

基于深度学习的肺部肿瘤图像识别方法

高雷鸣, 肖满生, 向华政

(湖南工业大学 计算机学院, 湖南 株洲 412000)

摘要: 鉴于浅层卷积神经网络难以获取图像深层特征、易过度拟合导致分类效率和精度低的问题, 因此, 设计一种肺部肿瘤图像的深度学习识别模型; 在运用样本扩充和迁移学习的基础上, 对 AlexNet 卷积神经网络进行改善和提升, 在每层网络数据输入之前对数据进行归一预处理, 同时使用线性整流函数 (ReLU), 实现对肺部肿瘤表达性特征的快速获取, 输出端经由三层全连接层和 softmax 算法进行分类; 实验结果表明, 此方法在网络收敛速率和分类精度方面取得更优性能, 比基于 AlexNet 卷积神经网络分类精度提高 5.66% 以上, 且具备良好的健壮性。

关键词: 样本扩充; 迁移学习; 深度学习; 归一预处理; 医学图像识别

Method for Lung Tumor Image Recognition Based on Deep Learning

Gao Leiming, Xiao Mansheng, Xiang Huazheng

(College of Computer, Hunan University of Technology, Zhuzhou 412000, China)

Abstract: In view of the fact that shallow convolutional neural networks are difficult to obtain the deep features of the image and are easy to overfit, which leads to low classification efficiency and accuracy, a deep learning recognition model for lung tumor images is designed. Based on the use of data augmentation and transfer learning, and the improvement and promotion of the AlexNet convolutional neural network, the data is subjected to a normal preprocessing before the data input of each layer of the network, while applying a linear rectification function (ReLU). Realize fast acquisition of lung tumor expression characteristics, and the output end is classified through three fully connected layers and Softmax algorithm. The experimental outcome indicate that the proposed method achieves better performance in terms of network convergence speed and classification accuracy, which is 5.66% higher than that based on the AlexNet convolutional neural network, and it has good robustness.

Keywords: sample expansion; migration learning; deep learning; normalized preprocessing; medical image recognition

0 引言

肺癌是现如今人类生命的危害之一, 如果能在早期发现并医治能大大提升肺癌病人的生存率。电子断面检测 (CT) 被用作肺癌诊断的筛查工具, 有助于肺癌早期的诊断, 但是分析海量肺部 CT 图像信息需要医生付出大量努力, 而且早期肺部肿瘤特征不明显, 医生在分析影像局部微小特征时会产生迟疑, 无法对病人病情做出精确判断。同时医生的个人阅历作用于整个的诊断流程, 缺少系统化的规范, 不同的医生对于同一幅肺部 CT 图像可能会产生分歧, 所以这种诊断模式必定存在主观成分的干扰, 快速准确地判断肺部是否有肿瘤和肿瘤良性还是恶性, 能够减少前期繁琐的检查, 防止不必要的手术, 减轻患者心理和身体的痛苦, 还能够提升病人的存活率。因此, 实现肺部肿

瘤图像的自动检测是一项非常具有研究价值和难度的工作。

当前, 主要在两方面实现对肺部肿瘤图像分类。第一是基于基础学习策略的方法, 采用小波分析 (WT)、非参数局部纹理特征描述子等特征提取方法和核方法、多决策树、加权稀疏编码算法等分类方法。如 F. Han^[1] 等人对伽柏纹理、边缘特征和非参数局部纹理特征描述子进行提取来训练稀疏稳健分类器进行肺部肿瘤图像的分类。采用基于基础学习策略的学习方法, 无法自动进行特征提取且过程复杂, 对专业领域的条件需求过高, 而且由于算法局限性, 对细微特征的提取方面也存在一定的难度, 严重限制了对肺部肿瘤图像分类。第二是利用卷积神经网络 CNN 进行识别。深度学习是基础学习更深领域的研究, 其中, CNN 模型在人工智能如生物身份识别^[2]、人机交互识别^[3-4]、医学影像分析^[5] 等领域都获得了突出的成就, 该网络可以直接对原始图像进行处理, 自动学习相应的有效特征, 避免了传统分类方法的繁琐性和限制性。

现如今, 卷积神经网络已普遍运用在医学图像分类。文献^[6]利用噪声数据训练编码器获取肺部肿瘤图像的特征, 训练泛化性能强的编码器, 对肿瘤图像做出良性和恶性判断, 比浅层特征提取方法取得了更高的鲁棒特征; 文献^[7]采用多标准特征提取方法训练网络, 解决了单标准特征提取的单一性和局限性, 获得了更高的分类性能; 文献^[8]提出一种处理海量数据的模型, 对网络内部进行升

收稿日期: 2020-02-28; 修回日期: 2020-03-30。

基金项目: 湖南省自然科学基金资助项目 (2018JJ4068, 2018JJ4078)。

作者简介: 高雷鸣 (1995-), 男, 山东淄博人, 硕士生, 主要从事医学图像处理和深度学习方向的研究。

肖满生 (1968-), 男, 湖南株洲人, 教授, 硕士生导师, 主要从事医学图像处理和深度学习方向的研究。

向华政 (1971-), 男, 湖南常德人, 硕士, 副教授, 主要从事机器学习方向的研究。

级, 在网络中加入隐层, 使模型能够提取更具张力的特性, 在面对海量图像数据时比现有方法具备更高的性能。然而, 由于医学 CT 图像的样本注释受限于匮乏的医学专家, 获取海量注释样本难以实现, 从而导致缺少肺部训练数据集, 卷积神经网络依然存在无法提取更有目的性的深层特征和拟合难题。

面对上述难题, 本文将样本扩充、迁移学习应用于卷积神经网络模型, 并在网络中引入批量归一化层, 输出层通过三层全连接层和 softmax 回归进行分类, 解决特征提取的繁琐性和网络微数据过拟合性, 从而提高肺部肿瘤图像的分类精度。

1 算法描述

1.1 卷积神经网络

卷积神经网络是由神经认知机模型^[9]进化而来的。现如今, 卷积神经网络已发展成为一个庞大的多层神经网络, 对图像全局特征地提取学习与分类是经过逐层来完成的。

卷积层是局部性的低层特征提取层, 如图 1 所示通过卷积核从左到右、从上到下的顺序依次作用于原始矩阵, 并将矩阵对应位置的元素相乘后相加, 经过多次卷积操作得到输入矩阵的特征图 (feature map)。卷积核矩阵的数值通过不断训练达到拟合。卷积计算^[10]如下式:

$$D_j^{(l)} = f\left(\sum_{i \in M_j} D_j^{(l-1)} * k_{ij}^{(l)} + c_j^{(l)}\right) \quad (1)$$

式中, $D_j^{(l)}$ 表示 l 层卷积计算的第 j 个特征 map, $f(\cdot)$ 表示神经网络神经元运行的函数, M_j 表示原始的特征 map 聚合, $*$ 表示滤波操作, k_{ij} 表示 l 的第 j 个特征 map 通道和下层的第 i 个特征 map 通道之间的过滤器, $c_j^{(l)}$ 表示偏置参数。

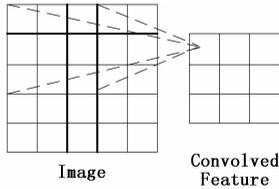


图 1 卷积操作

池化层是对卷积层特征进行整合分析。池化层作用于相邻的卷积层之间, 用来减少样本和数值的量, 以达到简化特征的维度、加速网络训练效率和避免过拟合现象的目的。池化计算公式

$$D_j^{(l)} = f(\beta_j p(x_j^{l-1}) + c_j^{(l)}) \quad (2)$$

式中, $p(\cdot)$ 表示降维函数, β 表示权重参数。

全连接层是特征加权层, 对特征矩阵进行向量相乘, 综合池化后的所有特征, 整合出具有区分性和目的性的特征信息, 结合 softmax 回归达到对图像分类的目的。

1.2 Softmax 分类器

本文使用 softmax 回归模型对肺部肿瘤图像进行分类。回归模型用假设函数 l_θ 计算测试样本 n 属于不同种类的几率值 $p(m = j | n)$, 假设函数为:

$$l_\theta(n^{(i)}) = \begin{pmatrix} p(m^{(i)} = 1 | n^{(i)}; \theta) \\ p(m^{(i)} = 2 | n^{(i)}; \theta) \\ \vdots \\ p(m^{(i)} = k | n^{(i)}; \theta) \end{pmatrix} = \frac{1}{\sum_{j=1}^w e^{\theta_j^T n^{(i)}}} \begin{pmatrix} e^{\theta_1^T n^{(i)}} \\ e^{\theta_2^T n^{(i)}} \\ \vdots \\ e^{\theta_w^T n^{(i)}} \end{pmatrix} \quad (3)$$

式中, θ 代表模型的参数, $\frac{1}{\sum_{j=1}^w e^{\theta_j^T n^{(i)}}}$ 表示概率分布归一化项。

w 项概率分布为:

$$p(m^{(i)} = j | n^{(i)}; \theta) = \frac{e^{\theta_j^T n^{(i)}}}{\sum_{l=1}^w e^{\theta_l^T n^{(i)}}} \quad (4)$$

Softmax 的代价函数为:

$$J(\theta) = -\frac{1}{N} \left[\sum_{i=1}^N \sum_{j=1}^w I\{m^{(i)} = j\} \log \frac{e^{\theta_j^T n^{(i)}}}{\sum_{l=1}^w e^{\theta_l^T n^{(i)}}} \right] + \frac{\lambda}{2} \sum_{i=1}^w \sum_{j=0}^D \theta_{ij}^2 \quad (5)$$

式中, $\lambda(\lambda > 0)$ 为正则化系数。 $I\{m^{(i)} = j\}$ 为特征函数。使用梯度法来得到式 (5) 最小值。

1.3 迁移学习

本文是对肺部肿瘤图像微样本进行实验, 在缺少海量实验数据的情况下, 如果使用卷积网络训练可能导致过拟合局面或者训练出来的网络缺乏泛化能力。因此本文把迁移学习^[11-12]的思想应用于卷积神经网络, 使用海量 ImageNet 样本对 CNN 网络进行预运算, 获得有效的参数值, 然后运用在肺部肿瘤数据集上进行调整学习。如式 (6) 和 (7) 所示, 其中 S_p 是预训练样本区间, S_t 是目标样本区间。

$$S_p = \{(a_1, b_1), \dots, (a_m, b_m)\} \quad (6)$$

$$S_t = \{(a'_1, b'_1), \dots, (a'_m, b'_m)\} \quad (7)$$

迁移学习可行性是因为 CNN 通过多层结构完成提取特征的任务, 从预训练样本区间提取到对目标样本训练有帮助的参数值, 避免参数的频繁变化, 这样网络在训练时就更加迅速, 有效解决过度拟合局面, 提高图像分类性能。

1.4 批量归一化 (BN)

卷积神经网络的运算是一个极其繁琐的过程, 数据在训练过程会发生转换, 下层输入参数会随着上层网络参数的改变进行变化, 这种频繁的改变会导致神经网络出现收敛速率过慢, 或者梯度消失等无法训练的情况。因此本文在网络中引入批量归一化层来解决上述问题。具体算法如下:

算法 1: 批处理

输入: $a: \beta = (a_1, \dots, a_m)$

输出: 规范后的网络响应 $\{b_i = BN_{\gamma, \beta}(a_i)\}$

$$1. \mu_\beta = \frac{1}{n} \sum_{i=1}^n a_i // \text{计算批处理数据均值}$$

$$2. \sigma_\beta^2 = \frac{1}{n} \sum_{i=1}^n (a_i - \mu_\beta)^2 // \text{计算批处理数据方差}$$

$$3. \hat{a}_i = \frac{a_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + l}} // \text{正规化}$$

$$4. b_i = \gamma \hat{a}_i + \beta = BN_{\gamma, \beta}(a_i) // \text{尺度变换和偏移}$$

5. Return 学习的参数 γ 和 β 。

2 网络模型设计

2.1 基于深度学习的特征提取模型

本文模型如图 2 所示，在每个卷积层和神经元激活函数之间引入批量归一化层，对输入数据首先进行预归一化处理，代替原网络中的局部归一化操作，并采用 ReLU 作为激活函数，通过三层全连接层和 Softmax 分类器实现肺部肿瘤图像的分类。

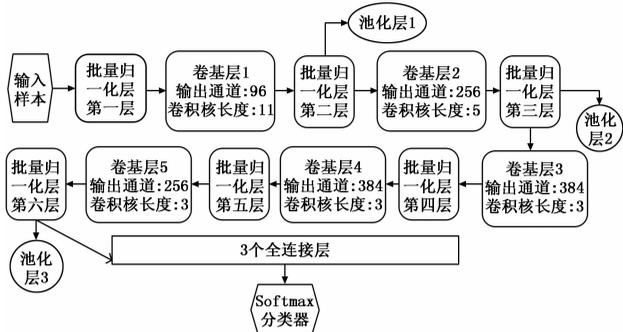


图 2 网络结构图

在整个网络训练之前，首先利用 ImageNet 数据集进行预训练，代替了零基础训练网络的传统方法，本文网络训练的权重、偏置的默认值使用预运算好的参数，损失函数变化速率设置为 0.01，将经过 5000 次迭代后预运算好的网络迁移到肺部图像上进行某种程度的调整学习。

2.1.1 改进后的网络模型

卷积层 1+池化层 1。使用大小为 $11 \times 11 \times 96$ ，间距为 4 的过滤器滤波操作，输出 $55 \times 55 \times 96$ 的特征 map，然后采用下采样尺度为 3×3 ，间距为 2 的下采样算法进行降维操作，输出 $27 \times 27 \times 96$ 的特征 map。

卷积层 2+池化层 2。使用大小为 $5 \times 5 \times 256$ ，间距为 1 的过滤器滤波操作，输出 $27 \times 27 \times 256$ 的特征 map，然后采用下采样尺度为 3×3 ，间距为 2 的下采样算法进行降维操作，输出 $13 \times 13 \times 256$ 的特征 map。

卷积层 3+卷积层 4。使用大小为 $3 \times 3 \times 384$ ，间距为 1 的过滤器滤波操作，输出 $13 \times 13 \times 384$ 的特征 map，这两层卷积层后不接池化层。

卷积层 5+池化层 3。使用大小为 $3 \times 3 \times 256$ ，间距为 1 的过滤器滤波操作，输出 $13 \times 13 \times 256$ 的特征 map，然后采用下采样尺度为 3×3 ，间距为 2 的下采样算法进行降维操作，输出 $6 \times 6 \times 256$ 的特征 map。

2.1.2 最大池化操作

池化操作不仅具有减少特征维度、参数数量的作用，还能够保持特征不变性。有两种池化操作：均值池化 (mean-pooling)、最大值池化 (max-pooling)，本文采用的是 max-pooling，对领域特征点取最大值，来减弱卷积层权重的差错对均值的影响，对在保持低参数计算量的情况下，到达保留更多纹理信息的目的。

2.2 肺部图像的自动分类

对肺部图像的分类任务是通过全连接层和分类器完成

的，如图 3 所示，全连接层的开始为第五层卷积层的聚合特征，通过 3 层的全连接作用获得 1000 维的 Softmax 输出，本文在全连接层中加入 Dropout 使某些神经元停止工作，使网络学习更具表达性的特征，以减少过拟合局面，达到正则化效果。同时使用 ReLU 避免梯度消失局面。

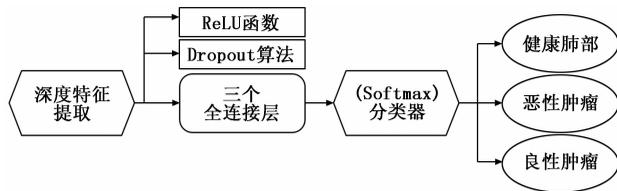


图 3 分类器模型图

3 实验结果分析

3.1 实验环境

本文采用 Caffe 平台。模型是在 Intel i7-9000K CPU, NVIDIA GeForce RTX 2070 上进行学习完成的。前期数据的处理用 Matlab 完成。

3.2 数据集

3.2.1 数据来源

本文实验使用肺结节数据集 LIDC, LIDC 整合了医学界专家的对肺结节病例的诊断信息。每个病例都包含 50~250 张肺部 CT 图像和一个注释文件，专家标注的诊断信息权威且详细。严格按照专业医师注明选取肺部 CT 样本 4000 例，健康 CT 样本占 20%，良恶性肿瘤样本占 80%。

3.2.2 数据处理

在卷积神经网络中需要保证特征输出图大小是一致的，需要将肺部图像进行归一化预处理操作，压缩为 227×227 ，将样本进行排序并按照一定的数量将肺部 CT 图像划分为训练样本和测试样本。其中训练样本占 70% 例，测试样本占 30% 例。

3.2.3 样本扩充

为了解决数据量不足对网络运算导致的过拟合局面，本文对 LIDC 样本集作出以下处理：将肺部肿瘤图像水平、垂直翻转、转动 $135^\circ/270^\circ$ 、缩放比例、加入高斯噪声、裁剪、移位等操作，将已有的训练样本集转化为新的样本集，以达到快速扩充样本集的目的，减少高频特征对网络的影响，提升网络模型的学习能力。

3.3 评价标准

本文使用准确率 ACC、敏感性 SNR、特异度 SPR、AUC 面积和训练时间来判定该分类系统的性能。

真阳性率 TPR 为准确筛选良恶性数据的百分比，真阴性率 TNR 为准确筛选健康数据的百分比，假阳性率 FPR 为错误筛选良恶性数据的百分比，假阴性率 FNR 为错误筛选健康数据的百分比。则 SPR、SNR、ACC 的公式如下：

$$SPR = \frac{TNR}{TNR + FPR} \quad (8)$$

$$SNR = \frac{TPR}{TPR + FNR} \quad (9)$$

$$ACC = \frac{TPR + TNR}{TPR + TNR + FPR + FNR} \quad (10)$$

3.4 实验结果分析

首先实验选择在同一数据集不同训练模型上进行比较, 将本文所提方法与 LeNet-5^[13], ResNet^[14], AlexNet^[15], VGGNet^[16], GooLeNet^[17]5 种模型进行对照, 表 1 展现了卷积神经网络在 6 种方法上的训练时间和测试准确率, 通过实验可以看出, 本文所设计网络和方法获取了更有效和表达性的肺部图像特征, 比其他 5 种模型实现了更好的分类准确度。在训练时间方面, 本文所提方法的训练时间明显低于其他 5 种方法, 网络具有更好的分类性能。

表 1 模型训练时间与准确率

网络结构	准确率/%	训练时间
LeNet-5	63.81	40 m 41 s
ResNet	88.67	56 m 43 s
AlexNet	89.77	45 m 56 s
VGGNet	85.13	50 m 20 s
GooLeNet	77.61	43 m 45 s
本文方法	95.43	21 m 52 s

本文用相同的肺部图像数据集对 AlexNet 模型和改进的网络模型进行训练, 验证批量归一化层的使用对模型稳定性和模型训练速率的作用。通过图 3 可以得出改进模型的准确率的上升速率和训练损失值下降速率都比 AlexNet 模型的快很多, 而且网络训练过程快速平稳。说明批量归一化层不仅可以避免梯度消失, 维持网络平稳性, 加速网络训练速率和学习能力。

本文采用以下方法进行网络运算来观察迁移学习对模型性能的作用:

- 1) 利用肺部样本对改进的模型使用零基础的运算方法;
- 2) 利用 ImageNet 样本对改进的模型实行初始运算, 用已经训练好的参数作为模型训练的输入值。

如表 2 所示, 利用迁移学习的方法模型各方面的性能都更优, 在面对小规模数据集训练时用较短时间提取到了更有效的信息, 有益于网络在肺部图像小样本判断中达到准确的识别分类。

表 2 网络不同运算方法性能比较

运算方法	准确率/%	敏感性/%	特异度/%	AUC 面积
零基础	92.13	81.64	85.36	0.8755
迁移学习	95.43	86.53	91.78	0.9476

本文对 AlexNet 模型和改进的模型分别采用原始样本和样本扩充的方法进行运算来观察样本扩充方式对网络性能的作用。如表 3 所示, 采用样本扩充的运算方法, 网络获得了更好的学习能力, 说明了样本扩充很好地减少了数据不平衡过少难题, 验证了样本扩充的功能性。

4 结束语

本文基于肺部肿瘤图像分类对深度卷积神经网络模型

表 3 网络不同运算方法性能比较

训练方法	准确率/%
AlexNet+原始样本	89.77
AlexNet+数据扩充	90.69
改进模型+原始样本	92.74
改进模型+样本扩充	94.19

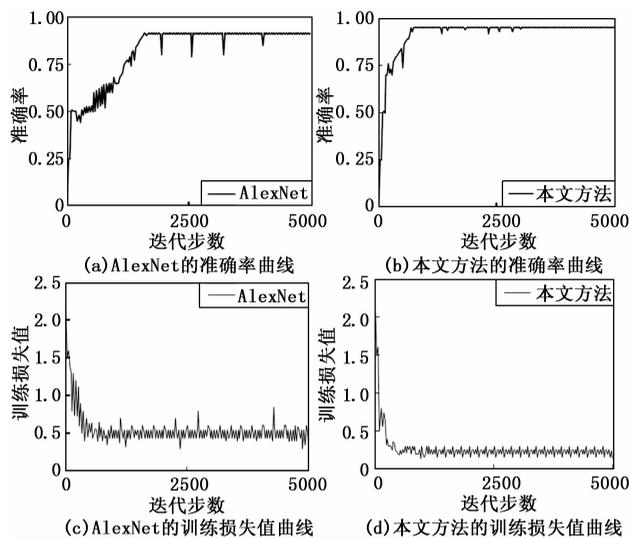


图 3 本文方法和 AlexNet 的测试准确率和损失值

优化改进, 在利用迁移学习和样本扩充基础上, 并在网络每层数据输入前预先归一化处理, 防止传统特征提取和分类的限制性, 减少了高频特征对网络模型的影响, 而且有效减少了网络在数据缺乏时导致的过拟合局面, 使卷积神经网络运用非常有限的医学样本, 提升了肺部肿瘤模型分类准确率和效率, 且网络健壮性得到了提升, 为医生判断提供良好的协助作用。在今后的研究中, 对网络内部构造和网络学习能力往深层次扩展, 进一步提升模型分类精度, 并运用于大规模医学图像的分类。

参考文献:

- [1] Han F, Wang H, Zhang G, et al. Texture feature analysis for computer-aided diagnosis on pulmonary nodules [J]. Journal of Digital Imaging, 2015, 28 (1): 99-115.
- [2] 马中启, 朱好生, 杨海仕, 等. 基于多特征融合密集残差 CNN 的人脸表情识别 [J]. 计算机应用与软件, 2019, 36 (7): 197-201.
- [3] 张 烁, 张 荣. 基于卷积神经网络模型的手写数字辨识算法研究 [J]. 计算机应用与软件, 2019, 36 (8): 172-176.
- [4] 张 顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用 [J]. 计算机学报, 2019, 42 (3): 453-482.
- [5] 田娟秀, 刘国才, 谷珊珊, 等. 医学图像分析深度学习方法与挑战 [J]. 自动化学报, 2018, 44 (3): 401-424.
- [6] Cheng J Z, Ni D, Chou Y H, et al. Computer-aided diagnosis with deep learning architecture: applications to breast Le-

sions in US images and pulmonary nodules in CT scans [J]. Scientific Reports, 2016, 6: 24454.

[7] Setio A A A, Ciompif, Litjens G, et al. Pulmonary nodule detection in CT images: false positive reduction using multi-view convolutional networks [J]. IEEE Transactions on Medical Imaging, 2016, 35 (5): 1160 - 1169.

[8] 白 琮, 黄 玲, 陈佳楠, 等. 面向大规模图像分类的深度卷积神经网络优化 [J]. 软件学报, 2018, 29 (4): 1029 - 1038.

[9] Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [J]. Biological Cybernetics, 1980, 36 (4): 193 - 202.

[10] Shen D G, Wu G R, Suk H I. Deep learning in medical image analysis [J]. Annual Review of Biomedical Engineering, 2017, 19: 221 - 248.

[11] Pan S J, Yang Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22 (10): 1345 - 1359.

[12] Bengio Y, Courville A, Vincent P. Representation learning: a review and new perspectives [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35 (8):

1798 - 1828.

[13] Le Cun Y, Jackel L, Bottou L, et al. Comparison of learning algorithms for handwritten digit recognition [A]. Proceedings of the International Conference on Artificial Neural Networks [C]. Paris, France, 1995, 60: 53 - 60.

[14] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Las Vegas, USA, 2016: 770 - 778.

[15] Krizhevsky A, Sutskever I, Hinton G E. Image Net classification with deep convolutional neural networks [A]. Proceedings of the 25th International Conference on Neural Information Processing Systems [C]. Lake Tahoe, USA, 2012: 1097 - 1105.

[16] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [A]. International Conference on Learning Representations (ICLR) [C]. Banff, Canada, 2015: 168 - 175.

[17] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [A]. 2015 IEEE Conference on computer GGGVision and Pattern Recognition [C]. Boston, USA, 2015: 1 - 9.

不同速度下航天器识别能力的影响对比表

传统本文	汽车	人	房屋	飞机
速度/(km/h)	803.5	0	250	
清晰度/像素	300/250	500/400	600/550	250/200
精准度/m	10/13	1/2	0.5/1.6	30/50

[5] 韩 萍, 宋厅华. 区域筛选与多级特征判别相结合的 PolSAR 图像飞机目标检测 [J]. 中国图象图形学报, 2019, 24 (7): 1197 - 1206.

[6] 董振辉, 王向晖, 穆 强, 等. 高分三号卫星中央单元多分区引导的设计与验证 [J]. 航天器工程, 2017, 26 (6): 126 - 131.

[7] 张阿龙, 江刚武, 张 一. 一种基于改进模糊聚类算法的遥感影像变化检测 [J]. 测绘科学技术学报, 2018, 35 (1): 55 - 59.

[8] 王彦华, 陈 维, 王军福, 等. 基于级联 CFAR 的 SAR 图像目标快速检测方法 [J]. 现代雷达, 2019, 41 (2): 21 - 25.

[9] 马广富, 朱庆华, 王鹏宇, 等. 基于终端滑模的航天器自适应预设性能姿态跟踪控制 [J]. 航空学报, 2018, 39 (6): 136 - 146.

[10] 王海涛, 程文科. 考虑尾流影响的降落伞弹射拉直过程研究 [J]. 航天返回与遥感, 2017, 38 (5): 3 - 9.

[11] 曹喜滨, 吴 凡, 王 峰. 一种使用磁力矩器管理双自旋航天器角动量的方法 [J]. 宇航学报, 2019, 40 (3): 327 - 333.

[12] 于志成, 庄树峰, 刘 涛, 等. 面向航天应用的高可靠性 FP-GA 动态局部重构 [J]. 航天返回与遥感, 2019, 40 (3): 40 - 46.

[13] 曹 倩, 石 峰, 王 宇, 等. 空间高精度太阳跟踪器设计与实现 [J]. 航天返回与遥感, 2018, 39 (3): 70 - 79.

[14] 张敬一, 刘志佳, 张 锐, 等. 一种光学遥感小卫星数传基带测试系统设计改进 [J]. 航天器工程, 2018, 27 (3): 127 - 134.

[15] 周剑敏, 魏 懿, 曹永梅, 等. 高分三号卫星控制分系统设计与在轨验证 [J]. 航天器工程, 2017, 26 (6): 93 - 98.

[16] 张传强, 孟恒辉, 耿利寅, 等. 星载平板有源 SAR 天线热设计与验证 [J]. 航天器工程, 2017, 26 (6): 99 - 105.

表 1 不同速度下航天器识别能力的影响对比表

根据表 1 中的数据可知, 速度的大小对传统方法下航天器的影响较大, 而对本文方法下的航天器识别能力影响较小, 在清晰度方面两种方法相差 20% 左右, 在精准度方面相差 5% ~ 50% 不等。

4 结束语

利用区域分割遥感图像航天器对目标进行自动识别, 实现对部分地区的实时观测以及情报收集等功能, 而高分辨率的遥感图像为航天器的目标识别制造了一定的困难, 因此本文针对环境复杂化以及图像模糊提出多种解决方法, 使航天器的目标自动识别工作更加的稳定。

参考文献:

[1] 刘丽霞, 李宝文, 王阳萍, 等. 改进 Canny 边缘检测的遥感影像分割 [J]. 计算机工程与应用, 2019, 55 (12): 54 - 58.

[2] 孙越娇, 雷武虎, 胡以华, 等. 基于视觉显著模型的遥感图像舰船快速检测 [J]. 激光技术, 2018, 42 (3): 379 - 384.

[3] 黄新波, 张慧莹, 张 焯, 等. 基于改进色差法的复合绝缘子图像分割技术 [J]. 高电压技术, 2018, 44 (8): 2493 - 2500.

[4] 任 佳, 张胜男, 董 超, 等. 基于改进模糊 C 均值的海面目标图像分割算法 [J]. 计算机工程与科学, 2019, 41 (5): 858 - 864.