110.5200; 150.0155

1 引言

因显微照相在毛发微观结构分析领域中的广泛应用, 结合形态学检验对毛发进行种属判别或致伤原因分析, 为毛发物证的检验创造了新的契机。作为物证检验的重要组成部分, 毛发物证在侦查破案中发挥着不可替代的重要作用, 尤其在凶杀、强奸等案件或自杀现场, 其往往对证实犯罪行为、缩小侦查范围起着至关重要的作用。常规的毛发物证检验方

法首先需确定现场提取的物证是否为人类毛发, 根据毛发来源分析其与案件之间的联系。在 DNA 缺失的情况下, 通常可对毛发中的微量元素、角蛋白等成分进行化学检验定性定量分析^[1], 但此方法专业性强且成本较高。传统的毛发形态学检验主要依靠以往经验及参考资料进行镜检分析, 通过对比检验中获取的毛发种类^[2]、附着物^[3]、损伤情况^[4]等排它属性特征可为侦破案件确定筛查范围。毛发的信息容量越丰富, 侦查工作将愈发迅速高效, 但目前人工

收稿日期: 2019-04-29; 修回日期: 2019-05-15; 录用日期: 2019-05-27

基金项目: 中国人民公安大学基本科研业务费(2018JKF219)、上海市现场物证重点实验室开放课题基金(2018XCWZK24)

* E-mail: gaoshuhui@ppsuc.edu.cn

镜检寻找特征并进行分析比对的方法易受主观因素影响,且工作量较大,耗时费力难以避免误差,侦查效率低下,易使侦破抓捕工作错过最佳时机。因此亟需一种基于图像处理与分析的毛发显微图像分类方法,从形态学角度对毛发进行无损检验、分类识别,以提高毛发检验的自动化程度,为追踪锁定犯罪嫌疑人提供快速、有效的信息。

本文提出一种改进的基于卷积神经网络(CNN)对毛发显微图像进行快速自动分类的方法,通过高倍光学显微镜采集实验数据,再经预处理后构建6类毛发的实验数据集;搭建新的卷积神经网络结构 Hair-Net 进行训练学习,通过调试网络参数、数据增强等方法进行网络模型改进,从而提高网络识别率与稳健性,实现对毛发形态学的无损非接触性特征提取与分类检验,为毛发形态学检验提供快速获得信息的新途径。

2 卷积神经网络基本原理及其适用性

2.1 卷积神经网络及其基本结构

神经网络领域的研究起步较早,目前已呈多学科交叉的融合趋势^[5],其中卷积神经网络^[6]最基本的成分为神经元模型^[7]。两层神经元构成感知机模型,可实现逻辑运算和权重学习的复杂任务。而在输入层和输出层之间加入隐含层,形成多层功能神经元模型,则可解决多分类问题。卷积神经网络的学习过程就是根据训练数据不断调整神经元之间的相关连接,改变不同功能神经元的阈值,利用误差逆传播算法(BP算法)^[8],基于梯度下降策略沿目标的负梯度方向作参数调整、权值共享和并行运算,可大幅减少参数量^[9]。卷积神经网络的核心部分为隐含层,主要由卷积层、池化层与全连接层组成,卷积层与池化层通常是交替使用^[10],基本结构如图1所示。

卷积层主要是对输入的二维图像数据进行主

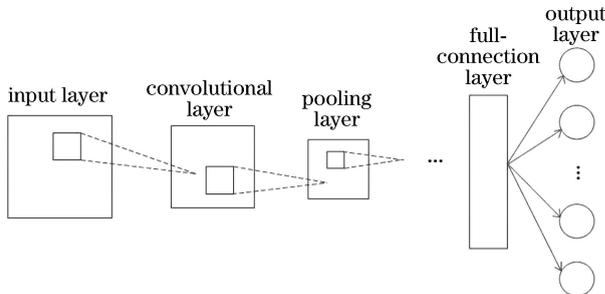


图1 卷积神经网络基本结构

Fig. 1 Basic structure of convolutional neural network

体特征提取,在卷积层内含有多个类似于前馈神经网络神经元的卷积核,它的每个元素都对应一个权重系数和偏差量。卷积核通过对输入二维数据图像进行特征点扫描,在感受野内对卷积特征矩阵元素作乘法求和并叠加偏差量来得到输出特征图^[11]。

池化层也称下采样层,其功能是忽略目标倾斜、旋转等相对位置的变化进行二维数据的采样,去除掉无关信息的影响,保存与分类训练有关的特征,起到二次提取的作用^[12]。池化层输入卷积层处理后的特征图,得到与池化前数量相同但分辨率更低的图像,由此获得特征图的空间不变性^[13]。代表性的池化操作主要有平均池化和最大池化2种,它们的区别主要在于计算特征点时对邻域的取值方式。

全连接层一般位于卷积神经网络隐含层的末尾段,作为网络终端的"分类器"^[14],它可对隐含层前部分操作中有特征差异性的局部特征进行整理,并且将二维数据中的细节信息图谱连接成一维数据。目前常用的网络模型通常采用ReLU函数作为全连接层的激励函数^[15],它可将卷积与降采样后输出的特征图通过非线性层的函数处理,生成一维特征图再进行输出与分类。

2.2 卷积神经网络在毛发形态学检验中的适用性

在以往案件中,曾多次出现:嫌疑人通过染发或戴假发来进行伪装犯罪;豢养宠物或家中饲养动物留下的毛发物证及其附着物等信息对犯罪侦破工作带来干扰。如果能检验确定毛发物证是否染色,或来自人与动物或其他纤维,都将在排除或锁定嫌疑人等方面发挥重要作用,有助于分析重建案件过程与现场情况。总而言之,仅凭肉眼是无法观察到毛发物证中的这些细节差异,需进一步进行镜检或其他形态学检验。

毛发微观形态学检验的关键在于特征提取与比对,对毛发显微图像实现自动特征提取与智能决策即可实现自动化识别,即通过对图像进行处理分析来识别不同模式目标或对象。随着人工智能、大数据时代的到来,模式识别技术不断发展成熟,得到了广泛的应用,其中,神经网络在图像分类与识别领域中可对二维图像进行采集处理、特征提取与自动识别^[16],尤其是卷积神经网络,其拓扑结构简单,可直接处理图像二维矩阵,减少了网络连接数和训练参数;特征提取和模式分类并行,摒弃了随机性强且耗时较长的显式提取过程;局部感知与全局共享

来自动提取原始图像的本质特征,能够精确分类,适合不同领域的多分类任务^[17],目前已被应用于人脸识别^[18-19]、笔迹识别^[20-21]、语音识别^[22-23]、行为识别^[24-25]等多个领域中。毛发显微图像与以往研究中的花卉图像、车标图像、岩石图像、植物叶片图像、纺织面料图像等类似,均可通过提取图像中的主体特征进行分类识别,可作为特征提取和分类识别未知图像的一种模式。将卷积神经网络引入毛发物证的形态学检验中,可最大限度地降低鉴定人员主观意识对检验鉴定结果的影响,同时还将缩短毛发分类检验时间,快速自动分类,实现信息提取的最大化,有效提高法医学物证检验技术的自动化程度。

3 实验材料与方法

3.1 实验样本

实验样本分为 3 大类。

第 1 大类为人类头发,来源于一名 24 岁女性志愿者,选取志愿者正常自然黑色头发,分为两部分,一部分为无处理的自然黑色头发,一部分为使用黑色染发剂染色 48 h 的漂染黑的白发;

第 2 大类为网购普通纤维丝自然黑色假发;

第 3 大类为动物毛发,分别为黑色狗毛、黑色猫毛、黑色鼠毛,采集部位为背中部的毛发中段。

将这 3 大类共 6 类毛发分别处理成 5 mm 左右长度的实验样本材料,分别使用透明胶带固定一根样本于一张载玻片上,盖好盖玻片,样本切片制作

完成。

3.2 实验数据采集

数据采集基于搭载 LASX 图像处理系统的徕卡 DVM 6 数码显微镜,放大倍数调整至 1400 倍。在 LASX 图像处理系统中,设置场景为全光模式,背景亮度值为 10,曝光值为 30,增益值为 1,图像格式为 Fast2MP,分辨率为 1600 pixel×1200 pixel,像质为 100%,位深为 8,在该模式下对不同毛发样本进行显微图像截取采集,每类样本采集 10000 余张。

3.3 实验样本数据集预处理

在采集的所有数据图像中去除有杂质及其他干扰的样本图像。每类毛发样本保存 10000 张数据,6 类共 60000 张样本图像。

使用 Matlab 对所有样本数据图像进行定点切割,利用坐标代码确定切割起始点,以固定区域大小截取样本图像中的毛发特征区域,去除与毛发内容无关的背景部分,防止丢失部分毛发特征,排除背景干扰。切割时注意保持所有毛发图像的长宽比相同。为方便实验操作及样本训练需对实验图像进行顺序命名,并利用双线性插值法对样本数据进行几何缩放,根据不同神经网络要求对图像尺寸的大小进行处理。给每一类样本数据生成类别标签,并随机抽取每类实验图像的 80% 作为训练集进行网络学习,剩余的 20% 作为验证集来考察网络性能。样本数据集转换为具有较高读写速度的 LMDB 格式文件。预处理后的部分样本数据集图像示例如图 2 所示。

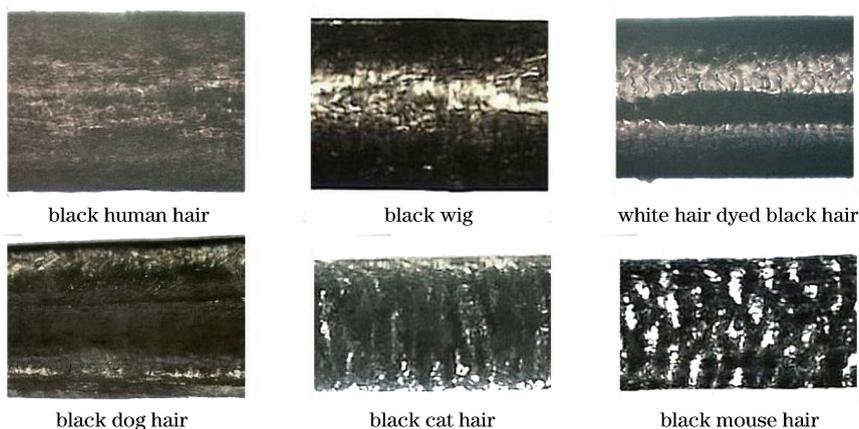


图 2 部分样本数据集图像示例

Fig. 2 Examples of sample dataset images

3.4 实验环境配置

实验环境的配置如表 1 所示。

3.5 网络模型结构设计及参数设置

针对建立的毛发显微图像数据集,提出一种新

的卷积神经网络结构 Hair-Net,具体网络配置如图 3 和表 2 所示。第一卷积层采用 9×9 的卷积核,便于提取细节特征,再使用两层 3×3 卷积核增加网络深度,在不增添计算量的同时保证网络训练速度,

表 1 实验环境配置及参数

Table 1 Experimental environment configuration and parameters

Software/hardware	Experimental configuration
CPU	Intel(R)4 Core(TM)i5-7200U, 2.50 GHz
GPU	NVIDIA GeForce 940MX
RAM	8.00 GB
Frame	Caffe
Tool	Matlab2016a, Python2.7, Visual
software	Studio 2013, Adobe Photoshop CS4

模型在每层卷积后连上 ReLU 激活函数;由于毛发显微图像的分类需要依靠毛发细节纹理形状,因此池化层全部采用最大池化,利于训练过程中对毛发特征的提取,将第二个全连接层(FC)的节点数设置为 1024,能控制网络宽度,可一定程度地提升性能;最后运用解决多分类问题的 Softmax 回归函数,结合 Center-loss 中心损失度量学习^[26]作为辅助损失函数^[27]得到分类值结果,将 Center-loss 的权重系数 λ 设为 0.001。

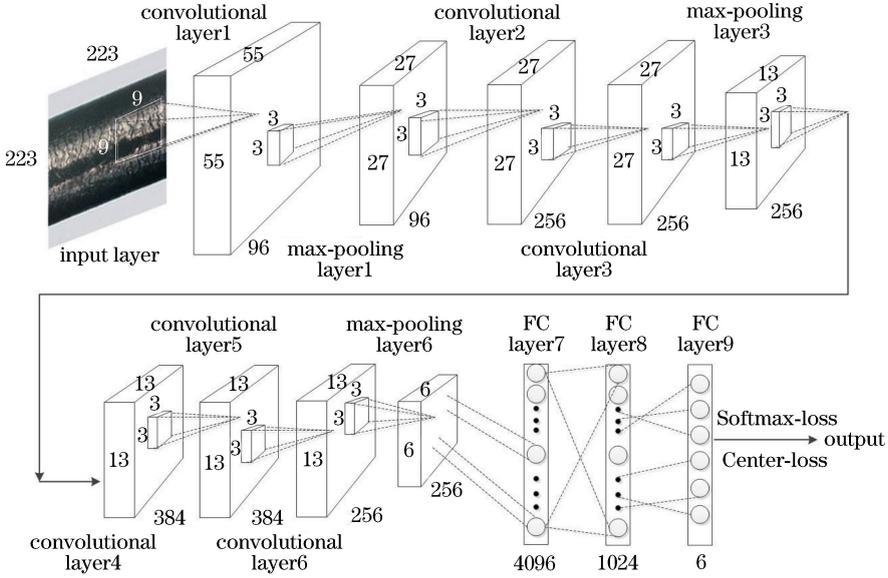


图 3 Hair-Net 的结构设计

Fig. 3 Structural design of Hair-Net

表 2 Hair-Net 的配置参数

Table 2 Configuration parameters of Hair-Net

Layer	Kernel size	Strides	Pad	Output size	Output number
Input				223×223	3
Convolution1+ ReLU1	9 * 9	4	1	55×55	96
Max pooling1	3 * 3	2	0	27×27	96
Convolution2+ ReLU2	3 * 3	1	1	27×27	256
Convolution3+ ReLU3	3 * 3	1	1	27×27	256
Max pooling3	3 * 3	2	0	13×13	256
Convolution4+ ReLU4	3 * 3	1	1	13×13	384
Convolution5+ ReLU5	3 * 3	1	1	13×13	384
Convolution6+ ReLU6	3 * 3	1	1	13×13	256
Max pooling6	3 * 3	2	0	6×6	256
Fully connected7+ ReLU7+ Dropout7				1×1	4096
Fully connected8+ ReLU8+ Dropout8				1×1	1024
Fully connected9				1×1	6
Output					6

3.6 实验算法流程设计

根据网络设计与毛发样本数据集分类的问题,

实验对从样本数据集的构建到分类测试网络性能的预测流程进行了设计与实现,流程图如图 4 所示。

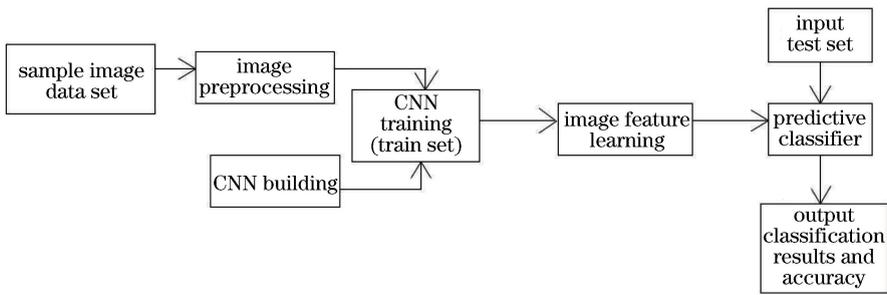


图4 毛发显微图像自动分类流程图

Fig. 4 Flow chart of automatic classification for microscopic hair images

4 实验结果分析与讨论

4.1 批尺寸对模型收敛情况及分类结果的影响

批尺寸(batch_size)是卷积神经网络中的重要参数,它标示着在模型训练或测试过程中一批次读入批量图片的数目。对于不同对象和目标的分类实验来说,根据迭代次数和实验样本数据集的大小来设定batch_size对于提高网络模型的训练效率与分类性能具有重要作用。对于小数据集来说,采用全数据集形式(batch_size等于数据集图片数目)可在训练中更好地确定极值所在方向,基于梯度符号有针对性地单独更新各权值;但当数据集较大时,样本数据增长和内存受限导致一次读入所有数据并不可行,以Rprop的方式进行迭代会因不同batch之间的样本选择差异致使各梯度修正值相互抵消而无法进行修正。

因此对于本分类实验来说, batch_size选择过小会导致修正方向不收敛,选择过大会由于迭代次数的减少造成参数修正过于缓慢,甚至计算机显存根本无法完成训练任务。因此实验选择批梯度下降法,在合理范围内增加batch_size,使网络模型达到最优收敛精度,提高内存利用率,控制训练振荡,提高数据处理速度和并行化效率,但这也增加训练时间和收敛难度,降低模型稳健性。由于训练使用图像处理器(GPU)进行,当batch_size为2的幂次时效率更高,因此经调参后采用最优参数组合,设置学习率为0.0003,最大迭代次数为100000, batch_size设置为16、32、64、128、256进行比较分析,如表3所示。

由表3可以看出,随着batch_size增大,网络性能确实有了一定的提升,损失函数不断下降,分类精度不断提升,但batch_size为256时,计算机已无法完成网络的样本训练,现有配置不能满足计算运行需求,因此在合理范围内选择batch_size尤为重要。

表3 批尺寸对实验结果的影响

Table 3 Effect of batch size on experimental results

Batch_size	Train accuracy / %	Loss	Test accuracy / %
16	76.15	1.149	72.43
32	83.42	0.822	80.97
64	88.50	0.709	86.39
128	94.81	0.388	93.66
256	Error	Error	Error

4.2 基于数据增强技术研究 crop_size 对实验结果的影响

卷积神经网络的分类任务一般需大量的带标签训练数据才能获得比较理想的分类结果。因此有学者提出,可通过数据增强技术对有限大小的数据集的训练图片进行随机变换来增加训练样本的多样性,以降低模型对某些属性的依赖,有效提高模型的稳健性,减少过拟合现象,使其更好地适应和解决不同的分类问题。例如, crop_size大于输入图片尺寸时,可使物体以不同比例出现在图像的各个位置,随机裁剪相当于建立了每个因子特征与相应类别的权重关系,减弱背景或噪音因子的权重,且能降低模型对目标位置的敏感性,增强模型稳定性。

在本实验中,为探究 crop_size对毛发分类结果的影响,使用 223×223 的 crop_size对训练样本进行随机裁剪,与输入图片大小为 227×227 和 223×233 两种样本数据格式对比。使用学习率为0.0003、最大迭代次数为100000来运行网络,实验结果如图5、图6所示。

数据增强技术在增加训练数据量的前提下可剪裁到样本图像的中心特征,使网络在训练过程中收敛更快、损失更小,能有效提升模型的分类精度与泛化能力,设置比样本数据原始图像稍小的 crop_size可作为优化模型的一种手段。

4.3 局部响应归一化与批正则化对分类结果的影响

局部响应归一化(LRN)来源于 AlexNet,广泛

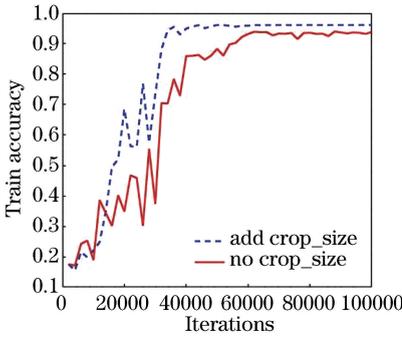


图5 使用 crop_size 前后的 Hair-Net 分类精度对比
Fig. 5 Comparison of Hair-Net classification accuracy with and without crop_size

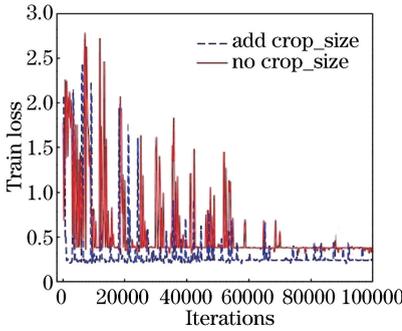


图6 使用 crop_size 前后的 Hair-Net 损失值对比
Fig. 6 Comparison of Hair-Net loss with and without crop_size

应用于 Tensorflow 等框架中,能模仿生物神经系统的侧抑制机制,通过激活局部神经元抑制相邻神经元,使响应较大的值更突出,以此加强模型的稳健性,提高识别精度。

批正则化(BN)是由 google 提出的一种训练优化方法,可解决网络训练过程中数据在中间层的分布发生改变的问题,有效防止梯度爆炸、加快训练和收敛速度。相比于 LRN, BN 优势较为明显,优势如下:其一,网络的每一层实际需要不同的学习率,而 BN 将每层、每维的 scale 归一化,可直接使用较高的初始学习率,显著提升训练速度;其二,训练时 BN 可将数据完全打乱,防止某一样本在每一批训练中常被选中,提高了网络泛化能力;其三, BN 可降低权重衰减系数,解决边界处在局部最优时权重斜率大的弊端,调整数据的权重分界面,有效防止过拟合。

实验将未使用归一化的 Hair-Net 模型与分别加入 LRN 和 BN 后的两种模型进行网络性能对比,得到表 4 的结果。

由表可见,基于 LRN 改进的 Hair-Net 对模型分类精度并无提升效果,而基于 BN 改进的 Hair-

表 4 LRN、BN 两种归一化对实验结果的影响

Table 4 Effects of LRN and BN on experimental results

Model structure	Train accuracy / %	Loss	Test accuracy / %
Hair-Net	96.15	0.247	95.32
Hair-Net+LRN	95.49	0.316	94.57
Hair-Net+BN	97.82	0.199	97.16

Net 则在增强模型稳健性的同时有效防止了过拟合现象,且模型分类准确率得到了有效提高,可以作为优化模型的技术手段进行下一步的实验研究。

4.4 实验结果综合分析

在 Hair-Net 中采用 batch_size 为 128,学习率为 0.0003、最大迭代次数为 100000 的最优参数组合进行样本训练,加入 crop_size 与 BN,最佳训练分类精度可达 97.82%。该网络中随着训练迭代次数的增长,分类精度和损失值的变化情况如图 7 和图 8 所示,可以看出训练迭代次数达到 50000 时测试精度超过 95%,而训练损失值随着精度的提高不断收敛至 0.2 左右。

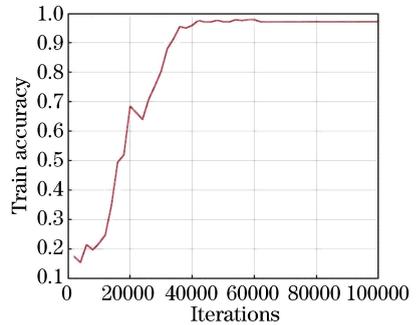


图7 网络性能最优状态下的分类精度
Fig. 7 Classification accuracy under optimal network performance

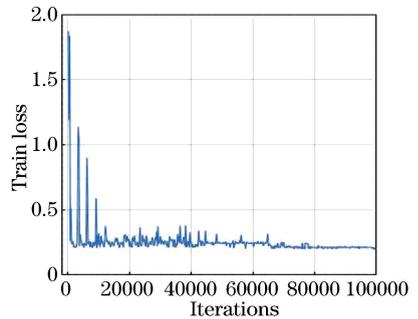


图8 网络性能最优状态下的损失

Fig. 8 Loss under optimal network performance

5 结 论

基于深度学习中的卷积神经网络设计了应用于毛发显微形态图像数据的自动快速分类方法。采集

6类样本毛发制成切片后,在1400倍徕卡DVM6数码显微镜下获得60000张样本数据图像,对数据进行预处理过程后建立小型毛发显微图像样本数据集,适用于本分类实验,并根据该分类问题设计搭建了新的卷积神经网络模型Hair-Net。通过Hair-Net对实验样本数据集中的6类样本数据进行训练学习及分类测试,通过多次调参并加入数据增强、批正则化等优化方式,对比分析实验结果得出,改进后的Hair-Net更为准确,高效的分类性能可有效保证97.82%的分类精度。下一阶段的实验研究将考虑样本图像数据种类的扩充与训练集合数据量的增加等影响识别精度与泛化能力的因素,引入更多先进的优化算法和函数手段来提升网络性能,为毛发形态学显微图像分类方法带来新的突破。

参 考 文 献

- [1] Zhang W, Xu Y C. A review and prospects of the research on hair microstructure [J]. *Acta Theriologica Sinica*, 2003, 23(4): 339-345.
张伟,徐艳春.毛发微观结构研究的回顾与展望[J].*兽类学报*, 2003, 23(4): 339-345.
- [2] Gan Y L, Guo Z W, Liu M H, *et al.* Scanning electron microscopy study of animal hair in criminal cases[J]. *Journal of Chinese Electron Microscopy Society*, 2003, 22(6): 489.
甘雅玲,郭中伟,刘明辉,等.刑事案件中动物毛发的扫描电镜研究[J].*电子显微学报*, 2003, 22(6): 489.
- [3] Zou Y, Quan Y K, Zhu Y C, *et al.* A study on the microtopography of gunshot damaged hair using ESEM [J]. *Chinese Journal of Forensic Medicine*, 2006, 21(6): 325-327.
邹友,权养科,朱永春,等.毛发枪弹损伤的环境扫描电镜研究[J].*中国法医学杂志*, 2006, 21(6): 325-327.
- [4] Zou Y, Tao K M, Li L X, *et al.* A study on the morphological characterizations of hair physical damage using ESEM [J]. *Forensic Science and Technology*, 2006(1): 4-6.
邹友,陶克明,李立新,等.毛发常见机械性损伤形态的环境扫描电镜研究[J].*刑事技术*, 2006(1): 4-6.
- [5] Szegedy C, Vanhoucke V, Ioffe S, *et al.* Rethinking the inception architecture for computer vision[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 2818-

2826.

- [6] Zhou F Y, Jin L P, Dong J. Review of convolutional neural network [J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251.
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.
- [7] Li Y D, Hao Z B, Lei H. Survey of convolutional neural network [J]. *Journal of Computer Applications*, 2016, 36(9): 2508-2515, 2565.
李彦冬,郝宗波,雷航.卷积神经网络研究综述[J].*计算机应用*, 2016, 36(9): 2508-2515, 2565.
- [8] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [9] He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [10] Chen X, Zhu R, Wang Z Y. Handwritten digits recognition based on fused convolutional neural network model [J]. *Computer Engineering*, 2017, 43(11): 187-192.
陈玄,朱荣,王中元.基于融合卷积神经网络模型的手写数字识别[J].*计算机工程*, 2017, 43(11): 187-192.
- [11] Zhong J Y, Yang B, Li Y H, *et al.* Image fusion and super-resolution with convolutional neural network [M] // Tan T, Li X, Chen X, *et al.* Pattern recognition. CCPR 2016. Communications in computer and information science. Singapore: Springer, 2016, 663: 78-88.
- [12] Xiao J S, Liu E Y, Zhu L, *et al.* Improved image super-resolution algorithm based on convolutional neural network [J]. *Acta Optica Sinica*, 2017, 37(3): 0318011.
肖进胜,刘恩雨,朱力,等.改进的基于卷积神经网络的图像超分辨率算法[J].*光学学报*, 2017, 37(3): 0318011.
- [13] Dong J F, Zheng B C, Yang Z J. Character recognition of license plate based on convolution neural network [J]. *Journal of Computer Applications*, 2017, 37(7): 2014-2018.
董峻妃,郑伯川,杨泽静.基于卷积神经网络的车牌字符识别[J].*计算机应用*, 2017, 37(7): 2014-2018.
- [14] Nguyen N G, Tran V A, Ngo D L, *et al.* DNA sequence classification by convolutional neural

- network [J]. *Journal of Biomedical Science and Engineering*, 2016, 9(5): 280-286.
- [15] Jiang S. Image recognition based on convolutional neural networks [D]. Changchun: Jilin University, 2017.
蒋帅. 基于卷积神经网络的图像识别 [D]. 长春: 吉林大学, 2017.
- [16] Gao H L. Military image classification based on convolutional neural network [J]. *Application Research of Computers*, 2017, 34(11): 3518-3520.
高惠琳. 基于卷积神经网络的军事图像分类 [J]. *计算机应用研究*, 2017, 34(11): 3518-3520.
- [17] Wang X, Liu Y, Li G Y. Moving object detection algorithm based on improved visual background extractor algorithm [J]. *Laser & Optoelectronics Progress*, 2019, 56(1): 011007.
王旭, 刘毅, 李国燕. 基于改进视觉背景提取算法的运动目标检测方法 [J]. *激光与光电子学进展*, 2019, 56(1): 011007.
- [18] Schroff F, Kalenichenko D, Philbin J. FaceNet: a unified embedding for face recognition and clustering [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 815-823.
- [19] Sun Y, Liang D, Wang X G, *et al.* DeepID3: face recognition with very deep neural networks [J/OL]. (2015-02-03) [2019-04-28]. <https://arxiv.org/abs/1502.00873>.
- [20] Hafemann L G, Sabourin R, Oliveira L S. Learning features for offline handwritten signature verification using deep convolutional neural networks [J]. *Pattern Recognition*, 2017, 70: 163-176.
- [21] Liang X L. Verification of off-line handwritten signature based on the improved neural network [D]. Beijing: China University of Political Science and Law, 2017.
梁曦璐. 基于改进神经网络的离线签名笔迹识别 [D]. 北京: 中国政法大学, 2017.
- [22] Abdel-Hamid O, Mohamed A R, Jiang H, *et al.* Convolutional neural networks for speech recognition [J]. *ACM Transactions on Audio, Speech, and Language Processing*, 2014, 22(10): 1533-1545.
- [23] Karpathy A, Toderici G, Shetty S, *et al.* Large-scale video classification with convolutional neural networks [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 1725-1732.
- [24] Li Y. Research on gait recognition based on three-dimensional convolutional neural network [D]. Beijing: Beijing Jiaotong University, 2018.
李影. 基于三维卷积神经网络步态识别方法的研究 [D]. 北京: 北京交通大学, 2018.
- [25] Zhao Y J, Zhou S P. Wearable device-based gait recognition using angle embedded gait dynamic images and a convolutional neural network [J]. *Sensors*, 2017, 17(3): 478.
- [26] Wen Y D, Zhang K P, Li Z F, *et al.* A discriminative feature learning approach for deep face recognition [M] // Leibe B, Matas J, Sebe N, *et al.* Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9911: 499-515.
- [27] Yu C B, Tian T, Xiong D E, *et al.* Joint supervision of center loss and Softmax loss for face recognition [J]. *Journal of Chongqing University*, 2018, 41(5): 92-100.
余成波, 田桐, 熊递恩, 等. 中心损失与 Softmax 损失联合监督下的人脸识别 [J]. *重庆大学学报*, 2018, 41(5): 92-100.