

基于DenseNet模型的无人机高分辨率影像树种分类研究

张泽宇¹, 王妮^{1,2}, 朱锦富¹, 孟祥瑞¹, 董思萌¹

¹滁州学院地理信息与旅游学院, 安徽 滁州

²滁州学院实景地理环境安徽省重点实验室, 安徽 滁州

收稿日期: 2021年9月28日; 录用日期: 2021年10月19日; 发布日期: 2021年10月26日

摘要

如今深度学习广泛应用于医学、工业、人工智能以及地理学等领域。本文基于DenseNet模型, 在其残差块之间加入 1×1 的小型卷积核作为瓶颈层得到了一种改进的DenseNet_BL模型, 以琅琊山林场为研究区, 使用DenseNet121_BL和DenseNet169_BL模型对研究区的无人机高分辨率光学影像进行分类研究实验。得到的实验结果表明DenseNet121_BL模型在进行树种分类时正确率最高, 达到了88.29%。说明改进后的DenseNet_BL模型是一种有效的树种分类算法。

关键词

DenseNet, 残差网络, 无人机, 深度学习, 树种分类

Tree Species Classification Based on DenseNet Model in UAV High Resolution Images

Zeyu Zhang¹, Ni Wang^{1,2}, Jinfu Zhu¹, Xiangduan Meng¹, Simeng Dong¹

¹College of Geographic Information and Tourism, Chuzhou University, Chuzhou Anhui

²Key Laboratory of Physical Geography of Anhui Province, Chuzhou University, Chuzhou Anhui

Received: Sep. 28th, 2021; accepted: Oct. 19th, 2021; published: Oct. 26th, 2021

Abstract

Deep learning is widely used in medicine, industry, artificial intelligence, geography and other fields.

文章引用: 张泽宇, 王妮, 朱锦富, 孟祥瑞, 董思萌. 基于 DenseNet 模型的无人机高分辨率影像树种分类研究[J]. 测绘科学技术, 2021, 9(4): 139-145. DOI: 10.12677/gst.2021.94017

This paper proposes an improved DenseNet_BL model based on DenseNet model. An improved DenseNet_BL model is obtained by adding a 1×1 small convolution kernel between the Residual Blocks as the Bottleneck Layer. Taking Langya Mountain Forest as the research area, DenseNet-121_BL and DenseNet169_BL models were used to classify UAV high-resolution optical images in the research area. The experimental results showed that DenseNet_BL121 model had the highest accuracy in tree species classification, reaching 88.29%. The improved DenseNet_BL model is an effective tree species classification algorithm.

Keywords

DenseNet, Residual Network, UAV, Deep Learning, Tree Species Classification

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

目前国家对于提高林业保护要求非常迫切,对植被的管理和保护,以及进行可持续森林管理成为了森林经营和林业研究的重要课题[1]。对森林树种高效准确地分类对于理解森林组成、保护森林资源和了解树种分布情况具有重要意义[2] [3]。用传统方法进行地面调查在大范围的森林资源调查中耗时长、成本高、效率低。目前基于无人机光学影像数据进行的树种分类[4]方法主要有三类,支持向量机(Support Vector Machine, SVM)、决策树(Decision Tree, DT)模型、卷积神经网络(Convolutional Neural Network, CNN)。

1) 支持向量机相较于人工神经网络虽然有更好的泛化能力,并且算法具有全局最优性,但万意等[5]进行了基于支持向量机的光学遥感影像分类实验得到的结论说明了支持向量机仅仅依靠光谱信息不能充分地进行分类。

2) 赵雪清等[6]进行了决策树与人工神经网络的对比分析得出的结论说明了决策树在处理特征关联性比较强的数据时表现较为一般,没有人工神经网络稳定、精度高。通过决策树进行的遥感分类实验大多结合多光谱数据,相较于 RGB 光学数据拥有更多的光谱信息,才能更好地提取特征。

3) 卷积神经网络具有自动学习分类特征的能力[7],其中卷积作为特征提取器,神经网络作为分类器,避免了传统识别方法中复杂的特征提取和数据构建的过程[8],能在多个图像分类任务中取得优异的分类效果,是目前热门的分类技术。卷积神经网络的层数越多,提取的特征就会越充分,因此探索深层的网络模型成了新的趋势。但是,随着网络深度的增加梯度消失问题也会出现,网络的后层不能有效地学习到分类特征,再增加网络层数时就会出现梯度下滑等问题。

针对网络层数增加梯度减少的问题,本文采用了具有密集连接机制的 DenseNet (密集神经网络)模型,任意一层都与它之前的所有层直接连接,得到的输入都是前面所有层输出结果的叠加,而该层所得到的结果也和前面所有层的输出一起作为输入传输给下一层,这样依次向下传输,将自身的特征图传递到后续的所有层,保证了每层都能得到前额特征。在传统的 N 层网络中只有 N 个直接连接,而在 DenseNet 中却有 $N(N - 1)/2$ 个直接连接。这种网络结构在面对多树种、高密度的森林遥感影像时有优异的分类表现。但是,每个密集层都密集连接在一起引起了输出通道过多,加大了网络的参数和计算量,本文提出了一种 DenseNet_BL 模型,在分类模型的残差块之间插入小型卷积核作为瓶颈层(Bottleneck Layer),对输入的特征图进行降维,减少网络的参数,提高网络模型的收敛速度。

2. 研究区及数据情况

2.1. 研究区概述

琅琊山林区位于安徽省滁州市琅琊区西南部，地处东经 118°07'35"~118°18'21"、北纬 32°15'17"~32°21'49"之间，属于江淮之间的低山丘陵地带，地形为西南高，东北低，主峰小丰山，海拔约 317 米，其它山峰高度在海拔 200~300 米之间，总面积 240 平方公里，是北亚热带向暖温带过渡的湿润季风气候区，林地主要为天然次生林和人工林、针叶林和阔叶林相互交错呈块状、带状混交体系，其间常见的乔木有樟树、广玉兰、龙柏、麻栎、女贞等，常见的灌木有红叶石楠、冬青、桂花树等。山间气候温和，雨量充沛，季风明显，四季分明，因而“四时之景不同”。山间年平均气温为 15.2℃，冬季月平均气温为 1.5℃~4.5℃，夏季七、八月平均气温为 27℃~28℃，年平均降水量约为 1050 毫米，全年无霜期为 217 天。良好的气候，给山区林木的繁殖和其他物类的繁衍创造了有利的条件[9]。

2.2. 数据采集与处理

本文使用的是分辨率为 20,480 × 20,480 的无人机航拍数据制成的数据集。数据集中共有樟树、女贞、红叶石楠、龙柏、桂花树五类树种，共计 300 张图像。对基础数据集中的每一类首先划分出训练集、测试集和验证集，随后对训练集再通过镜像、垂直翻转、水平翻转以及旋转 90°和 180°的方式进行数据增强，增加到原来的 6 倍，得到训练集:验证集:测试集 = 3:1:1。

3. 研究方法

3.1. DenseNet (密集神经网络)

本次实验环境为 Python3.7，基于 PyTorch 框架，训练使用的计算机为：RTX2060 显卡，显存为 12GB。模型的批量大小为 32 (BATCH SIZE)，模型初始学习率为 0.00001，训练次数为 300 次，采用随机梯度下降算法对参数进行更新，加快了收敛速率。

本文使用的算法主体是 DenseNet (密集神经网络) [10]，DenseNet 模型优化了网络中信息和梯度的传递，使得 DenseNet 模型更加容易被训练。每层可以直接利用损失函数的梯度以及最开始的输入信息进行调整，有助于训练深层网络。其主要结构是由 Dense Block (内部密集模块)和 Transition Layer (过渡层)组成的。实现了神经网络的密集连接，构建了“前层传递”的方法，即在网络模型中的每一层输出都来自于前面所有层的传递，这种“前层传递”的方式有效避免了梯度弥散的问题，保证了能获得网络层的最大信息 [11] [12]。(下列(1)式和(2)式中 X_n 代表第 n 层的输出， $H_n(\cdot)$ 为每一层的非线性函数， $[X_1, X_2, \dots, X_{n-1}]$ 为各层的密集连接)

在 ResNet 中的特征传递方式为恒等映射：

$$X_n = H_n(X_{n-1}) + X_{n-1} \quad (1)$$

对 ResNet 而言， n 层的输出是 $l-1$ 层的输出加上对 $n-1$ 层输出的非线性变换。自身与经过 H_n 得到的输出是通过求和的形式来连接的。这会使网络中信息的传播受到影响。

在 DenseNet 中的特征传递方式为“前层传递”，能够更有效地将原始特征传递给后续网络：

$$X_n = H_n([X_1, X_2, \dots, X_{n-1}]) \quad (2)$$

在普通的 n 层卷积神经网络中，总共有 n 层连接，而在 DenseNet 有 $\frac{n(n+1)}{2}$ 层连接(DenseNet 采用“前层传递”的连接方式)。DenseNet 模型结构对特征传递序列进行了调整，而没有按照以往用加深网络或者

加宽网络的方式入手。总体来说 DenseNet 有如下优点：

- 1) 一定程度上解决梯度消失；
- 2) 加强特征传播；
- 3) 更有效地利用特征。

在 DenseNet 模型中 Dense Block 中主要是由 Residual Block [13] [14] [15] (残差块)组成，输入层与各个 Residual Block 相连，各个 Residual Block 之间存在前额全连接，Residual Block 内部则是由两个卷积层组成，将特征图进行合并，实现增加特征图维度的目的。经过改进后在 Residual Block 之间插入 Bottleneck Layer 来降低深层网络在使用时占用的计算资源和存储资源，提高整个网络的计算效率。

Transition Layer 则是由一个卷积核为 1×1 的卷积层与一个池化层组成的。其中卷积层将输入的特征图张数降维到原来的一半，池化层则将特征图的大小降维到原来的一半，降低了密集块(Dense Block)之间传递特征图的维数，提高计算效率问题。

根据 Dense Block 中 Residual Block 数量的不同，可以构成不同层数的 DenseNet 模型，本文所使用的 DenseNet121 模型和 DenseNet169 模型主要差异在于第 3 个和第 4 个 Dense Block 中残差结构的数量上。

3.2. DenseNet_BL

网络深度的增加，会引起卷积层需要训练网络参数的增加，增加了网络的参数和计算量。本文的方法是在 DenseNet Block 中的残差块之间加入 1×1 的小型卷积核作为瓶颈层(Bottleneck Layer) [16]，对传递的特征图进行提前降维[17] [18]。调整后的模型由一个 7×7 的卷积核开始，该卷积核对输入的树冠影像进行内核大小为 7×7 、步幅大小为 2 卷积操作，之后是步长为 2 的 3×3 的最大池化操作。中间部分由 4 个 Dense Block 组成，Dense Block 中的层与层之间通过 1×1 瓶颈层连接，用来对输入的特征图进行降维。Dense Block 之间由过渡层连接，通过卷积和池化操作来改变特征图的大小和尺寸。4 个 Dense Block 之后采用 7×7 的全局平均池化对输出图像进行处理，后面连接 1×1 的全连接层，最后附加一个分类器，输出分类结果。

标准的残差块输入一个 $X \times Y \times Z$ 的特征图后(X 、 Y 为特征图的尺寸， Z 为通道数)，经过一个 3×3 的卷积核后，会向后输出一个 $X \times Y \times Z/2$ 特征图。

标准方法每个残差块的计算量：

$$X \times Y \times Z \times 3 \times 3 \times Z/2 \quad (3)$$

标准方法每个残差块参数量：

$$Z \times 3 \times 3 \times Z/2 \quad (4)$$

加入一个 1×1 卷积作为瓶颈层后，前面传递进来的特征图会先被瓶颈层降维。

本文方法每个残差块的计算量：

$$X \times Y \times Z \times 1 \times 1 \times Z/4 + X \times Y \times Z / 4 \times 3 \times 3 \times Z/2 \quad (5)$$

本文方法每个残差块的参数量：

$$Z \times 1 \times 1 \times Z/4 + Z/4 \times 3 \times 3 \times Z/2 \quad (6)$$

标准方法中的计算量和参数量都约是本文方法的 3.3 倍，证明了瓶颈层能够增加网络的非线性，同时降低网络计算量和参数量，使得网络可以表达更加复杂的特征。

4. 分类实验结果与分析

树种分类结果分析

使用训练好的模型对所选两块样地进行分类实验，得到的分类效果如图 1 所示，得到的各个树种在两个模型上的分类精度如表 1、表 2 所示。

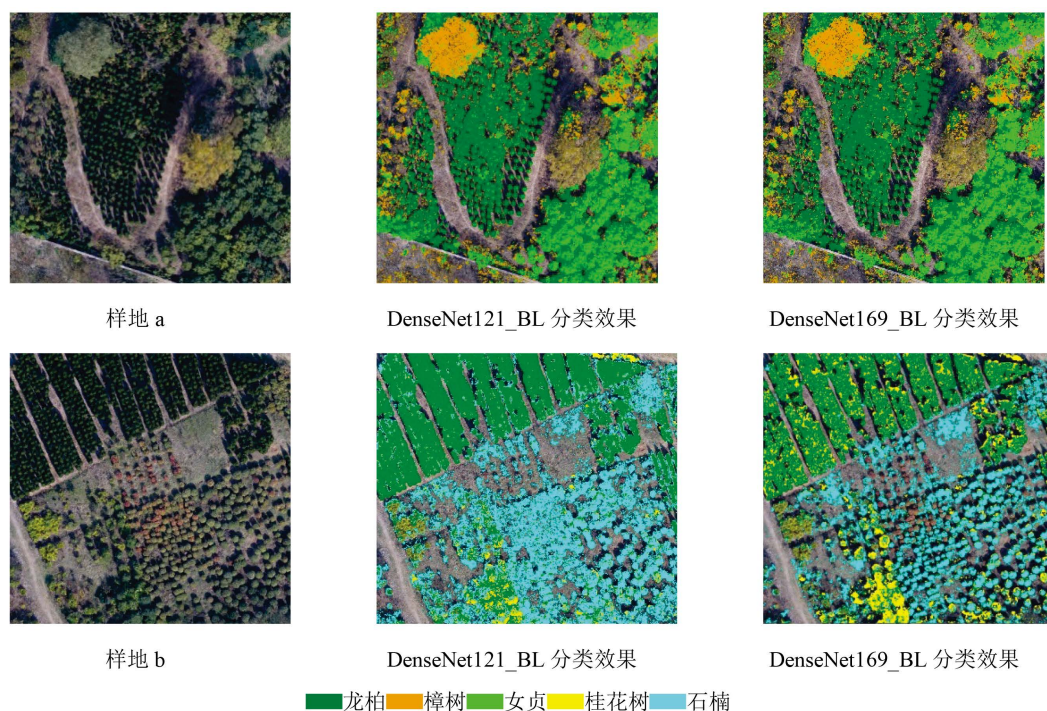


Figure 1. Effect of classification

图 1. 分类效果

Table 1. Classification results of DenseNet121_BL

表 1. DenseNet121_BL 分类结果

名称	正确度	整体精度
龙柏	89.17%	88.29%
石楠	92.92%	
桂花树	89.52%	
女贞	73.48%	
樟树	91.12%	

Table 2. Classification results of DenseNet169_BL

表 2. DenseNet169_BL 分类结果

名称	正确度	整体精度
龙柏	86.55%	83.73%
石楠	85.29%	
桂花树	88.82%	
女贞	63.05%	
樟树	92.66%	

在数据集制作过程中,有的影像中存在一些不属于对应标签树种但又没能避免的空地等地面杂物,在较深的网络模型中,随着模型的感受野增加,对标签树种以外的地物特征提取增加,在得到的实验结果中导致 DenseNet169_BL 模型的整体精度率略低于 DenseNet121_BL。

为了对算法的分类结果进行评估,本文采取相似性系数 JI (Jaccard Index)和准确率(Accuracy)两种评估指标对分类性能进行评价,两种评估指标的计算公式如下:

$$JI = \frac{TP}{TP + FP + FN} \quad (7)$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

式中 TP (真阳性)为正确识别对应树种像素数目, TN (真阴性)为正确识别非对应树种像素数目, FP (假阳性)为错误识别非对应树种像素为对应树种像素数目, FN (假阴性)为错误识别对应树种像素为非对应树种像素的数目。两种模型的评价指标经计算后得到结果如表 3 所示。

Table 3. Rating of merit

表 3. 性能评价

模型	JI	ACC
DenseNet121_BL	0.7370	0.8829
DenseNet169_BL	0.7615	0.8373

可以看出在相似性上 DenseNet169_BL 要高于 DenseNet121_BL,说明了在与样本的相似性上 DenseNet169_BL 要更高。而在准确率上 DenseNet121_BL 要高于 DenseNet169_BL,说明了样本中存在少量非标签树种的现象将会被放大。

5. 结语

本文充分利用所学知识,将图像处理技术与深度学习理论相结合,使用 DenseNet121_BL 和 DenseNet169_BL 网络模型在树种分类方面进行了实验,在验证集上得到的分类正确率最高为 89.17%,这表明将 DenseNet_BL 模型应用于无人机树种分类有很高的可行性。综上所述,本文提出的树种分类模型具有分类效果好、数据易获取、成本低、数据受外界影响较小等优点。但在较深的 DenseNet169_BL 模型中还存在一定的受地面杂物影响的问题,有待改进,并且本文进行实验所使用的树种数据较少,受限于数据量的局限性还需进一步验证模型的可行性,后续可通过补充更多树种数据进行识别。

基金项目

国家自然科学基金项目(41601455);安徽省大学生创新创业训练计划项目(S202010377068);国家级大学生创新创业训练计划项目(202110377012);国家级大学生创新创业训练计划项目(202110377008)。

参考文献

- [1] 黎庆华. 林业生态保护存在的问题及对策[J]. 乡村科技, 2020, 11(35): 60-61.
- [2] 李丹, 黄钰辉, 孙中字, 张卫强, 甘先华, 王佐霖, 孙红斌, 杨龙. 基于机器学习的深圳市坝光湿地公园树种高光谱分类[J]. 红外, 2019, 40(7): 47-52.
- [3] 吴恒, 朱丽艳, 王海亮, 刘智军. 乔木树种分布格局和林分空间结构分析[J]. 林业资源管理, 2020(1): 54-61.
- [4] Masanori, O. and Takeshi, I. (2021) Explainable Identification and Mapping of Trees Using UAV RGB Image and Deep Learning. *Scientific Reports*, **11**, 1-15. <https://doi.org/10.1038/s41598-020-79653-9>

- [5] 万意, 李长春, 赵旭辉, 刘冰洁. 基于 SVM 的光学遥感影像分类与评价[J]. 测绘地理信息, 2018, 43(6): 74-77.
- [6] 赵雪清, 安晓东. 决策树与人工神经网络的对比分析[J]. 电脑开发与应用, 2007(11): 13-15.
- [7] 林志玮, 丁启禄, 黄嘉航, 涂伟豪, 胡典, 刘金福. 基于 DenseNet 的无人机光学图像树种分类研究[J]. 遥感技术与应用, 2019, 34(4): 704-711.
- [8] Geetha, G., Kirthigadevi, T., Ponsam, G.G., et al. (2020) Image Captioning Using Deep Convolutional Neural Networks (CNNs). *Journal of Physics: Conference Series*, **1712**, Article ID: 012015. <https://doi.org/10.1088/1742-6596/1712/1/012015>
- [9] 涂清芳. 琅琊山风景区野生观赏植物资源调查及评价[D]: [硕士学位论文]. 南京: 南京林业大学, 2012.
- [10] 王欣, 樊彦国. 基于改进 DenseNet 联合空谱注意力机制的高光谱图像分类[J/OL]. 激光与光电子学进展, 1-19. <http://kns.cnki.net/kcms/detail/31.1690.tn.20210423.1116.018.html>, 2021-10-10.
- [11] 宋宇鹏, 边继龙, 安翔, 张锡英. 基于注意力机制的 DenseNet 模型的树种识别应用[J]. 实验室研究与探索, 2020, 39(7): 122-127+173.
- [12] 吴云志, 刘翔宇, 朱小宁, 刘晨曦, 范国华, 乐毅, 张友华. FI-DenseNet: 用于植物病害图像识别的卷积网络[J/OL]. 安徽农业大学学报, 2021, 48(1): 1-7. <https://doi.org/10.13610/j.cnki.1672-352x.20210319.002>, 2021-10-10.
- [13] 张玉红, 白韧祥, 孟凡军, 王思斯, 吴彪. 图像识别中的卷积神经网络应用研究[J]. 新技术新工艺, 2021(1): 52-55.
- [14] Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [15] Li, L.W., Qin, S.Y., Lu, Z., Xu, K.H. and Hu, Z.Y. (2020) One-Shot Learning Gesture Recognition Based on Joint Training of 3D ResNet and Memory Module. *Multimedia Tools and Applications: An International Journal*, **79**, 5. <https://doi.org/10.1007/s11042-019-08429-9>
- [16] 马金林, 张裕, 马自萍, 毛凯绩. 轻量化神经网络卷积设计研究进展[J/OL]. 计算机科学与探索, 1-21. <http://kns.cnki.net/kcms/detail/11.5602.tp.20210927.2250.004.html>, 2021-10-10.
- [17] 朱雪晨, 陈三林, 蔡刚, 黄志洪. 降低参数规模的卷积神经网络模型压缩方法[J]. 计算机与现代化, 2021(9): 83-89.
- [18] 郭俊亮, 张洪川. 卷积神经网络模型研究分析[J]. 科技创新与应用, 2021, 11(23): 16-18+22.