

基于改进深度卷积神经网络的纸币识别研究

盖杉* 鲍中运

(南昌航空大学信息工程学院 南昌 330063)

摘要: 针对如何提高纸币识别率的问题, 该文提出一种改进深度卷积神经网络(DCNN)的纸币识别算法。该算法首先通过融合迁移学习、带泄露整流(Leaky ReLU)函数、批量归一化(BN)和多层次残差单元构造深度卷积层, 对输入的不同尺寸纸币进行稳定而快速的特征提取与学习; 然后采用改进的多层次空间金字塔池化算法对提取的纸币特征实现固定大小的输出表示; 最后通过网络全连接层和softmax层实现纸币图像分类。实验结果表明, 该算法在分类性能、泛化能力与稳定性上明显优于常用的纸币分类算法; 同时该算法也能够满足纸币清分系统的实时性要求。

关键词: 纸币识别; 深度卷积神经网络; 残差学习; 空间金字塔池化

中图分类号: TP391.41; TP181

文献标识码: A

文章编号: 1009-5896(2019)08-1992-09

DOI: 10.11999/JEIT181097

Banknote Recognition Research Based on Improved Deep Convolutional Neural Network

GAI Shan BAO Zhongyun

(School of Information Engineering, Nanchang Hangkong University, Nanchang 330063, China)

Abstract: In order to improve the recognition rate of banknotes, the improved banknote recognition algorithm based on Deep Convolutional Neural Network(DCNN) is proposed. Firstly, the algorithm constructs a deep convolution layer by integrating transfer learning, Leaky-Rectified Liner Unit (Leaky ReLU) function, Batch Normalization(BN) and multi-level residual unit that perform stable and fast feature extraction and learning on input different size banknotes. Secondly, a fixed-size output representation of the extracted banknote features is obtained by using the improved multi-level spatial pyramid pooling algorithm. Finally, the banknote classification is implemented by the full connection layer and the softmax layer of the network. The experimental results show that the proposed algorithm can effectively improve the recognition rate of banknotes, and has better generalization ability and robustness than the traditional banknote classification method. Meanwhile, the algorithm can meet the real-time requirements of the banknote sorting system.

Key words: Banknote recognition; Deep Convolutional Neural Network (DCNN); Residual learning; Spatial pyramid pooling

1 引言

近年来, 基于数字图像处理技术的纸币清分系统逐渐取代人工劳作, 该系统是一种光机电一体化复杂的设备。纸币清分系统的核心功能是对纸币图像进行分析, 并根据结果进行分类与检测。鉴于纸

币的重要性, 如何提取稳定的分类特征与构造稳定的分类器是目前有待解决的难题之一。纸币清分系统的核心步骤是特征提取, 区分性好的特征将有利于后续识别性能的提升。目前常用的纸币特征提取方法主要有几何特征^[1]、自由掩模^[2]、网格特征^[3]。这些方法虽然在应用中取得了良好的效果, 但是其性能好坏取决于最优掩盖集与网格数量的选取。文献^[4]提出了一种基于小波变换的纸币图像特征提取方法, 通过预先设定的阈值在分解得到的高频子带上计算特征向量。在此基础上, 文献^[5]提出了一种基于四元小波变换的纸币图像特征提取算法, 该算法能够有效地弥补小波变换缺乏对纸币图像相位信息描述的缺陷。针对纸币在流通过程中不断磨损的

收稿日期: 2018-11-28; 改回日期: 2019-03-27; 网络出版: 2019-04-21

*通信作者: 盖杉 gaishan@nchu.edu.cn

基金项目: 国家自然科学基金(61563037), 江西省杰出青年计划(20171BCB23057)

Foundation Items: The National Natural Science Foundation of China(61563037), The Outstanding Youth Scheme of Jiangxi Province (20171BCB23057)

情况, 文献[6]采用统计模型描述纸币图像的退化过程, 进而实现对纸币图像退化过程的量化分析。

近年来随着计算机性能的进一步提高, 深度学习^[7,8]被大家所熟知并快速发展起来。深度卷积神经网络(Deep Convolutional Neural Network, DCNN)在训练时能够自动提取最有效的特征, 不仅突破了传统方法对图像特征提取的技术瓶颈, 同时也突破了物体识别、分类的技术瓶颈, 使得图像分类问题得到了更好的解决。文献[9]提出的AlexNet首次在深度卷积神经网络中成功地应用了线性整流函数(Rectified Linear Unit, ReLU)与局部响应归一化(Local Response Normalization, LRN), 使得构建的网络模型对图像特征的提取能力显著增强。文献[10]提出的VGGNet探索了卷积神经网络的深度与其性能之间的关系, 通过反复堆叠 3×3 的小型卷积核和 2×2 的最大池化层, 构造了16~19层深度的卷积神经网络, 实验结果表明其具有很强的拓展性。文献[11,12]采用Inception Net构建22层网络结构, 在有效控制计算复杂度和参数个数的同时, 增加了网络宽度, 获得了更强的表达能力和分类性能。文献[13]提出的残差网络(Residual Neural Network, ResNet)通过使用残差单元(Residual Unit)成功训练152层神经网络, 不仅能够提取图像更深层次的特征, 而且还能够快速地进行神经网络模型训练, 进而提升模型的分类精度。

受上述算法设计思想的启发, 本文充分考虑纸币图像数据的特点, 采用改进空间金字塔池化算法^[14]和多层次残差单元, 提出了一种基于改进深度卷积神经网络模型的纸币识别算法。本文算法首先通过迁移学习^[15]、Leaky ReLU函数、批量归一化

(Batch Normalization, BN)^[16]和多层次残差单元的卷积层对纸币图像更深层次特征进行快速提取与学习; 然后采用改进多层次空间金字塔池化算法对纸币图像特征进行降维和固定大小的输出表示; 最后通过本文构造的深度网络模型的全连接层和softmax层实现纸币图像的高效分类。

2 基于改进DCNN的纸币识别算法

本文在VGGNet-19网络构造框架基础上, 结合纸币图像自身的特性, 提出一种改进深度卷积神经网络框架。本文首先采用带泄露整流函数(Leaky-Rectified Linear Unit, Leaky-ReLU)作为本文网络中的激活函数; 然后在网络中的每个卷积层和激活函数之间添加一个批量归一化层, 并且去除原网络结构中的Dropout层; 最后在网络深层结构中引入3个不同的多层次残差单元, 并用改进的空间金字塔池化层代替原网络结构中最后一个最大的池化层。与此同时, 本文考虑到纸币种类以及网络训练效率, 采用全连接层fc-1024, fc-256, fc-5/6/7代替原网络中的全连接层fc-4096, fc-4096, fc-1000, 本文提出的深度网络结构如图1所示。在图1中, 为了简化结构示意图, 全连接层fc-4096, fc-4096, fc-1000直接用“全连接层”进行泛指。

本文设计的改进深度卷积神经网络结构主要包括4部分: (1) 对纸币图像进行亮度校正、边缘检测与倾斜校正等预处理; (2) 然后利用本文设计的卷积神经网络对校正后的纸币有效特征信息进行充分挖掘和更深层次的特征学习和提取; (3) 通过改进的多层次空间金字塔池化算法对提取的纸币特征从不同的角度进行固定大小的特征向量表示; (4) 采用全连接层和softmax分类器对纸币图像进行分类。

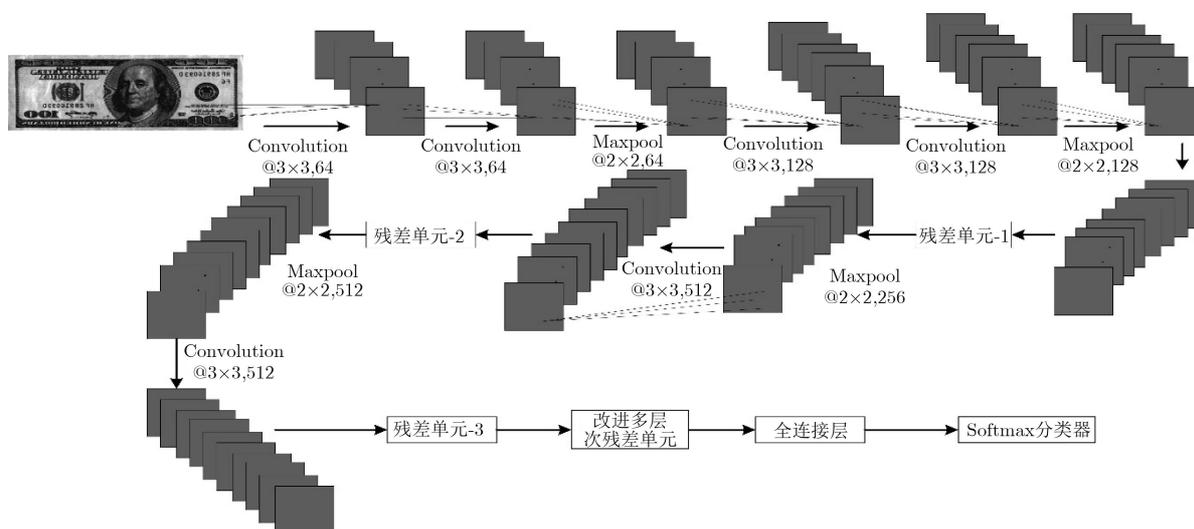


图1 算法结构示意图

2.1 纸币图像预处理

清分系统扫描装置对图像传感器进行模数转换后得到原始的纸币图像样本。由于自带光源传感器线阵上的每点存在差异性，导致纸币图像样本的各点光强不同。另外，纸币在清分系统中的运动是一个极其复杂的过程，它在传动轮和电机的带动下进行纵向的运动过程中必然存在一定程度的横向移动，这就会造成扫描得到的纸币图像存在一定程度的几何变形。因此，本文在进行特征提取和识别之前需要对纸币图像进行亮度校正和几何校正。针对残损纸币的情况，本文通过对纸币图像的残缺程度进行评估并引入拒识类的策略进行处理。如果，纸币图像的两条对边的残缺长度总和小于两条对边总长度的1/2，利用纸币图像两条边平行的特性，我们采用最小二乘法对检测出的边缘离散点进行拟合，作为纸币图像的边缘直线。否则，本文认定该

纸币图像样本缺损程度过大，将按拒识类进行处理。纸币图像样本的预处理过程如图2、图3和图4所示。

2.2 纸币图像特征提取

为了更好地挖掘纸币图像深层次的特征信息，本文设计了一种19层的改进深度卷积神经网络结构用于纸币的分类任务。该模型通过融合迁移学习、Leaky ReLU函数、批量归一化和多层次残差单元获取更加高效和稳定的纸币图像特征。除残差单元外，本文在整个卷积层部分使用步长为 1×1 的 3×3 卷积核和步长为 2×2 的 2×2 池化核进行最大池化，卷积过程中padding都设置为“SAME”而池化过程中padding都设置为“VALID”，同时在反复堆叠的卷积层里，每块卷积层的输出特征依次设置为64, 128, 256, 512和512，具体如图1所示。



图 2 纸币图像预处理(RMB-100)



图 3 纸币图像预处理(USD-100)

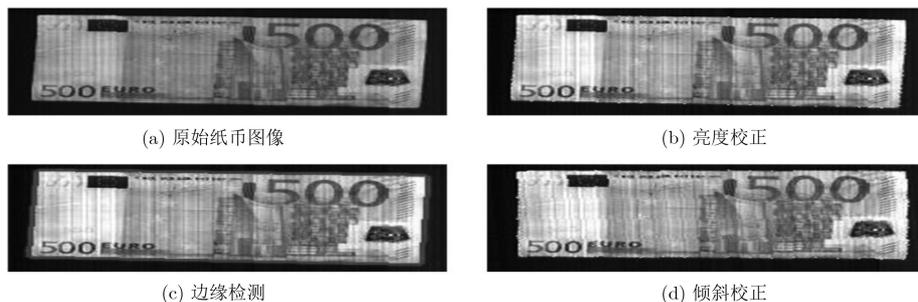


图 4 纸币图像预处理(EUR-500)

为了提高网络训练的效率和分类器的性能, 本文采用迁移学习来初始化并固定部分卷积层参数值, 将VGG16在ImageNet上训练好的参数作为本文训练网络参数的初始值。利用VGG16的前4层参数来初始化本网络的前4层参数, 并在训练时固定浅层参数不变(Train=False), 训练5~19层深层参数(Train=True), 采用这种策略可以提高网络模型的训练效率。此外, 目前在训练深度卷积神经网络模型中广泛使用的激活函数为ReLU函数, 其定义如式(1)所示。

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

ReLU函数虽然能够减少参数依赖性, 缓解过拟合问题, 但它的输出容易陷入硬饱和区从而出现“神经元坏死”现象, 导致相应参数难以被更新, 从而使纸币图像在训练过程中发生部分信息丢失, 降低神经网络的准确度。为了解决这个问题, 本文使用Leakly ReLU激活函数。

$$f(x) = \begin{cases} 0.01x, & x < 0 \\ x, & x \geq 0 \end{cases} = \max(0.01x, x) \quad (2)$$

Leakly ReLU函数不但具有ReLU函数的所有优点同时也解决了ReLU函数带来的部分神经元“坏死”的问题。当自变量在负半轴上取值时, 其输出值不为0。在特征提取过程中, 这个特性能够提高重要特征信息的完整性和利用率。为了更有效地提高网络的训练效率和分类性能, 本文在每个卷积层和非线性化函数之间添加1个BN层^[17], 同时还在深层卷积层引入了3个多层次残差单元, 这种策略不但可以加速深层网络的训练, 提高网络对纸币图

像特征提取的稳定性, 而且还能够提升网络模型对纸币图像的分类性能, 具体的结构设计如图5所示。

本文引入的3个多层次残差单元在结构设计上各有不同, 残差单元-1由3个相同的 3×3 卷积层堆叠而成。相比于 7×7 的卷积层, 该残差单元减少了参数个数, 增加了非线性变换, 包含了相同的256个输出通道, 这些变化使得网络对特征的学习能力得到增强。残差单元-2由1个 3×3 与2个 1×1 卷积层堆叠而成, 输出通道数分别为128、128和512。该残差单元在特征提取过程中减少了运算的复杂度, 特别是 1×1 卷积的设计, 实现了跨通道组织信息, 提高了网络的表达能力。残差单元-3的第1个堆叠层为 3×3 卷积, 输出通道数为512的卷积层。本文采用2个并列的卷积层对中间的 3×3 卷积层进行改进, 第1个并列层仍然使用 1×1 卷积实现跨通道组织信息提高网络的表达能力, 第2个并列层由 1×3 卷积层和 3×1 卷积层串联组成。这种非对称结构的拆分提高了运算效率并抑制了过拟合现象, 同时利用增加的非线性扩展模型可以处理更多的空间特征, 增加了提取特征的多样性与稳定性。最后将2个并列层合并后再串联1个具有512输出通道的 1×1 卷积层。本文引入的多层次残差单元如图5所示。

2.3 纸币特征固定输出表示

受传统金字塔池化算法构造原理的启发, 本文提出一种改进的多层次金字塔池化算法。本文算法在保留 1×1 块和 4×4 块的金字塔级的同时采用并联非对称结构的 1×3 块和 3×1 块金字塔级来代替 3×3 金字塔级, 最终输出 $(1 + 3 + 3 + 16) \times 512$ 维特征向量。改进的多层次空间金字塔池化算法在池

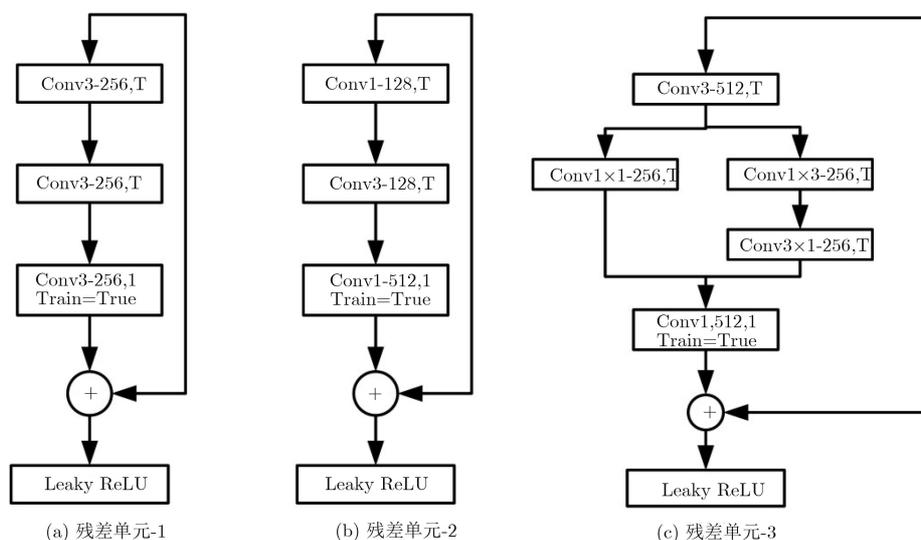


图5 多层次残差单元结构图

化过程中保留了局部空间块, 并通过本算法对每个空间块的过滤器响应进行池化, 然后将得到的

$n \times M$ 维输出向量作为全连接层的输入。改进的多层次空间金字塔池化算法结构框架如图6所示。

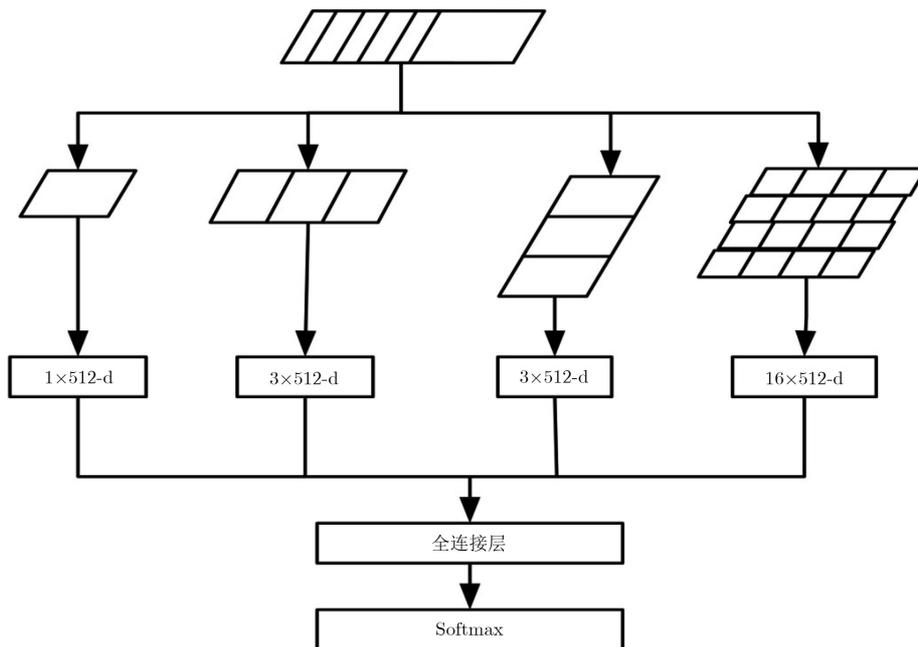


图6 多层次空间金字塔池化算法结构框架

本文所提改进多层次空间金字塔池化算法具有如下优点: 首先所提改进算法能够产生固定大小的输出, 使得网络的输入图像尺寸不受固定尺寸输入要求的限制。针对纸币图像分类的特点, 本文算法有效地解决了因固定尺寸输入的需要导致数据处理时重要信息丢失而降低识别精度的问题, 提高了网络的分类性能。另外, 改进的多层次空间金字塔池化算法能够从不同的角度提取纸币图像特征, 同时还能充分利用图像处理器(GPU), 保证算法的实时性。纸币的多尺寸和全图像表示完全对应了改进的多层次空间金字塔池化算法的特点, 一方面改进的多层次空间金字塔池化算法能够抽取尺度间的图像特征, 不受网络输入固定尺寸样本数据的限制, 这与输入的多尺寸纸币样本相契合。另一方面, 纸币的多尺寸特点能够有效提升改进的多层次空间金字塔池化算法对网络模型的准确度, 进而得到更好的纸币识别效果。

2.4 纸币图像分类

本文采用改进多层次空间金字塔池化算法对多币种纸币图像进行特征提取, 将提取的纸币特征进行全连接层处理, 然后通过softmax回归模型对纸币图像进行分类, 并优化网络的损失函数。假设类别标签为 $\mathbf{y}^{(i)} \in \{0, 1, \dots, k\}$, 当输入特征为 $\mathbf{x}^{(i)} \in R^{n+1}$ 时, 将每个样本所属类别的期望概率 $p(\mathbf{y} = j | \mathbf{x})$ 作为假设函数, 定义为

$$h_{\theta}(\mathbf{x}^{(i)}) = \begin{bmatrix} p(\mathbf{y}^{(i)} = 1 | \mathbf{x}^{(i)}; \theta) \\ p(\mathbf{y}^{(i)} = 2 | \mathbf{x}^{(i)}; \theta) \\ \dots \\ p(\mathbf{y}^{(i)} = k | \mathbf{x}^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}} \begin{bmatrix} e^{\theta_1^T \mathbf{x}^{(i)}} \\ e^{\theta_2^T \mathbf{x}^{(i)}} \\ \dots \\ e^{\theta_k^T \mathbf{x}^{(i)}} \end{bmatrix} \quad (3)$$

其中, θ 表示参数量, 且 $\theta \in R^{n+1}$, 对于单个样本所属类别的期望概率如式(4)所示。

$$p(\mathbf{y}^{(i)} = j | \mathbf{x}^{(i)}; \theta) = \frac{e^{\theta_j^T \mathbf{x}^{(i)}}}{\sum_{i=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}} \quad (4)$$

本文采用文献[16]的函数优化算法实现基于深度网络模型的高效纸币分类, 则softmax回归模型的代价函数的定义为

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k \{y^{(i)} = j\} \lg \frac{e^{\theta_j^T \mathbf{x}^{(i)}}}{\sum_{i=1}^k e^{\theta_j^T \mathbf{x}^{(i)}}} \right] \quad (5)$$

3 实验结果与分析

本文从自行设计的多功能纸币清分系统中采集人民币图像(DB1)、美元图像(DB2)与欧元图像(DB3)构建3个纸币实验数据库。其中纸币清分系统的硬件部分主要由接触式传感器(CIS)、数模转

换器(A/D), DSP(TI TMS6747), FPGA(Xilinx XC3S4000), Flash等部分组成。构建的3个实验数据库具体信息如表1所示。不同币种与面值的纸币

均具有4个面向即正面向上, 正面向下, 反面向上与反面向下。图7显示样本RMB-100, USD-100与EUR-500的4个面向。

表 1 纸币数据库

纸币种类	纸币面值	纸币分类	纸币样本数	训练样本数	测试样本数
人民币(RMB)	5, 10, 20, 50, 100	20	46000	36000	10000
美元(USD)	1, 2, 10, 20, 50, 100	24	38000	25000	13000
欧元(EUR)	5, 10, 20, 50, 100, 200, 500	28	35000	26000	9000

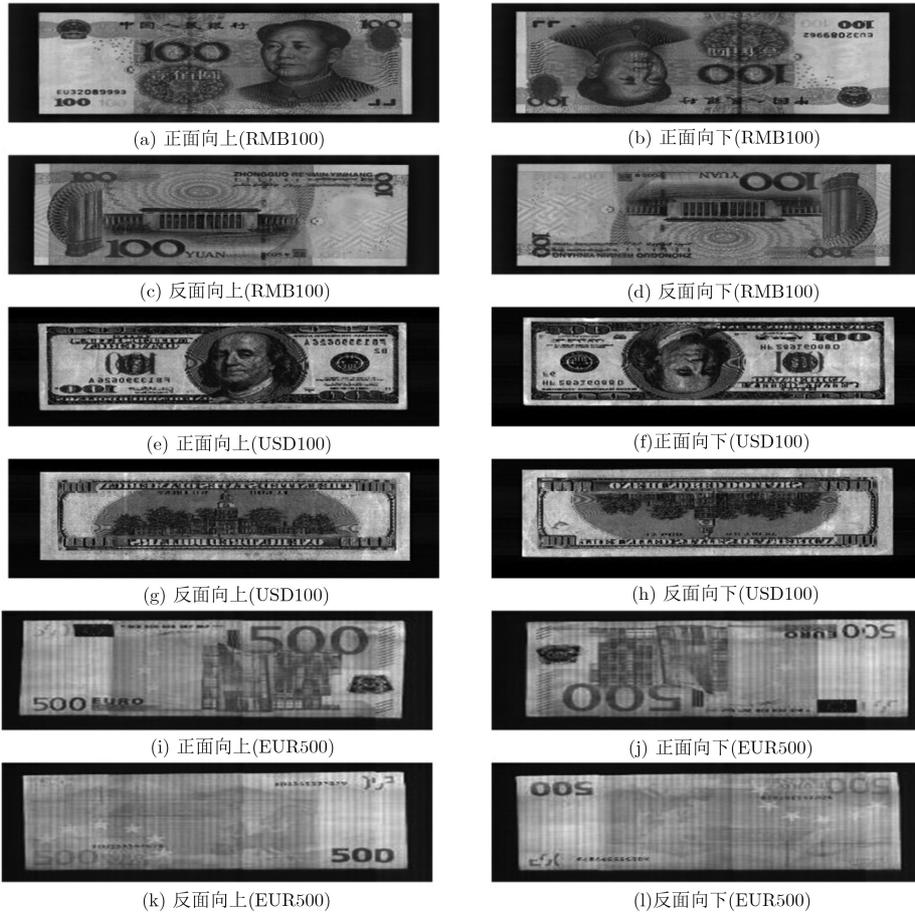


图 7 纸币图像的4个面向

3.1 实验环境与参数设置

鉴于纸币清分系统对准确性与实时性的高要求, 本文的实验主要在Intel(R) Core(TM) i7-4790 CPU 3.60 GHz+Nvidia GeForce GTX 1080 Ti GPU配置的服务器上进行, 另外采用基于Python语言的TensorFlow4.2深度学习框架对不同纸币数据库进行训练与测试。本文将提出的卷积神经网络的深度设计为19层, 采用文献[15]的方法初始化深层网络参数 w, b , 使用交叉熵作为网络的损失代价函数, 利用Adam优化算法对网络进行优化。为了取得更好的优化效果, 采用Adam的默认参数设置, 即学习率 $\xi = 0.001$, 矩估计指数衰减速率 ρ_1 ,

ρ_2 分别选取0.9与0.999, 常数 $\sigma = 10^{-8}$ 。为了提高网络模型的效率, 本文对网络的输入数据采用小批量输入法, mini-batch设置为256。如果在连续3轮周期以内, 训练误差稳定在某一固定数值或者在某一数值附近轻微波动, 就停止网络模型的迭代训练。通过实验证明, 本文设计的网络模型在3个不同币种的数据集中分别进行了50轮、45轮与47轮的训练。

3.2 实验结果对比

为了验证本文算法的有效性, 在相同的实验条件下将本文算法与网络特征[3], 自由掩模[2], VGGNet19[10], PReLU-net[18], BN-inception[16],

ResNet-34B^[13]6种经典分类算法进行比较。本文采用分类准确率与分类复杂度作为衡量模型性能好坏的指标。表2、表3与表4显示了不同分类算法在纸币数据库(DB1, DB2, DB3)中的平均识别率。实验结果表明,本文这种整体框架的设计特性在纸币图像特征提取上表现得更加充分具体,有效地提高了模型的分类性能,比其他6种算法取得更高的识别精度。

为了进一步验证本文算法的稳定性和泛化能力,对本文构建的纸币实验数据库样本的特点进行分析。其中,具有不同程度污损的纸币样本在数据库DB1中占比为35%即16100张纸币样本,在数据库DB2中占比为42%即15960张纸币样本,在数据

库DB3中占比为30%即10500张纸币样本。采用网络特征^[3],自由掩模^[2],VGGNet19^[10],PReLU-net^[18],BN-inception^[16],ResNet-34B^[13]和本文算法对具有不同程度污损纸币的实际测试识别率如表5所示。实验结果表明,与其他算法相比,本文算法将污损纸币的实际识别率分别提高到97.58%,96.75%和97.29%。由此可以看出,本文算法能够更有效地降低污损对纸币识别造成的影响,提升了算法的稳定性和泛化能力。

在纸币识别速度方面,表6给出了本文算法与其他纸币分类算法运行时间的比较结果。实验结果表明,本文算法的识别时间明显低于VGGNet19^[10],PReLU-net^[18],BN-inception^[16]与ResNet-34B^[13]的

表2 数据库DB1平均识别率(%)

人民币	网格特征 ^[3]	自由掩模 ^[2]	VGGNet19 ^[10]	PReLU-net ^[18]	BN-inception ^[16]	ResNet-34B ^[13]	本文算法
100	74.25	76.44	91.52	91.45	92.38	94.16	96.68
50	74.02	74.75	90.83	91.76	92.11	95.98	97.80
20	75.23	76.88	92.34	91.56	93.64	94.88	95.03
10	80.12	83.34	94.06	94.76	95.67	96.86	96.97
5	83.24	80.57	93.16	93.27	95.53	95.66	97.82

表3 数据库DB2平均识别率(%)

美元	网格特征 ^[3]	自由掩模 ^[2]	VGGNet19 ^[10]	PReLU-net ^[18]	BN-inception ^[16]	ResNet-34B ^[13]	本文算法
100	70.13	72.24	89.26	91.33	93.25	94.46	95.67
50	73.14	72.28	91.35	91.49	92.98	94.29	94.96
20	74.56	77.82	90.23	92.14	93.05	95.11	95.89
10	76.21	75.34	91.25	93.34	93.67	94.28	95.15
2	78.11	80.12	92.13	92.86	93.58	95.67	96.75
1	81.23	80.02	91.24	90.36	94.27	96.16	97.98

表4 数据库DB3平均识别率(%)

欧元	网格特征 ^[3]	自由掩模 ^[2]	VGGNet19 ^[10]	PReLU-net ^[18]	BN-inception ^[16]	ResNet-34B ^[13]	本文算法
500	81.12	84.23	93.25	92.91	94.56	94.93	96.98
200	81.65	82.32	93.24	94.13	94.68	95.12	98.20
100	85.46	86.94	94.12	94.67	95.23	96.11	97.75
50	79.25	83.24	93.20	93.12	94.35	95.29	96.79
20	83.24	84.52	94.25	95.28	95.64	96.33	98.76
10	85.33	87.12	94.24	94.76	94.19	97.20	97.88
5	84.20	83.52	94.16	93.26	95.12	95.78	97.89

表5 污损纸币实际测试识别率(%)

污损样本	网格特征 ^[3]	自由掩模 ^[2]	VGGNet19 ^[10]	PReLU-net ^[18]	BN-inception ^[16]	ResNet-34B ^[13]	本文算法
DB1(16100)	78.65	82.49	92.45	93.18	94.37	95.06	97.58
DB2(15960)	75.42	79.16	88.24	91.07	92.53	94.84	96.75
DB3(10500)	80.28	83.17	91.52	93.65	95.18	96.78	97.29

表 6 不同识别算法运行时间(s)

自由掩模 ^[2]	网格特征 ^[3]	VGGNet19 ^[10]	PRReLU-Net ^[18]	BN-inception ^[16]	ResNet-34B ^[13]	本文算法
0.98	0.85	1.97	1.72	1.58	1.24	1.06

识别时间, 略高于自由掩模^[2]及网格特征^[3]的识别时间。但是, 本文算法在满足纸币清分系统实时性要求的同时在识别性能上要高于自由掩模^[2]和网格特征^[3]。

4 结束语

本文所提改进深度卷积神经网络纸币识别算法, 一方面采用迁移学习、Leaky ReLU函数、批量归一化和多层次残差单元对纸币数据进行建模, 提高了深层网络对纸币特征的学习与提取效率。另一方面, 本文所提改进多层次空间金字塔池化算法在不增加网络计算复杂度的同时, 突破了深度卷积神经网络需要输入图像尺寸固定的限制, 有效地解决了因固定尺寸输入而导致在数据处理时面对任意尺寸和比例的图像或子图像时重要信息丢失而降低识别精度的问题, 提高了网络的分类性能。将本文算法与其他经典的纸币分类算法在不同币种的数据库上进行对比实验, 结果表明本文算法不但具有较高的识别率, 更好的泛化能力和鲁棒性, 而且还能够满足纸币清分系统的实时性要求。

参 考 文 献

- [1] KATO N, SUZUKI M, OMACHI S, *et al.* A handwritten character recognition system using directional element feature and asymmetric mahalanobis distance[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(3): 258–262. doi: [10.1109/34.754617](https://doi.org/10.1109/34.754617).
- [2] TAKEDA F and OMATU S. High speed paper currency recognition by neural networks[J]. *IEEE Transactions on Neural Networks*, 1995, 6(1): 73–77. doi: [10.1109/72.363448](https://doi.org/10.1109/72.363448).
- [3] 刘家锋, 刘松波, 唐隆龙. 一种实时纸币识别方法的研究[J]. *计算机研究与发展*, 2003, 40(7): 1057–1061.
LIU Jiafeng, LIU Songbo, and TANG Xianglong. An algorithm of real-time paper currency recognition[J]. *Journal of Computer Research and Development*, 2003, 40(7): 1057–1061.
- [4] CHOI E, LEE J, and YOON J. Feature extraction for bank note classification using wavelet transform[C]. The IEEE 18th International Conference on Pattern Recognition (ICPR), Hong Kong, China, 2006: 934–937. doi: [10.1109/ICPR.2006.553](https://doi.org/10.1109/ICPR.2006.553).
- [5] GAI Shan, YANG Guowei, and WAN Minghua. Employing quaternion wavelet transform for banknote classification[J]. *Neurocomputing*, 2013, 118: 171–178. doi: [10.1016/j.neucom](https://doi.org/10.1016/j.neucom).
- [6] JIN Ye, SONG Ling, TANG Xianglong, *et al.* A hierarchical approach for banknote image processing using homogeneity and FFD model[J]. *IEEE Signal Processing Letters*, 2008, 15: 425–428. doi: [10.1109/LSP.2008.921470](https://doi.org/10.1109/LSP.2008.921470).
- [7] 吴震东, 王雅妮, 章坚武. 基于深度学习的污损指纹识别研究[J]. *电子与信息学报*, 2017, 39(7): 1585–1591. doi: [10.11999/JEIT161121](https://doi.org/10.11999/JEIT161121).
WU Zhendong, WANG Yani, and ZHANG Jianwu. Fouling and damaged fingerprint recognition based on deep learning[J]. *Journal of Electronics & Information Technology*, 2017, 39(7): 1585–1591. doi: [10.11999/JEIT161121](https://doi.org/10.11999/JEIT161121).
- [8] 樊养余, 李祖贺, 王凤琴, 等. 基于跨领域卷积稀疏自动编码器的抽象图像情绪性分类[J]. *电子与信息学报*, 2017, 39(1): 167–175. doi: [10.11999/JEIT160241](https://doi.org/10.11999/JEIT160241).
FAN Yangyu, LI Zuhe, WANG Fengqin, *et al.* Affective abstract image classification based on convolutional sparse autoencoders across different domains[J]. *Journal of Electronics & Information Technology*, 2017, 39(1): 167–175. doi: [10.11999/JEIT160241](https://doi.org/10.11999/JEIT160241).
- [9] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[C]. The 25th International Conference on Neural Information Processing Systems, Nevada, USA, 2012: 1097–1105.
- [10] SIMONYAN K and ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. International Conference on Learning Representations (ICLR), Banff, Canada, 2015: 168–175.
- [11] SZEGEDY C, LIU Wei, JIA Yangqing, *et al.* Going deeper with convolutions[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA, 2015: 1–9. doi: [10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594).
- [12] 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), Las Vegas, USA, 2016: 2818–2826. doi: [10.1109/CVPR.2016.308](https://doi.org/10.1109/CVPR.2016.308).
- [13] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016: 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).

- [14] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904–1916. doi: [10.1109/TPAMI.2015.2389824](https://doi.org/10.1109/TPAMI.2015.2389824).
- [15] PENG Peixi, TIAN Yonghong, XIANG Tao, *et al.* Joint semantic and latent attribute modeling for cross-class transfer learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(7): 1625–1638. doi: [10.1109/TPAMI.2017.2723882](https://doi.org/10.1109/TPAMI.2017.2723882).
- [16] IOFFE S and SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]. Proceedings of the 32nd International Conference on International Conference on Machine Learning, Lille, France, 2015: 448–456.
- [17] KINGMA D P and BA J. Adam: A method for stochastic optimization[C]. Proceedings of the 3rd International Conference on Learning Representations (ICLR), San Diego, USA, 2015: 1–8.
- [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification[C]. 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 1026–1034. doi: [10.1109/ICCV.2015.123](https://doi.org/10.1109/ICCV.2015.123).
- 盖 杉: 男, 1980年生, 副教授, 硕士生导师, 研究方向为计算机视觉、图像处理、深度学习.
- 鲍中运: 男, 1990年生, 硕士生, 研究方向为计算机视觉、图像处理、深度学习.