

基于深度学习的农作物病虫害图像识别技术研究进展

贾少鹏 高红菊 杭 潇

(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 深度学习作为图像识别领域重要的技术手段,具有识别速度快、准确率高等优势。阐明了深度学习技术研究的意义及必要性,概述了国内外深度学习领域农作物病虫害图像识别技术的研究进展,对深度学习技术在图像识别研究中存在的问题进行归纳总结,并指出深度学习领域中的图像识别方法存在训练样本大、模型结构复杂、复杂图像识别正确率低等问题。提出了一种 CNN 与胶囊网络的组合模型,经过初步实验,模型的图像识别正确率达 93.75%,比 CNN 模型提高了 3.55 个百分点。随着深度学习技术的不断发展,胶囊网络研究将是未来的发展趋势。

关键词: 病虫害;深度学习;图像识别

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2019)S0-0313-05

Research Progress on Image Recognition Technology of Crop Pests and Diseases Based on Deep Learning

JIA Shaopeng GAO Hongju HANG Xiao

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Throughout the history of agricultural development, crop pests and diseases have always been one of the main obstacles hindering the development of agricultural economy. The crop disease identification system based on digital image processing technology had the characteristics of fast, accurate and real-time, which can help the farmers to take effective prevention measures in time. As an important technical means in the field of image recognition, deep learning has broad application prospects. The research progress of crop pest and disease image recognition technology in deep learning field in China and abroad was reviewed. The significance and necessity of deep learning technology research were clarified. The training samples of deep learning technology in image recognition research were large and the model structure was complex. Complex image recognition accuracy was low. It was proposed that improving the recognition accuracy of complex images would be the development direction of future research.

Key words: pests and diseases; deep learning; image recognition

0 引言

经济社会的不断发展带来了全球的气候和环境问题,病害的发生以及真菌细菌的变异影响着人们的生活。农作物病虫害的发病率越来越高,发生的病害也越来越复杂,因此,研究农作物病害的预防,以及病害诊断和补救措施显得尤为重要。传统的人工检测病虫害的方法完全依赖于养殖户的观察经

验,或者请专家上门指导,这样的方法速度慢、效率低、费用高、主观性强、准确率低、无时效性。随着互联网的不断发展,信息化技术的运用给农作物病虫害识别提供了新的方法和思路。运用高效的图像识别技术可以提高图像识别效率、降低成本、提高识别正确率。为此,国内外专家学者进行了大量的研究,其中深度学习成为了研究焦点。

随着深度学习技术的发展,科研工作者开始将

收稿日期: 2019-04-20 修回日期: 2019-05-20

基金项目: 国家自然科学基金项目(31371531)

作者简介: 贾少鹏(1994—),男,硕士生,主要从事机器学习研究,E-mail: 823510056@qq.com

通信作者: 高红菊(1972—),女,副教授,主要从事数据挖掘和通信技术研究,E-mail: hongju_gao@yahoo.com

深度学习应用到图像识别,并且在近几年取得了较大的进展。深度学习应用在作物病害识别上可以大大减少工作量,缩短识别时间。复杂的网络结构和庞大的数据样本是深度学习最大的特点,深度学习技术的出现为图像识别提供了强有力的技术保障。许多深度学习模型被提出,如:深层信念网络(DBN)、卷积神经网络(CNN)、循环神经网络(RNN)、生成式对抗网络(GAN)、胶囊网络(CapsNet)等,本文对此进行归纳和阐述。

1 深层信念网络

深度信念网络(Deep belief network, DBN)由HINTON在2006年提出。它起源于人工神经网络,由多层受限玻尔兹曼机和一层分类器组合而成,是一种概率模型,通过训练其神经元间的权重,使整个神经网络按照最大概率来生成训练数据。

ZHONG等^[1]提出一种新的DBN模型,运用了DBN模型对高光谱遥感图像进行分类,但训练中模型的隐藏层相似度非常高。为了优化DBN的各项性能,研究者对过程进行规范微调,基于多样性这一特点,总结了一种新的多样化DBN,提高了工作效率。在预训练学习阶段,研究者提出运用贪婪策略进行学习,贪婪学习过程使权重参数变换多样,隐藏单元不再那么相似,赋予它们多样性。

实验证明,使用优化后的多样化DBN对遥感图像进行分类取得了较好的效果,图像识别分类精度和时间等性能有了新的进步和提高,但由于DBN模型的数量庞大,模型调整难度高,所以DBN的改进依然是今后研究的重点。

2 卷积神经网络

卷积神经网络(Convolutional neural network, CNN)是一类包含卷积计算且具有深度结构的前馈神经网络。CNN模型结构包括输入层、卷积层、池化层、全连接层以及输出层。在CNN图像识别分类中,通过多层的卷积计算使得图像特征更为清晰,内容更加丰富,在CNN模型中使用多层卷积和多层池化组合,将图像包含的信息通过计算表达出来。近年比较经典的CNN模型有LeNet-5、AlexNet、ZF-Net、VGGNet、GoogLeNet、ResNet以及DenseNet^[2],这些模型均是改进的LeNet模型。

ZHANG等^[3]提出了一种多特征的加权DenseNet模型(MFR-DenseNet)用于图像分类。这种模型通过自动调整信道特征响应和不同卷积层特征之间的依赖性,与传统的DenseNet相比,提高了表达能力。为了达到重新校准动态信道特征的目的,

研究者在DenseNet中引入挤压激励模块(SEM),然后提出用双挤压激励模块(DSEM)来模拟不同卷积层特征之间的依赖,最后研究者将这种方法与集成学习方法结合起来设计了MFR-DenseNet模型,实验结果显示,此模型的分类效果明显。ZHANG等^[3]利用深度学习技术设计了一套判断苹果叶片病菌感染的系统,研究者将搜集到的苹果叶分成4类,分别是健康叶片、感染初期叶片、感染中期叶片和感染末期叶片,利用VGG16模型进行叶片分类,正确率达到90.4%。2017年,美国宾夕法尼亚州州立大学RAMCHARAN等^[4]在对木薯病虫害识别中应用迁移学习来训练深度卷积神经网络。实验结果显示,木薯褐斑病的识别精度为98%、红蜘蛛的识别精度为96%、绿螨的识别精度为95%、木薯褐条病的识别精度为98%、木薯花叶病的识别精度为96%,实验结果表明,深度学习模型识别精度高。美国特拉华大学HOLMES等^[5]利用高光谱技术在2014—2016年收获的苹果中提取出了350~2500nm反射光谱数据,从有效距离范围内捕获高光谱苹果图像,提取这些图像的有效光谱特征,并利用逻辑回归计算阈值。实验显示对于苹果酸甜还是苦涩的分类正确率达85%,此方法可用于生产线上的苹果分类。张善文等^[6]设计了一个11层的LeNet卷积神经网络对黄瓜的病害进行识别。研究者采集了1200幅黄瓜病害彩色图像进行裁剪和归一化预处理,然后对经过预处理的彩色图像进行训练,并利用RGB颜色通道进行调整。实验显示该方法识别正确率达到90%以上,比传统的方法识别正确率高。甘肃农业大学刘闯宇等^[7]采用区域Faster-RCNN模型对采集到的图像进行训练,通过分类器对图像进行分类识别,对病叶识别正确率最高可达75.52%,最低为60.56%。鉴于收集的图像是在田间复杂的环境下随机拍摄的,光照等条件不理想,图像背景复杂以及存在遮挡的问题,所以这个识别正确率在可接受的范围内。华南理工大学黄双萍等^[8]在田间采集了1467幅穗株高光谱图像,其中包括247幅健康植株图像、1220幅患病图像。研究者首先将图像进行归一化处理,然后利用GoogleLeNet深度卷积神经网络模型进行建模,最后采用随机梯度下降法来优化模型。最终实验的精度达到了92.0%,分类效果明显。华南农业大学甘海明等^[9]利用稀疏自编码模型建立了龙眼叶片叶绿素含量预测的高光谱反演模型,这种模型大大提高了识别精度,并且基本不受生长不同阶段的影响,灰度图像中颜色越深则叶绿素含量越少,彩色图像中蓝色部分越多,则表示叶片含有的叶绿素含量越低。

该模型表明把深度学习技术应用到高光谱是可行的,给以后的研究提供了思路。SHARADA 等^[10] 用在受控条件下采集的 54 306 幅病态和健康的植物叶片训练了卷积神经网络,并且用训练的模型识别了 14 种作物和 26 种疾病,精度达到 99.35%。ALVARE 等^[11] 提出了一种深度学习元体系结构的概念,这种结构是将 Faster R-CNN、SSD、RFCN 和 VGG NET 和 RESNET 等特征提取器结合起来,利用这种方法进行分类识别效果显著。ANANDHAKRISHNAN 等^[12] 利用深度卷积网络训练图像分类识别模型,效果显著。YANG 等^[13] 提出的基于深度卷积神经网络的模型对水稻病叶进行识别,精度达到了 95.48%。这个精度比传统的机器学习模式高,验证了该方法的可行性和有效性。LEE 等^[14] 利用 Faster R-CNN 对茶叶的褐斑病、水疱病和褐斑病进行识别,该模型初步结果显示测试集上的图像的平均识别精度为 63.58%、81.08%、64.71%。

卷积神经网络的特点是局部权值共享,这种特殊的功能使得卷积神经网络在图像处理上有着天然的优势,其结构更复杂更像实际的生物神经网络,卷积神经网络避免了特征提取这一复杂过程。但卷积神经网络结构复杂不易理解,且训练时间较长。

3 循环神经网络

循环神经网络(Recurrent neural network, RNN)是一种处理序列数据的时间递归神经网络^[15],主要用来解决序列数据问题。RNN 模型最大的特点是模型网络会对之前的信息进行记忆以便后续的计算,与 CNN 不同的是,RNN 模型隐藏层之间的神经元是相互连接的,共同作用。然而 RNN 仍有许多缺点,如:网络结构复杂、训练难度大、训练时间长等,随后,出现了一些改进的 RNN,例如:长短期记忆网络、GRU^[16]、双向 RNN 等模型。这些改进的 RNN 模型相比于传统的 RNN 表现了良好的优势。

MIRZA 等^[17] 利用长短期记忆网络模型设计了一种顺序自动编码器,这种编码器是利用图像的维数约简和特征提取特性自动编码,有效地执行重建过程。此外,研究者设置了一个基于交叉验证的阈值对输入网络的数据序列是否异常进行分类。实验证明,此框架性能良好,具有动态性、健壮性和可扩展性。郝志峰等^[18] 提出一种基于序列标注的细粒度意见分析的双向 RNN 模型,同时进行文本属性抽取以及情感分类。通过对文本的词向量、词性和依存关系等特征的融合设计了时间序列标注模型。在真实数据集上进行实验,与其他模型相比,该模型情感分类效果显著。MOU 等^[19] 提出一种新的 RNN

模型,该模型可以有效地将高光谱像素作为序列数据进行分析并通过网络进行图像分类。改进的 RNN 模型中使用一种改进的参数校正 tanh (PRetanh)激活函数,这种激活函数在训练过程一直保持较高的学习率,实验效果显著。

4 生成式对抗网络

生成式对抗网络(Generative adversarial network, GAN)是 GOODFELLO 等^[20] 在 2014 年提出的,此模型的原理是通过在对抗的过程中生成新模型的一种框架。GAN 主要由生成模型和判别模型构成,生成模型是创造一幅看似真实的图像,判别模型用于判断一幅给定的图像是否真实。ZHU 等^[21] 首次提出了将 GAN 模型应用在高光谱图像数据分类中。该模型有效缓解了深度 CNN 的过拟合问题,研究者提出了两种 HIS 分类框架,分别是 1D-GAN 和 3D-GAN,用两种框架进行实验,实验结果表明,GAN 模型优于传统的 CNN,在训练样本有限的情况下也是如此。研究者在所提出的 GAN 中,加入了两个 CNN,一个 CNN 用来对真实输入进行模拟,形成假输入。另一个 CNN 则用来对真实输入和第一个 CNN 生成的假输入进行分类。两个 CNN 同时进行训练。这种对抗训练提高了 CNN 识别的泛化能力,当训练样本有限时,这种对抗网络分类效果显著。唐贤伦等^[22] 提出了一种条件深度卷积生成对抗网络模型,该模型结合了深度卷积生成对抗网络和条件生成对抗网络的优点,在 MNIST 数据集和 CIFAR-10 数据集上的识别正确率分别为 99.45% 和 84%,在作物病害识别分类上效果也高达 90% 以上。

5 胶囊网络

胶囊网络(Capsule network, CapsNet)是 SABOUR 等^[23] 在 2017 年提出的。胶囊网络是在 CNN 的基础之上发展而来,由于 CNN 模型无法从新的视角去理解对象,难以识别精确空间关系,最大池化层只有值最大的神经元会被传递到下一层,丢失了大量信息。为了解决这些问题,胶囊网络应运而生。目前的 CapsNet 结构较浅,是由卷积层、主胶囊层、数字胶囊层构成。胶囊是一组神经元,它会学习检测给定区域图像的特定目标并输出一个向量,如果对象有轻微的空间变化,则胶囊将会根据变化进行调整输出合适的向量。

DENG 等^[24] 提出利用有限训练样本的胶囊网络对高光谱图像进行分类。使用 PaviaU 和 Salinas 这两个 HSI 数据集对胶囊网络进行训练,相比于传

统的 CNN,胶囊网络在 MNIST 数据集分类的正确率高达 99.75%,远超传统的 CNN。但由于胶囊网络只有 3 层网络,在图像分类识别方面的效果尚不如 CNN 模型。如在胶囊网络的结构和路由算法方面作进一步突破,胶囊网络会有很大的发展空间,尤其是图像识别领域。

6 传统机器学习技术与深度学习技术对比

在深度学习技术发展之前,图像识别以传统的技术手段实现。随着深度学习技术的发展,科研工作者开始将深度学习应用到图像识别中,并且在最近的几年中取得了很多成果,特别是在人脸识别、医学图像识别、遥感图像识别等方面。图像的识别效率和效果比传统的识别方法有了较大的进步。传统识别方法与深度学习识别方法对比如表 1 所示。

表 1 两类图像处理技术的优缺点对比
Tab.1 Comparison of advantages and disadvantages of two types of image processing technology

技术	优点	缺点
传统机器学习	对于小数据样本的训练有优势;不需要昂贵的硬件设备,算法结构简单易懂;调参相对简单;对于许多问题经典的机器学习算法表现得更为优异	经典的机器学习算法通常需要复杂的特征工程;需要进行数据降维;分类精度不高,对于复杂背景的图像识别困难
	深度学习技术的深层特征提取功能使其在图像、音频和文本数据上表现优异,很容易通过反向传播来更新数据;不同的构架适用于不同的问题,隐藏层降低了算法对特征工程的依赖	对机器配置要求高,需要大量的数据;对于传统的机器学习问题,表现并不比集成方法好

7 未来发展趋势概述

通过对比经典的深度学习技术发现,胶囊网络

对于图像识别的效率较高,并且具有所需的训练数据量较少、不易受多类别重叠的干扰、抵御白盒对抗性攻击能力较强等优势。胶囊网络对于复杂图像的特征提取更为全面,在图像识别领域将会有更广阔的应用前景。胶囊网络虽然性能优异,但仍有缺陷,需要对网络模型进行改进。

(1) 优化网络架构

目前胶囊网络对于复杂图像的识别效率仍较低。本文提出一种改进的模型,该模型是将胶囊网络加入到 CNN 架构中,以胶囊网络作为 CNN 模型的全连接层,这样可以弥补 CNN 在输出时会丢失大量信息的缺陷。课题组选取了 300 幅番茄灰霉病害图像,分别用 CNN 模型和 CNN 与胶囊网络的组合模型对病害图像进行分类识别。实验结果显示,CNN 模型的识别精度达到 90.20%,优化后的模型识别精度达到 93.75%,识别精度比 CNN 模型提高了 3.55 个百分点。

(2) 提高识别速度

胶囊网络的识别速度比其他经典深度学习模型慢得多,在很大程度上是受囊间动态路由算法和参数量多的影响,动态路由内部的多次迭代耗费时间长,大大降低胶囊网络的识别效率。利用矩阵来表示向量可以减少参数量,进而降低计算量。未来可以从优化路由算法方面来提高胶囊网络识别速度。

8 结束语

对近年来深度学习农作物病虫害图像识别领域的研究技术进展进行了概述。虽然目前的图像识别技术取得了较好的识别效果,但还有很多问题亟待解决。未来图像识别的研究方向应该着眼于农田里随机发现的拥有复杂背景的病虫害病体图像,改进现有的算法,利用深度学习的优势,学习识别背景复杂、成像模糊的图像。利用图像识别技术来帮助农民或种植户识别病虫害,对于保障农业生产、推动农业经济发展具有重要意义。

参 考 文 献

[1] ZHONG P,GONG Z Q,LI S T,et al. Learning to diversify deep belief networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017,55(6):3516-3530.

[2] HUANG Z L. Densely connected convolutional networks[C]//The Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE,2017: 2261-2269.

[3] ZHANG K,GUO Y R,WANG X S,et al. Multiple feature reweight DenseNet for image classification[J]. IEEE Access, 2019, 7: 9872-9880.

[4] RAMCHARAN A,BARANOWSKI K,MCCLOSKEY P,et al. Deep learning for image-based cassava disease detection[J]. Frontiers in Plant Science,2017(8): 1852.

[5] HOLMES L,LAHURD A,WASSON E,et al. Racial and ethnic heterogeneity in the association between total cholesterol and pediatric obesity[J]. International Journal of Environmental Research and Public Health,2018,13(1): ijerph13010019.

[6] 张善文,谢泽奇,张晴晴. 卷积神经网络在黄瓜叶部病害识别中的应用[J]. 江苏农业学报,2018,34(1): 56-61.

- ZHANG S W, XIE Z Q, ZHANG Q Q. Application research on convolutional neural network for cucumber leaf disease recognition [J]. *Jiangsu Journal of Agricultural Sciences*, 2018, 34(1): 56–61. (in Chinese)
- [7] 刘闯宇, 冯全, 杨森. 基于卷积神经网络的葡萄叶片病害检测方法[J]. *东北农业大学学报*, 2018, 49(3): 73–83.
- LIU Y Y, FENG Q, YANG S. Detecting grape diseases based on convolutional neural network [J]. *Journal of Northeast Agricultural University*, 2018, 49(3): 73–83. (in Chinese)
- [8] 黄双萍, 孙超, 齐龙, 等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. *农业工程学报*, 2017, 33(20): 169–176.
- HUANG S P, SUN C, QI L, et al. Rice panicle blast identification method based on deep convolution neural network [J]. *Transactions of the CSAE*, 2017, 33(20): 169–176. (in Chinese)
- [9] 甘海明, 岳学军, 洪添胜, 等. 基于深度学习的龙眼叶片叶绿素含量预测的高光谱反演模型[J]. *华南农业大学学报*, 2018, 39(3): 102–110.
- GAN H M, YUE X J, HONG T S, et al. Hyperspectral inversion model for prediction of chlorophyll content in longan leaves based on deep learning [J]. *Journal of South China Agricultural University*, 2018, 39(3): 102–110. (in Chinese)
- [10] SHARADA P M, DAVID P H, MARCEL S. Using deep learning for image-based plant disease detection [J]. *Frontiers in Plant Science*, 2016(8): 255–304.
- [11] ALVARE F, SOOK Y, SANG C K, et al. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition [J]. *Sensors*, 2017, 17(9): 2022.
- [12] ANANDHAKRISHNAN J H, ANNETTE J, JERIN F. Plant leaf disease detection using deep learning and convolution neural network [J]. *International Journal of Engineering Science and Computing*, 2017, 7(3): 5324–5328.
- [13] YANG L, YI S J, YONG Z, et al. Identification of rice diseases using deep convolutional neural networks [J]. *Neurocomputing*, 2017, 267: 378–384.
- [14] LEE S H, WU C C, CHEN S F. Development of image recognition and classification algorithm for tea leaf diseases using convolutional neural network [C] // 2018 ASABE Annual International Meeting, 2018.
- [15] LIPTON Z C. A critical review of recurrent neural networks for sequence learning [J/OL]. <https://arxiv.org/abs>.
- [16] CHO K, MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using rnncoder-decoder for statistical machine translation [J/OL]. <https://arxiv.org/abs/1406.1078>.
- [17] MIRZA A H, COSAN S. Computer network intrusion detection using sequential LSTM neural networks autoencoders [C] // The Proceedings of 26th Signal Processing and Communications Applications Conference (SIU). IEEE, 2018: 1–4.
- [18] 郝志峰, 黄浩, 蔡瑞初, 等. 基于多特征融合与双向 RNN 的细粒度意见分析 [J]. *计算机工程*, 2018, 44(7): 199–204, 211.
- HAO Z F, HUANG H, CAI R C, et al. Fine-grained opinion analysis based on multi-feature fusion and bidirectional RNN [J]. *Computer Engineering*, 2018, 44(7): 199–204, 211. (in Chinese)
- [19] MOU L C, GHAMISI P, ZHU X X. Deep recurrent neural networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639–3655.
- [20] GOODFELLO I J, POUGET J, MIRZA M, et al. Generative adversarialnets [C] // The Proceedings of the 27th International Conference on Neural Information Processing Systems—Volume 2. Montreal, Canada: MIT Press, 2014: 2672–2680.
- [21] ZHU L, CHEN Y S, PEDRA M, et al. Generative adversarial networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5046–5063.
- [22] 唐贤伦, 杜一铭, 刘雨微, 等. 基于条件深度卷积生成对抗网络的图像识别方法 [J]. *自动化学报*, 2018, 44(5): 855–864.
- TANG X L, DU Y M, LIU Y W, et al. Image recognition with conditional deep convolutional generative adversarial networks [J]. *Acta Automatica Sinica*, 2018, 44(5): 855–864. (in Chinese)
- [23] SABOUR S, FROSST N, HINTON G. Dynamic routing between capsules [J/OL]. <https://arxiv.org/abs/1710.09829>.
- [24] DENG F, PU S, CHEN X, et al. Hyperspectral image classification with capsule network using limited training samples [J]. *Sensors*, 2018, 18(9): 1–22.