

基于深度学习的卫星图像识别分类方法^①



方浩文, 施华君

(中国电子科技集团公司第三十二研究所, 上海 201808)

通讯作者: 方浩文, E-mail: fhwustc@mail.ustc.edu.cn

摘要: 卫星遥感技术是一种非常重要的地球空间监测技术. 卫星遥感图像经过处理后具有数据量大和数据类型复杂多样的特点, 传统方法进行识别分类耗费大量人力物力. 为了降低工作量, 并为后续处理提供便利, 本文将深度学习算法应用于卫星图像的识别分类中, 设计了一种基于 VGGNet 的识别分类方法, 利用除雾算法对训练数据进行数据增强处理, 并添加岭回归正则化层, 利用标签之间的相关性进行预测, 使得方法达到 90% 以上的 F2 score, 并在实验部分进行了对比验证. 最后利用此方法搭建了一个基于 Django 的在线识别分类展示系统.

关键词: 卫星图像; 深度学习; 卷积神经网络; 图像识别; 除雾算法

引用格式: 方浩文, 施华君. 基于深度学习的卫星图像识别分类方法. 计算机系统应用, 2019, 28(10): 27-34. <http://www.c-s-a.org.cn/1003-3254/7081.html>

Satellite Image Recognition and Classification Method Based on Deep Learning

FANG Hao-Wen, SHI Hua-Jun

(The 32nd Research Institute of China Electronics Technology Group Corporation, Shanghai 201808, China)

Abstract: Satellite remote sensing technology is a very important geo-spatial monitoring technology. After being processed, the satellite remote sensing images have a large amount of data characteristics of various complex data types, the traditional target classification and recognition ways spend a lot of manpower and material resources. In order to reduce the workload and provide convenience for subsequent processing, we consider using deep learning algorithms for satellite images classification and recognition. In this paper, we designed an image recognition and classification method based on VGGNet. We augmented data by using haze removal algorithm and other tricks. And we added ridge regression to use correlations between labels to predict. Verified by experiment comparison, this method can achieve more than 90% of F2 score. Finally, an online recognition, classification and display system based on Django is built by using this method.

Key words: satellite image; deep learning; convolutional neural networks; image recognition; dehaze algorithm

卫星遥感图像经过处理后得到的卫星图像包含了大量的信息, 具有数据量大和数据类型复杂多样的特点. 传统的目标检测识别方法难以适应海量数据, 依赖人工标注, 非常耗时耗力, 且强烈依赖于专业知识和数据本身的特征^[1]. 而近年来非常活跃的深度学习^[2-4]则提供了非常有效的特征提取框架, 使得其在卫星遥感图像的识别和分类中也具有很好的效果. 本文采用了

深度学习网络中的卷积神经网络 (CNN), 这是一种能从大量数据中自动学习目标特征的模型, 并且已成为目标检测与识别领域的研究热点^[5-10].

基于 CNN 的目标检测算法的基本流程为特征提取网络、区域建议生成、感兴趣区域分类. 采用卷积神经网络作为特征提取网络, 对检测算法的检测性能具有显著影响. 通常采用的卷积神经网络有 AlexNet^[11],

① 收稿时间: 2019-03-13; 修改时间: 2019-04-04; 采用时间: 2019-04-10; csa 在线出版时间: 2019-10-15

ZF^[12], VGGNet^[13], GoogleNet^[14], ResNet^[15]等, 这些网络通过逐步加深网络来提高性能. 本文采用了 Keras 框架及其中的 VGGNet 神经网络模型并取得了良好的效果.

目前, 已有基于深度学习技术的卫星图像分类识别应用, 如俞汝劼等使用了 YOLO 算法^[16]与图像分割进行了卫星图像中航空器的识别^[17], 保证了算法精度与实时性. 又如 D.Duarte 等利用了对偶连接和加宽卷积的 CNN 来进行卫星图像中建筑物损毁分类^[18], 提升了一定的分类准确度.

卫星图像包含了天气因素, 如雾天、多云等. 这些天气因素会影响地物特征的识别, 同时也可以作为天气特征进行识别. 何恺明在 2009 年提出了暗通道除雾算法^[19], 指出没有雾的图像其像素点在至少一个颜色通道上具有很低的强度, 所以可以根据这个先验和雾图像模型来判断图像中雾的厚度并还原出一个没有雾的图像. 由于所有图像都具有天气特征, 所以意识到此算法可以利用在卫星图像识别分类方面后, 本文使用的方法便利用了此除雾算法进行图像预处理作为改进.

正则化是一种为了避免过拟合而常用的方法, 岭回归正则化即 L2 范数正则化^[20], 通过对模型系数的 L2 范数进行惩罚, 来达到在拟合数据的同时使模型权重尽可能小的目的. 本文采用此方法进行了最后标签之间相关性的处理.

第 1 部分简要介绍深度学习 VGGNet 网络模型、Keras 框架和 F2Score 评测指标; 第 2 部分介绍了识别分类方法的设计及展示系统的框架, 在数据预处理小节介绍了如何利用上述除雾算法等技巧进行数据增强, 随后介绍了基于 VGGNet 模型的训练和预测的流程, 说明了如何使用上述正则化方法利用标签的相关性进行预测, 最后一小节介绍了基于 Django 的在线识别分类展示系统的框架设计及搭建方法; 第 3 部分介绍实验的设计和细节, 并将实验结果进行对比来得出结论, 最后说明本方法的下一步研究方向.

1 深度学习网络模型及框架概述

1.1 VGGNet

VGGNet^[13]是牛津大学计算机视觉组 (Visual Geometry Group) 和 Google DeepMind 公司的研究员一起开发的深度卷积神经网络. VGGNet 探索了卷积神经网络的深度及性能之间的关系, 通过反复堆叠 3×3 的小型卷积核和 2×2 的最大池化层, VGGNet 成功

构筑了 16~19 层深的卷积神经网络 (如图 1 所示). VGGNet 相比之前的网络结构, 错误率大幅下降, 并取得了 ILSVRC2014 比赛分类项目的第二名和定位项目的第一名. 同时具有很好的拓展性, 迁移到其他图片数据上的泛化性非常好.

| Convnet configuration | | | | | |
|---------------------------|------------------------|------------------------|-------------------------------------|-------------------------------------|--|
| A | A-LRN | B | C | D | E |
| 11 Weight layers | 11 Weight layers | 13 Weight layers | 16 Weight layers | 16 Weight layers | 19 Weight layers |
| Input (224×224 RGB image) | | | | | |
| Conv3-64 | Conv3-64 LRN | Conv3-64 Conv3-64 | Conv3-64 Conv3-64 | Conv3-64 Conv3-64 | Conv3-64 Conv3-64 |
| Maxpool | | | | | |
| Conv3-128 | Conv3-128 | Conv3-128 Conv3-128 | Conv3-128 Conv3-128 | Conv3-128 Conv3-128 | Conv3-128 Conv3-128 |
| Maxpool | | | | | |
| Conv3-256 Conv3-256 | Conv3-256 Conv3-256 | Conv3-256 Conv3-256 | Conv3-256 Conv3-256 Conv1-256 | Conv3-256 Conv3-256 Conv3-256 | Conv3-256 Conv3-256 Conv3-256 Conv3-256 |
| Maxpool | | | | | |
| Conv3-512 Conv3-512 | Conv3-512 Conv3-512 | Conv3-512 Conv3-512 | Conv3-512 Conv3-512 Conv1-512 | Conv3-512 Conv3-512 Conv3-512 | Conv3-512 Conv3-512 Conv3-512 Conv3-512 |
| Maxpool | | | | | |
| Conv3-512 Conv3-512 | Conv3-512 Conv3-512 | Conv3-512 Conv3-512 | Conv3-512 Conv3-512 Conv1-512 | Conv3-512 Conv3-512 Conv3-512 | Conv3-512 Conv3-512 Conv3-512 Conv3-512 |
| Maxpool | | | | | |
| FC-4096 | | | | | |
| FC-4096 | | | | | |
| FC-1000 | | | | | |
| Soft-max | | | | | |

图 1 VGGNet 各级别网络结构图

VGGNet 拥有 5 段卷积, 每一段内有 2~3 个卷积层, 同时每段尾部会连接一个最大池化层来缩小图片尺寸. 每段内的卷积核数量一样, 越靠后的段的卷积和数量越多: 64-128-256-512-512. 其中经常出现多个完全一样的 3×3 的卷积层堆叠在一起的情况, 是因为 3 个串联的 3×3 卷积层效果相当于 1 个 7×7 的卷积层, 参数比后者少 45%, 且 3 个 3×3 的卷积层拥有比 1 个 7×7 卷积层更多的非线性变换, 使得 CNN 对特征的学习能力更强^[21].

1.2 Keras 框架

Keras^[22]是一个用 Python 编写的高级神经网络 API, 它能够以 Tensorflow, CNTK 或者 Theano 作为后端运行, 具有用户友好、模块化、以拓展性和基于 Python 实现的特点, 同时支持卷积神经网络和循环神经网络以及两者的结合, 能够在 CPU 和 GPU 上无缝运行.

1.3 F2-Score

F-Score^[23]是一个为了平衡准确率和召回率的较为全面评价的一个分类指标. 当对一个样本集合(包括正样本和负样本)进行分类时, 会出现以下几种情况:

TruePositive: 把本来是正样本的分类成正样本;

FalsePositive: 把本来是负样本的分类成正样本;

FalseNegative: 本来是正样本的分类成负样本;

TrueNegative: 本来是负样本的分类成负样本.

对准确率 (*Precision*) 和召回率 (*Recall*) 的定义如下:

$$Precision = \frac{TruePositive}{TruePositive + FalsePositive}$$

$$Recall = \frac{TruePositive}{TruePositive + FalseNegative}$$

F-Score 的定义如下:

$$F_{\beta} = (1 + \beta^2) \frac{Precision \times Recall}{\beta^2 \times Precision + Recall}$$

所以 F2-Score 即当 $\beta=2$ 时的 F-Score, 即召回率比准确率重要一倍.

2 除雾算法与正则化介绍

2.1 除雾算法

何恺明提出了一种非常简单而有效的去雾算法^[19], 可以同来还原图像的颜色和能见度. 与之前的方法不同, 他把注意力放到了无雾图像的统计特征上. 他发现, 在无雾图像中, 每一个局部区域都很有可能会有阴影, 或者是纯颜色的东西, 又或者是黑色的东西. 因此, 每一个局部区域都很有可能会有至少一个颜色通道会有很低的值. 他把这个统计规律叫做暗通道先验. 直观来说, 暗通道先验认为每一个局部区域都总有一些很暗的东西. 由于雾总是灰白色的, 因此一旦图像受到雾的影响, 那么这些本来应该很暗的东西就会变得灰白. 不仅如此, 根据物理上雾的形成公式, 还能根据这些东西的灰白程度来判断雾的浓度.

给暗通道先验一个数学定义, 对于任意的输入图像 J , 其暗通道可以用下式表达:

$$J^{dark}(x) = \min_{y \in \Omega(x)} \left(\min_{c \in \{r, g, b\}} J^c(y) \right) \quad (1)$$

式中, J^c 表示彩色图像的每个通道, $\Omega(x)$ 表示以像素 X 为中心的一个窗口.

暗通道先验的理论指出:

$$J^{dark} \rightarrow 0 \quad (2)$$

在文献[15]中, 统计了 5000 多幅图像的特征, 基本符合暗通道先验, 因此可以认为是一条定理. 接着进行数学推导来解决最终问题.

在计算机视觉和计算机图形中, 下述方程描述的雾图形成模型被广泛应用:

$$I(x) = J(x)t(x) + A(1 - t(x)) \quad (3)$$

其中, $I(x)$ 为已有待去雾图像, $J(x)$ 为恢复成无雾的图像, A 为全球大气光成分, $t(x)$ 为透射率.

将式(3)做变形:

$$\frac{I^c(x)}{A^c} = t(x) \frac{J^c(x)}{A^c} + 1 - t(x) \quad (4)$$

式中, c 为 RGB 三通道.

假设在每一个窗口内透射率 $t(x)$ 为常数, 定义其为 $\tilde{t}(x)$, 且 A 已知, 对式(4)两边求两次最小值运算, 得到:

$$\min_{y \in \Omega(x)} \left(\min_c \frac{I^c(y)}{A^c} \right) = \tilde{t}(x) \min_{y \in \Omega(x)} \left(\min_c \frac{J^c(y)}{A^c} \right) + 1 - \tilde{t}(x) \quad (5)$$

根据暗通道先验理论式(1), 可推导出:

$$\min_{y \in \Omega(x)} \left(\min_c \frac{J^c(y)}{A^c} \right) = 0 \quad (6)$$

将式(6)带入式(4), 得到:

$$\tilde{t}(x) = 1 - \min_{y \in \Omega(x)} \left(\min_c \frac{I^c(y)}{A^c} \right) \quad (7)$$

这就是透射率的预估值.

在实际情况下, 即使天气晴朗, 空气中也存在一定颗粒, 看远处物体还是能感觉到雾的影响, 所以需要保留一定程度的雾, 可以通过在式(7)中引入一个 $[0, 1]$ 之间的因子 ω , 则式(7)修正为:

$$\tilde{t}(x) = 1 - \omega \min_{y \in \Omega(x)} \left(\min_c \frac{I^c(y)}{A^c} \right) \quad (8)$$

以上运算均基于全球大气光 A 已知, 实际可以在有雾图像中获取该值, 步骤为:

(1) 从暗通道图中按照亮度的大小提取前 1% 的像素;

(2) 在这些位置中, 在原始有雾图像 I 中寻找对应的具有最高亮度的点的值, 作为 A 值.

当投射度 t 的值很小时, 会导致 J 的值偏大, 从而使得图像整体向白场过度, 因此一般可设置一阈值 T_0 , 当 t 值小于 T_0 时, 令 $t=T_0$.

最终的恢复公式如下:

$$J(x) = \frac{I(x) - A}{\max(t(x), t_0)} + A \quad (9)$$

在意识到可以利用除雾算法作为在有雾图像的地物特征识别的改进后, 本方法在预处理阶段对图像进行了除雾处理, 效果如图2.

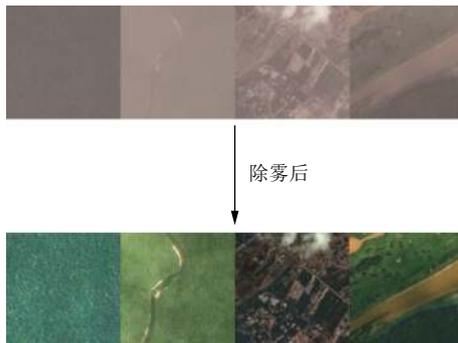


图2 图像除雾算法使用前后对比

可以看到地物特征明显更为显著, 更有利于对地物特征进行识别, 之后将通过实验证明除雾算法的有效性.

2.2 正则化

有监督机器学习主要问题即在规则化参数的同时最小化误差, 最小化误差为了模型能很好拟合训练数据, 而规则化参数是为了防止模型过拟合训练数据. 如果参数太多, 会导致模型复杂度上升, 导致过拟合. 于是正则化的作用有:

(1) 约束参数, 降低模型复杂度;

(2) 规则项的使用还可以约束我们的模型的特性, 这样就可以将人对这个模型的先验知识融入到模型的学习当中, 强行地让学习到的模型具有人想要的特性, 例如稀疏、低秩、平滑等等.

一般来说, 监督学习可以看成最小化如下目标函数:

$$\omega^* = \arg \min_{\omega} \sum_i L(y_i, f(x_i; \omega)) + \lambda \Omega(\omega) \quad (10)$$

其中, 求和部分第一项 $L(y_i, f(x_i; \omega))$ 为误差平方和, 第二项 $\lambda \Omega(\omega)$ 为惩罚项, 为了使模型尽量简单, 我们需要通过规则化函数 $\Omega(\omega)$ 来对参数 ω 进行约束. 然而 $\Omega(\omega)$ 的不同取得的效果也不同, 主要常见的 $\Omega(\omega)$ 有 L0, L1 和 L2 范数.

L0 范数指向量中非 0 的元素的个数. 如果用 L0 范数来规则化一个参数矩阵 ω 的话, 就是希望 ω 的大

部分元素都是 0. L1 范数是指向量中各个元素绝对值之和, 也称 Lasso 回归正则化.

L1 范数为 L0 范数的最优凸近似, L1 范数和 L0 范数可以实现稀疏, L1 因具有比 L0 更好的优化求解特性而被广泛应用. 参数稀疏可以实现对特征的自动选择, 会学习筛选掉信息量不够的特征, 且会让模型更容易解释. 在本数据集中, 因为大量特征具有相关性, 如天气特征中, 有晴朗标签则不会有云、雾天气标签, 河流常出现在雨林旁边, 道路常在住房和农业处出现. 故不适合使用更有利于处理稀疏特征数据的 L1 范数.

L2 范数又称岭回归正则化, 是指先对向量中各元素进行求平方和, 然后再求平方根. 通过让 L2 范数的规则项 $\|\omega\|_2$ 最小, 可以使得 ω 的每个元素都接近于 0.

L2 范数可以使参数变小, 从而使得模型更简单, 因此不仅可以防止过拟合, 还可以让优化求解变得稳定与快速^[24]. 岭回归正则化在本数据集中表现良好, 精度更高且更好适应与拟合. 故本方法采用了添加岭回归正则化层来进行特征之间相关性的处理.

3 基于深度学习的识别分类与展示

3.1 数据预处理

因为卫星数据数量庞大, 会有许多诸如云、雾等天气因素干扰使得我们无法看清地物特征, 此时可以使用图像除雾算法使得类似路、水、农田等标签更明显, 从而能够得到更好的地物特征. 本文对训练数据进行了除雾算法操作 (图3), 同时保留原有数据进行对比. 由于进行了去雾处理, 所以针对其中包含云、雾等标签的图像会降低特征, 下一节会讲述如何处理这个问题.

其次在训练数据时还需要通过变换图像大小来进行输入, 然后通过数种数据增强方法进行随机变换, 从而增加了训练数据集大小, 并可以更好地防止过拟合以及增强模型的鲁棒性.

3.2 模型训练

因为使用了除雾算法可能会导致某些标签变换过大, 本方法采用了对每个标签进行单独训练模型的方式 (图4), 即使用除雾后和未除雾的原始训练集进行每个标签的单独训练, 得到了每个标签在不同训练集上的准确率. 由于一张图中可能会含有数个标签, 于是选择每个标签在验证集上表现更好的使用的训练集训练出的模型, 将标签进行整合, 从而减少除雾算法带来的负面效果. 例如, 除雾后训练出没有雾标签的图像在未

除雾时训练出有雾标签, 则说明此图像有雾标签的准确度更高, 在验证集上验证结果也是如此.

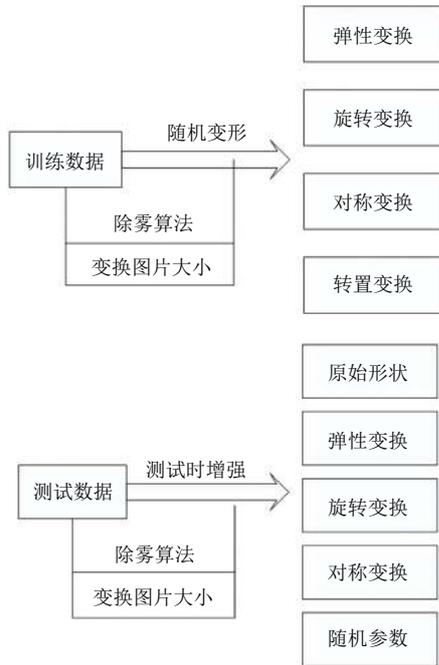


图3 数据预处理流程

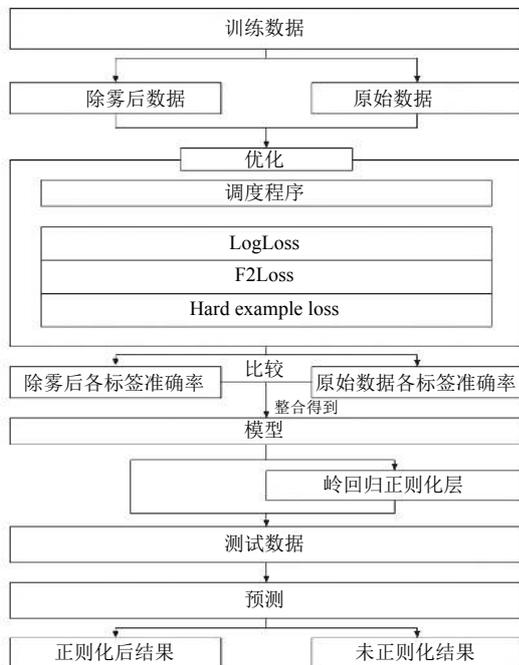


图4 训练模型及预测流程

训练时采用了3种损失(loss)函数, 其中F2Loss是一种结合了准确率和召回率的评估指标, 其召回率

比准确率重要一倍. 所以在训练模型时不仅仅需要训练预测标签的概率, 还需要选择一个合适的阈值, 使得当概率大于阈值时, 判断有此标签, 否则没有. 本文对F2-Loss函数进行了改进, 使得训练时更侧重于改进每个标签的召回率, 从而更符合F2-Score的评判标准. 结果是对某些如全云、农业等标签效果明显.

3.3 预测

许多标签有着相关性, 比如晴朗和有云、全云和有雾就不可能同时出现, 而住房和农业同时出现的情况更多, 即利用相关性可以更好地改进模型进行预测. 所以在本文提出的方法里, 采用了以下方法: 先用VGGNet训练出所有标签的单独概率, 依前方法整合得到模型, 随后添加一个岭回归正则化层, 以便在给定所有其他标签的情况下重新校准每个标签的概率. 相当于在进行特定标签的最终预测时, 又添加了一个输入为所有标签的VGGNet预测的单独的特定标签岭回归模型. 这样一来就利用了各标签之间的相关性来提升了模型的鲁棒性, 且减少了因为数据集相关性而导致的过拟合现象. 并且本文做了没有添加岭回归正则化层的对比实验.

3.4 展示系统搭建

为了能够更好地展现本方法的结果, 并建立在线上传识别图像并展示的系统, 使用Django搭建了一个在线展示系统(图5).

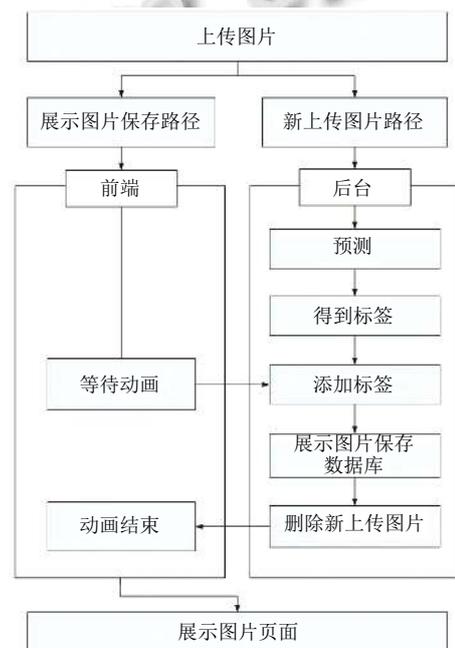


图5 展示系统设计流程

Django 是一个用 Python 语言编写的开源 Web 开发框架, 鼓励快速开发, 并遵循模型-视图-控制器 (MVC) 设计. 功能完善, 要素齐全, 具有强大的数据库访问组件、灵活的统一资源定位符 (URL) 映射、丰富的模板语言, 安全性和可拓展性都非常优秀.

展示系统具有以下功能: 批量上传、等待动画、批量预测和带标签展示.

批量上传后将新上传的图片分别保存至展示图片保存路径和新上传图片保存路径, 并对新上传的图片进行预测并得到标签, 于此同时, 前端界面显示等待动画. 得到标签后对展示图片进行标签添加, 将展示图片保存至数据库, 并删除新上传图片. 这一步是为了每次上传后只用预测新上传的图片, 而展示图片均已添加过标签, 直接放入展示图片页面即可, 相比每次都要进行全部图片预测大大提高了速度. 上述操作进行完毕后等待动画结束并进入展示图片页面.

4 实验结果与分析

为了验证本文提出的基于深度学习的识别分类方法, 对实验设计如下.

4.1 准备工作

数据来源于 Planet 和其合作伙伴 SCCON 在太阳同步轨道 (SSO) 和国际空间站 (ISS) 轨道上的 4 波段卫星的地球全帧分析场景图片, 并用 Crowd Flower 平台以及柏林和洛杉矶的标注团队进行标注, 共分为全云 (Cloudy), 局部有云 (Partly Cloudy), 有雾 (Haze), 清晰 (Clear) 等 4 个天气标签; 原始森林 (Primary), 水 (Water), 居住 (Habitation), 农业 (Agriculture), 道路 (Road), 种植 (Cultivation), 裸地 (Bare Ground) 等 7 个常见地物标签; 刀耕火种 (Slash and Burn), 选择性砍伐 (Selective logging), 开花 (Blooming), 常规采煤 (Conventional Mining), 矿业采煤 (Artisinal Mining), 吹倒 (Blow Down) 等 6 个不常见地物标签. 总共 17 个标签, 40 479 张有标注的图片.

4.2 实验阶段

在训练数据经过随机变换后以 8 : 2 的比例随机分成训练集和验证集, 并进行标签映射, 将训练集中有云、雾的图片进行了除雾处理, 并保留原始数据进行对照实验. 对所有图片进行红绿蓝 (RGB) 转换, 去除各维度均值. 均值来自于 ImageNet 数据集统计, ImageNet 含有近 1400 多万张图片, 涵盖 2 万多个类别, 去除均

值更有利于图像训练. 随后进行大小裁剪使得符合 VGGNet 输入, 并加载 Keras 框架中的 VGGNet-16 模型.

加载模型完成后进行批标准化. 批标准化是近年来深度学习领域的重要成果, 可以使得在神经网络训练过程中每一层神经网络的输入保持相同分布. 随着网络深度的加深和训练过程的进行, 深层神经网络在做非线性变换前的激活输入值会逐渐发生偏移和变动, 整体分布逐渐往非线性函数的取之区间的上下限两端靠近, 导致反向传播时低层神经网络的梯度消失, 从而会使得神经网络收敛越来越慢. 而批标准化可以通过一定的手段, 将每层神经网络任意神经元的输入值分布变成均值为 0 方差为 1 的正态分布, 避免梯度消失问题.

在卷积层和全连接层之间使用扁平函数, 使得多维输入变成一维, 大大减少参数使用量, 避免过拟合现象.

优化器选择自适应矩估计, 初始学习率 lr 为 0.0001, 采用当评价指标不再提升时减少学习率的策略, 减少因子 $factor$ 为 0.1, 每次学习率将以 $lr*factor$ 的形式减少. 因为当学习停滞时, 减少 2 倍到 10 倍的学学率常常能获得较好的效果. 当 3 个循环后评价指标都不再改善后将停止训练.

激活函数选择 LeakyReLU, 是 ReLU 激活函数的特殊版本, 当不激活时, LeakyReLU 仍然会有非零输出, 从而获得一个小的梯度, 避免 ReLU 可能出现的神经元“死亡”现象.

最后在预测前进行了添加岭回归正则化层、添加 Lasso 回归正则化层和不添加的对照实验.

4.3 实验结果

本节通过对照实验对除雾算法和岭回归正则化层的效果进行了验证, 具体如图 6、图 7 和图 8.

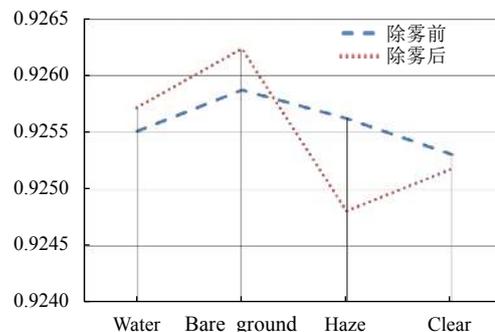


图 6 除雾前后部分标签验证集 F2-Score

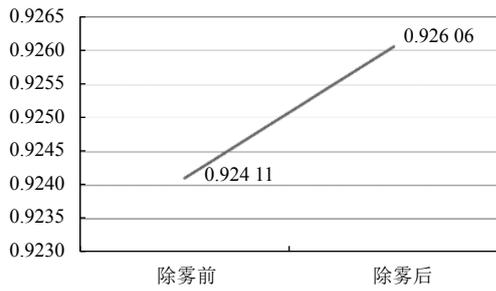


图7 除雾前后总体 F2-Score

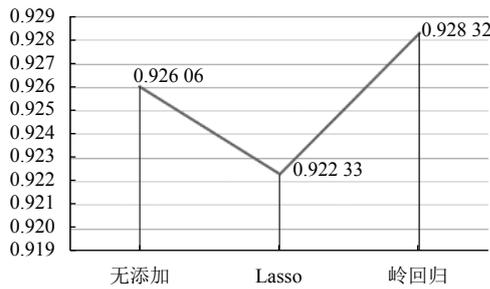


图8 添加正则化层前后总体 F2-Score

由图6和图7可以看出,除雾算法增强了部分标签(如 water 和 bare_ground)的 F2-Score,但同时也降低了其他的标签(如 haze 和 clear)的 F2-Score.然而这点降低可以通过为每个标签选择更好的模型,并整合这些模型来解决.总体来说除雾算法提高了整体的 F2-Score,效果明显.

由图8可以看出,相比于不添加和添加 Lasso 回归正则化层,添加岭回归正则化层可以改善整体预测效果,对提高识别准确率有帮助,证明了添加岭回归正则化层的作用.

根据表1可以看出,大部分标签的 F2-Score 可以达到 90% 以上,表现出良好的检测效果,但有部分标签 F2-Score 甚至不到 50%.根据分析论证后得到以下影响分类精度的因素:

(1) 数据集的大小.本方法采用的数据集总量达四万余张图片,总体数据集大小足够进行训练,故天气标签及常见地物标签经过训练后得到良好的结果,而不常见的地物标签只有区区数百张图片,数据集过小,故无法很好地提取特征进行训练,从而得到的结果不如人意.但这些标签总数不多,对总体的 F2-Score 影响并不大.

(2) 人工标注时的误差.由于本方法采用的数据集需要人工标注,而人工标注时由于每个人对标签的判断不尽相同,且同一个人也可能会对标签的判断前后

不一,从而会出现标注误差.这属于不可避免的影响因素,对每个需要有标注数据集的实验均会有影响.

(3) 地物标签的交叉.由于本数据集含有的部分标签具有相互交叉的特点,如:农业与种植、常规采煤与矿业采煤等,故会在训练时会影响特征的提取,从而会影响预测时标签的分类.

表1 各标签原始 F2-Score

| 标签 | F2-Score |
|-------|----------|
| 全云 | 0.924 89 |
| 局部有云 | 0.925 58 |
| 有雾 | 0.925 63 |
| 清晰 | 0.925 31 |
| 原始森林 | 0.931 02 |
| 水 | 0.925 51 |
| 居住 | 0.926 22 |
| 农业 | 0.923 48 |
| 道路 | 0.926 57 |
| 种植 | 0.922 35 |
| 裸地 | 0.925 88 |
| 刀耕火种 | 0.356 18 |
| 选择性砍伐 | 0.423 53 |
| 开花 | 0.176 64 |
| 常规采煤 | 0.210 35 |
| 矿业采煤 | 0.362 51 |
| 吹倒 | 0.148 89 |

本方法在不断地微调后得到的 F2-Score 为 92.832%,证明本方法针对卫星遥感图像取得了良好的检测效果,准确地挖掘到了数据特征,可以作为卫星图像识别分类系统的算法.于是本文利用此方法进行展示系统服务器搭建,部分效果如图9所示.

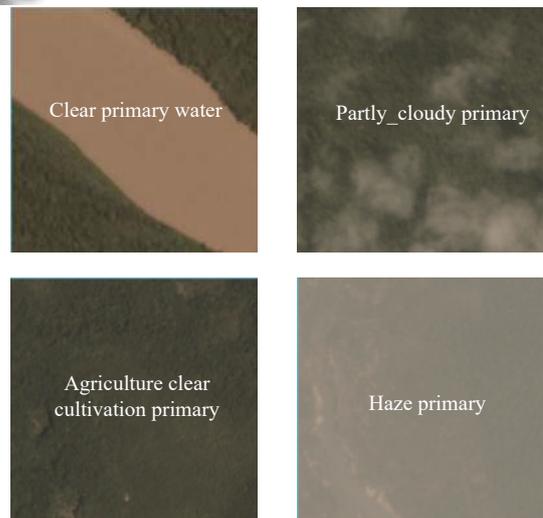


图9 卫星图像识别分类系统(部分)

5 结束语

本文提出了利用除雾算法与岭回归正则化的基于深度学习网络模型 VGG 的卫星图像识别分类方法, 针对卫星遥感图像的特点, 分析了卷积神经网络的原理和框架结构, 使用深度学习的方法进行了识别和分类. 通过一系列的数据增强方法和调整, 得到了合理优化的卷积神经网络. 最后将方法应用于在线识别分类展示系统. 实验结果表明本文方法能够准确对卫星图片进行识别分类, 从而证明其有效性. 如何进一步提高准确率和减少模型规模是下一步的研究方向.

参考文献

- 1 姚连生. 基于模糊聚类的遥感图像云判算法研究[学位论文]. 北京: 北京航空航天大学, 2013.
- 2 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436–444. [doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539)]
- 3 陈旭, 孟朝晖. 基于深度学习的目标视频跟踪算法综述. *计算机系统应用*, 2019, 28(1): 1–9. [doi: [10.15888/j.cnki.csa.006720](https://doi.org/10.15888/j.cnki.csa.006720)]
- 4 Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*, 2015, 61: 85–117. [doi: [10.1016/j.neunet.2014.09.003](https://doi.org/10.1016/j.neunet.2014.09.003)]
- 5 Ren SQ, He KM, Girshick R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137–1149. [doi: [10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031)]
- 6 吕铄, 蔡烜, 冯瑞. 基于改进损失函数的 YOLOv3 网络. *计算机系统应用*, 2019, 28(2): 1–7. [doi: [10.15888/j.cnki.csa.006772](https://doi.org/10.15888/j.cnki.csa.006772)]
- 7 李俊杰, 刘成林, 朱明. 基于多任务 CNN 的监控视频中异常行人快速检测. *计算机系统应用*, 2018, 27(11): 78–83. [doi: [10.15888/j.cnki.csa.006607](https://doi.org/10.15888/j.cnki.csa.006607)]
- 8 姚相坤, 万里红, 霍宏, 等. 基于多结构卷积神经网络的高分遥感影像飞机目标检测. *计算机工程*, 2017, 43(1): 259–267. [doi: [10.3969/j.issn.1000-3428.2017.01.045](https://doi.org/10.3969/j.issn.1000-3428.2017.01.045)]
- 9 赵银玲, 周武能. 基于改进卷积神经网络的交通标志识别方法. *计算机系统应用*, 2018, 27(10): 209–213. [doi: [10.15888/j.cnki.csa.006580](https://doi.org/10.15888/j.cnki.csa.006580)]
- 10 马晓焯, 张谧. 基于标签卷积神经网络的文本推荐算法. *计算机系统应用*, 2018, 27(8): 132–137. [doi: [10.15888/j.cnki.csa.006494](https://doi.org/10.15888/j.cnki.csa.006494)]
- 11 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*. Lake Tahoe, NV, USA, 2012. 1097–1105.
- 12 Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. *Proceedings of the 13th European Conference on Computer Vision*. Zurich, Switzerland, 2014. 818–833.
- 13 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv: 1409.1556*, 2014.
- 14 Szegedy C, Liu W, Jia YQ, *et al.* Going deeper with convolutions. *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA, USA, 2015. 1–9.
- 15 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. *Proceeding of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA, 2016. 770–778.
- 16 Redmon J, Divvala S, Girshick R, *et al.* You only look once: Unified, real-time object detection. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA, 2016. 779–788.
- 17 俞汝劼, 杨贞, 熊惠霖. 基于深度卷积神经网络的航空器检测与识别. *计算机应用*, 2017, 37(6): 1702–1707, 1715. [doi: [10.11772/j.issn.1001-9081.2017.06.1702](https://doi.org/10.11772/j.issn.1001-9081.2017.06.1702)]
- 18 Duarte D, Nex FC, Kerle N, *et al.* Satellite image classification of building damages using airborne and satellite image samples in a deep learning approach. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, IV-2: 89–96. [doi: [10.5194/isprs-annals-IV-2-89-2018](https://doi.org/10.5194/isprs-annals-IV-2-89-2018)]
- 19 He KM, Sun J, Tang XO. Single image haze removal using dark channel prior. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12): 2341–2353. [doi: [10.1109/TPAMI.2010.168](https://doi.org/10.1109/TPAMI.2010.168)]
- 20 李航. 统计学习方法. 北京: 清华大学出版社, 2012.
- 21 黄文坚, 唐源. TensorFlow 实战. 北京: 电子工业出版社, 2017: 108.
- 22 Chollet, François and Others. Keras. <https://keras.io>, 2015.
- 23 Manning CD, Raghavan P, Schütze H. *Introduction to Information Retrieval*. Cambridge: Cambridge University Press, 2008. 155–158.
- 24 zouxy09. 机器学习中的范数正则化之 (一) L0、L1 与 L2 范数. <https://blog.csdn.net/zouxy09/article/details/24971995>, [2014-05-04].