

# 控制与决策

Control and Decision

## 基于卷积神经网络的云雾遮挡舰船目标识别

刘坤, 于晟焘

引用本文:

刘坤, 于晟焘. 基于卷积神经网络的云雾遮挡舰船目标识别[J]. *控制与决策*, 2021, 36(3): 661–668.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.0781>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning

*控制与决策*. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

### 抗遮挡与尺度自适应的改进KCF跟踪算法

Improved KCF tracking algorithm based on anti-occlusion and scale transformation

*控制与决策*. 2021, 36(2): 457–462 <https://doi.org/10.13195/j.kzyjc.2019.0394>

### 尺度自适应的多特征融合相关滤波目标跟踪算法

Scale adaptation and multi-feature fusion correlation filtering object tracking algorithm

*控制与决策*. 2021, 36(2): 429–435 <https://doi.org/10.13195/j.kzyjc.2019.0445>

### 复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

*控制与决策*. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

### 改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

*控制与决策*. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

# 基于卷积神经网络的云雾遮挡舰船目标识别

刘坤<sup>†</sup>, 于晟焘

(上海海事大学 信息工程学院, 上海 201306)

**摘要:** 海上舰船目标识别对于海运交通、海上目标跟踪、军事侦察等都有着重要作用,然而海面气象复杂、光照不均、云雾遮挡等自然现象易导致遥感图像中舰船目标识别率低、鲁棒性差等问题. 针对云雾遮挡问题,提出一种改进 InceptionV3 网络模型 InceptionV3-FC 的舰船目标识别算法. 首先, InceptionV3-FC 通过引入一层全连接层用来学习新的目标函数,用该目标函数对清晰样本和遮挡样本进行训练;其次,通过目标函数的约束项对清晰样本以及遮挡样本的特征进行约束,进而使得训练的遮挡样本和清晰样本的特征映射彼此接近,共享它们的特征,提高被遮挡舰船目标识别的鲁棒性. 由光学遥感图像数据集的实验可知,相比于改进前的网络,将被云雾遮挡达到 30%、50%、70% 的舰船目标平均识别率分别提高 3.23%、4.44%、15.67%. 实验结果表明,该网络模型能有效改善舰船被云雾遮挡后特征丢失而导致的识别率低的问题.

**关键词:** 遥感图像; 深度学习; 卷积神经网络; 目标识别; 特征提取; 云雾遮挡

中图分类号: TP751

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.0781

开放科学(资源服务)标识码(OSID):



引用格式: 刘坤,于晟焘. 基于卷积神经网络的云雾遮挡舰船目标识别[J]. 控制与决策, 2021, 36(3): 661-668.

## Obscured ship target recognition based on convolutional neural network

LIU Kun<sup>†</sup>, YU Sheng-tao

(College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China)

**Abstract:** The technology of target recognition plays an important role in maritime traffic, maritime target tracking and military reconnaissance, etc. The complex ocean ambient results in the information of ship targets is incomplete, so the cloud obscured ship target will have low recognition rate and poor robustness. Therefore, this paper proposes a obscured ship target recognition algorithm based on the convolutional neural network. First, the improved InceptionV3 network is used to learn a new objective function, which is used to train the clear samples and occluded samples. Then in order to share the features of obscured samples and the clear samples, a constraint function is added to the loss function. Finally, experiments are performed on the optical remote sensing image dataset. The proposed method can improve the average recognition rates of the obscured ship target by 3.23%, 4.44%, and 15.67% than the unimproved network which are obscured 30%, 50%, 70% respectively. The experimental results show that the network model can effectively improve the low ship target recognition rate caused by cloud obscured.

**Keywords:** remote sensing image; deep learning; convolution neural network; target recognition; feature extraction; cloud occlusion

## 0 引言

舰船目标识别技术在民用和军事等领域都有着广泛的应用前景. 舰船目标识别已成为海运交通、海上搜寻、海上目标跟踪、军事侦察等方面的热点研究问题. 越来越多的学者开展了相关研究,例如:从潜在的船舶目标中提取多个高维局部特征并且通过使用支持向量机(support vector machine, SVM)进行船只识别的方法<sup>[1]</sup>、基于分层显著区域的算法<sup>[2]</sup>、

集合局部二进制模式(local binary patterns, LBP)特征的海陆分割与SVM分类器共同训练的舰船识别方法、利用小波不变矩和支持向量机对船只进行识别或者不变伪线矩的目标识别算法<sup>[3-5]</sup>. 舰船目标在传统模式识别方法中,通常提取舰船图像的结构形状,如船只主要结构的位置、船只长度、面积等特征,以及利用矩不变性等方法将空间矩作为特征表征图;或者为了不丢失图像的特征细节,将全部像

收稿日期: 2019-06-03; 修回日期: 2019-09-12.

基金项目: 国家自然科学基金项目(61803257).

责任编辑: 侯忠生.

<sup>†</sup>通讯作者. E-mail: kunliu@shmtu.edu.cn.

素作为特征送入分类器训练.但上述方法中,有的是人工设计,不能保证提取出有效或重要的特征,有的过于繁琐会带来大量的冗余信息.卷积神经网络(convolutional neural network, CNN)在一定程度上解决了上述问题,并且能够自动提取图像更深层的特征,因此,深度学习在目标识别领域得到快速发展并取得了一定的成果.例如应用 AlexNet 网络实现了目标的旋转不变性以及多波段图像识别<sup>[6-8]</sup>.谷歌提出的 GoogLeNet<sup>[9]</sup>获得 ILSVRC 冠军,使 top-5 错误率为 6.7%,并且 GoogLeNet 网络的 Inception 结构经历了 V1、V2、V3、V4 等多个版本的发展,不断地趋于完善, top-5 错误率进一步降低<sup>[9-11]</sup>.文献[12]提出一种基于卷积神经网络与奇异值分解算法相结合的网络模型,能够改善云雾遮挡以及近海船舶的特征提取.文献[13]提出 PCANet 网络模型,通过主成分分析学习多层滤波器核、二进制哈希编码和分块直方图进行下采样和编码,进而对物体进行识别.随着深度学习在目标识别领域的发展以及各种网络模型的提出,对于实际问题的解决带来了更多的选择.

海面气象环境复杂,采集到的图像往往不是理想图像,例如云雾遮挡就是海面环境中常遇到的情况之一,被云雾遮挡的舰船目标会损失一定的特征,进而影响后续舰船目标的识别率,甚至误判.针对这一情况,通常有两种解决方案:一种是通过去云雾算法提高图像质量,再进行训练识别,例如文献[14]通过增大图像的低层细节系数,减小高层细节系数,并适当减小近似系数以达到去除云雾的目的;另一种方案是直接将云雾遮挡的舰船图片送入网络训练,通过目标函数约束特征,从而提高目标识别率.因此,本文提出一种基于改进的 InceptionV3 网络的云雾遮挡舰船目标识别方法.首先,创建特定的舰船数据集,避免有其他因素影响识别率;其次,通过对卷积神经网络原来的 softmax 交叉熵函数添加约束项来对卷积神经网络提取的特征进行约束,使得训练的遮挡样本和清晰样本的特征映射彼此接近且共享它们的特征,从而提高遮挡样本的识别率.实验结果表明,通过改进 Loss 函数对不同遮挡程度的特征进行约束,可使遮挡后的样本特征差异性减小.与多种方法进行实验对比,本文方法的识别率均优于实验的其他算法.因此,本文算法可应用于海上搜寻、军事侦察等领域中舰船目标的识别.

## 1 InceptionV3-FC 网络的基本理论

卷积神经网络的一般模型主要是由卷积层、池化层以及全连接层组成.卷积层和池化层的作用是

对输入的图像进行特征提取以及降维,全连接层一般在若干卷积层和池化层后面,将卷积层的输出作为输入,使用 softmax 激活函数进行图像识别的分类.根据模型的需要,可以调整卷积层、池化层和全连接层数.

卷积神经网络对比于其他神经网络,其局部感知野和权值共享降低了网络的复杂性,使训练参数大大减少,目前已成为热门的深度学习方法之一. InceptionV3 是 GoogLeNet 网络的第 3 个版本,选用 InceptionV3 是因为该网络分解成小的卷积的方法很有效,可以降低参数数量,减少过拟合带来的问题,还可以增加网络的非线性表达能力;空间结构的简化,能够将空间信息转化为高阶抽象的特征信息, Inception module 用多个分支提取不同抽象程度的特征,丰富了网络的表达能力<sup>[15]</sup>.对于本文选择 InceptionV3 模型作为基础模型,而不选择 InceptionV4,将在下文实验结果与验证处详细说明.

在 InceptionV3 网络基础上本文添加了一层全连接层,用于处理清晰特征与遮挡特征之间的差异,所以将本文所使用的网络称为 InceptionV3-FC. InceptionV3-FC 模型由 11 个 Inception 模块组成,共 42 层,而参数仅是 AlexNet 网络的十二分之一,因此,选择 InceptionV3 为基础构建舰船识别的网络模型具有很大的优势.

## 2 基于卷积神经网络的云雾遮挡舰船识别

### 2.1 基于 InceptionV3-FC 卷积神经网络的云雾遮挡舰船识别算法

基于 InceptionV3-FC 网络的舰船识别模型,首先将  $m \times m$  的图片通过 5 个步长为 2 的卷积层或者池化层降低空间尺寸,实现输入数据的尺寸压缩,并对特征抽象化;其次,通过 3 个 Inception module 将空间结构简化,把空间信息转化为高阶的抽象特征信息;然后,通过全局平均池化将高阶抽象特征变成线性特征, linear 层作为 FC 层的输入,通过特征约束送入 softmax 层完成分类预测. FC 层的主要作用是存储云雾遮挡前后的特征以及减少特征位置对分类带来的影响.舰船识别网络模型如图 1 所示.

基于 InceptionV3-FC 的云雾遮挡的舰船目标具体实现过程主要有 3 个步骤:数据建立、网络训练和网络测试.

#### 1) 实验数据建立.

本文对云雾遮挡图像进行识别,因此需要大量具有云雾遮挡的样本图像.由于目前公开的遥感图像舰船类数据集较少,数据集的获取主要通过谷歌卫星地图上的光学遥感图片;对于遮挡的舰船样本,则通

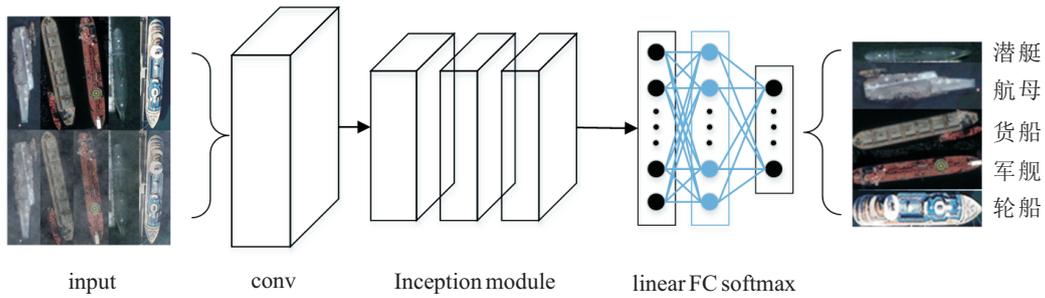


图1 基于InceptionV3-FC的舰船识别简化模型

过使用柏林噪声<sup>[16]</sup>获得模拟云雾遮挡效果的图片并构成训练所使用的数据集. 云雾的遮挡程度主要由权重系数控制, 遮挡程度越大, 表示云层越厚. 光学遥感图像所获取的舰船图像大多是停靠在码头、港口等地方, 陆地上的地物信息会对识别产生严重干扰, 因此, 为了后续的目标识别的稳定、精准、高效<sup>[17]</sup>, 需对舰船图片进行海陆分割, 本文选择改进 Chan-Vese 模型实现海陆分割<sup>[18]</sup>.

为了验证模型是否对不同光照条件下具有鲁棒性, 通过增加不同光照条件增加样本, 减少过拟合. 对于某一样本, 选取光源中心点  $(x_0, y_0)$ , 假设图像的宽高分别为  $w, h$ , 若旋转光源在图像中心, 则有

$$x_0 = \frac{w}{2}, y_0 = \frac{h}{2}. \quad (1)$$

距离光源越近的像素点, 其亮度值越大, 所以

$$f(x, y) = m \left( 1 - \frac{\sqrt{(x - x_0)^2 + (y - y_0)^2}}{r} \right). \quad (2)$$

其中:  $m$  为常数, 设  $m = 0.4$ ;  $r$  为光源作用半径, 设  $r$  的值分别为 200、300、400;  $f(x, y)$  为添加光照模拟后的样本,  $x, y$  为样本的像素点.

对于给定的样本, 定义  $K$  个遮挡尺度  $\varphi = \{\varphi_1, \varphi_2, \dots, \varphi_k\}$  及其遮挡变换  $T_\varphi = \{T_{\varphi_1}, T_{\varphi_2}, \dots, T_{\varphi_k}\}$ , 其中  $T_{\varphi_k}$  表示遮挡程度为  $\varphi_k$  的样本. 对所有训练样本  $X = \{x_1, x_2, \dots, x_N\}$  应用遮挡变换  $T_\varphi$  可以得到一组新的训练样本  $T_\varphi X = \{T_\varphi x_1, T_\varphi x_2, \dots, T_\varphi x_N\}$ , 其中单个遮挡样本为  $T_\varphi x_i = \{T_{\varphi_k} x_i | k = 1, 2, \dots, K\}$ . 清晰样本和遮挡之后的总训练样本, 即  $\chi = \{X, T_\varphi X\}$ , 将共同用于训练 InceptionV3-FC 模型. 对于本文所使用的数据集, 设  $K = 5$ , 则  $\varphi = \{30, 40, 50, 60, 70\}$ . 本文使用的数据集包含 5 类舰船, 包括航母、军舰、轮船、潜艇、货船. 训练集共有 60 000 张, 验证集 6 000 张, 测试集 6 000 张. 为了保障网络输入大小相同, 本实验通过预处理将所有图像大小调整为  $299 \times 299$ , 同时对图像进行零均值归一化处理. 图2是本文数据集中模拟云雾遮挡舰船中航母的部分展示图. 其中: 横向表示云雾不同遮挡程度, 纵向表示不

同光照程度.

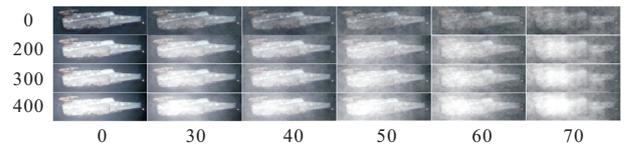


图2 云雾遮挡舰船中航母部分展示图

### 2) InceptionV3-FC 网络训练.

InceptionV3-FC 网络训练流程如图3所示. 首先完成网络参数的初始化设置; 然后假设输入的图片尺寸为  $299 \times 299 \times 3$ , 通过使用 32 个卷积核为  $3 \times 3$ 、步长为 2 的卷积得到  $149 \times 149 \times 32$  的特征图; 再将得到的特征图送入卷积核为  $3 \times 3$ 、步长为 1 的第 2 层卷积, 得到  $147 \times 147 \times 32$  的特征图. 第 3 层卷积与第 2 层区别是该层有填充, 得到  $147 \times 147 \times 32$  的特征图, 随后, 通过池化层得到  $147 \times 147 \times 64$  的特征图; 再使用 32 个卷积核为  $3 \times 3$ 、步长为 2 的卷积得到  $73 \times 73 \times 64$  的特征图; 之后两层卷积分别使用 80 个卷积核为  $3 \times 3$ 、步长为 1 以及 192 个  $3 \times 3$  卷积核步长为 2, 最终得到  $35 \times 35 \times 192$  的特征图. 将得到的特征图作为输入经过 3 个 Inception module 将模块组输出的  $8 \times 8 \times 1280$  特征图作为池化层的输入, 把空间信息转化为高阶的抽象特征信息, 得到  $8 \times 8 \times 2048$  的特征图, 对高阶抽象特征通过全局平均池化, 变成线性的  $1 \times 1 \times 2048$  尺寸. linear 层作为 FC 层的输入, 通过目标函数增加特征约束, 使得遮挡样本接近清晰样本的特征向量, 然后计算目标值与实际输出偏差以及特征误差, 完成网络的前向传播. 判断偏差及特征误差是否在容许的范围内, 通过反向传播更新权值与偏差, 训练结束后固定权值和阈值, 保存网络模型. 该过程通过 Adam 算法<sup>[19]</sup>进行优化.

### 3) InceptionV3-FC 网络测试.

对于训练好的网络模型, 将测试样本作为输入, 得到输出预测值, 通过与样本真实值进行比较, 计算网络的平均识别率.

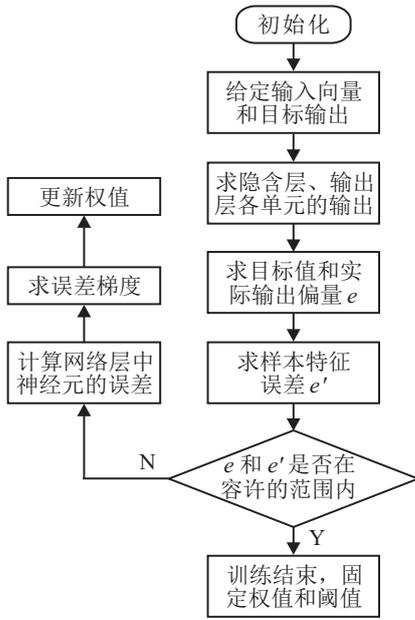


图3 InceptionV3-FC网络训练流程

## 2.2 InceptionV3-FC 特征分析

对于有云雾遮挡的舰船目标识别率下降的原因是被遮挡的舰船目标信息的缺失,当信息缺失达到一定程度时,识别率会迅速下降.若将清晰样本特征与遮挡样本特征之间的误差减小,使两者之间的特征相似,则对于遮挡目标的识别率将会提升.针对这一问题,本文提出特征约束函数用来约束清晰样本特征与遮挡样本特征,同时为了使得模型更加鲁棒,对于遮挡样本的特征,通过将不同遮挡程度的样本特征取其平均值,再求与清晰样本特征之间的误差,通过网络模型的训练,误差逐渐减小,得到最终的网络模型.对于 InceptionV3-FC 模型,除了要尽量减少训练数据集上的错误识别以外,还要求对于任意训练样本  $\{x_i, T_\varphi x_i\}$  都能够识别.为此,提出一个新的目标函数

$$L = L_s + \lambda L_c. \quad (3)$$

其中:  $\lambda$  为目标函数权衡系数;  $L_s$  是 softmax 交叉熵损失函数,为了将损失达到最小化,其表达式为

$$L_s = -\frac{1}{N+NK} \sum_{x_i \in X} \sum_{k=1}^C y_{x_i}[k] \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^C e^{W_j^T x_i + b_{y_j}}} [k]. \quad (4)$$

这里:  $y_{x_i}$  表示样本的真值标签向量,  $N$  是  $X$  中初始训练样本的总数,  $K$  是每个  $x_i \in X$  的遮挡变换总数,  $C$  表示总的类别.

本文选用对数双曲余弦函数作为约束函数,这是因为对数双曲余弦函数是一种比  $L_2$  损失函数更为平滑的损失函数:当样本特征误差很小时,  $\text{logcosh}(x)$  与  $L_2$  损失近似;当误差较大时,  $\text{logcosh}(x)$  与  $\text{abs}(x)$

$\times \log 2$  相似;而  $\text{abs}(x) - \log 2$  与 Huber 函数在  $\delta = 1$  时近似.这意味着对数双曲余弦函数可以在保证损失函数具有连续导数的同时,也可以利用均方误差 (mean square error, MSE) 误差减小的性质,使得清晰样本特征与遮挡样本特征更近似,从而提高网络模型的鲁棒性.对数双曲余弦函数与其他函数的对比如图4所示.

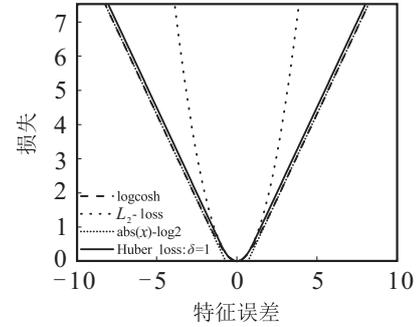


图4 对数双曲余弦函数对比

$L_c$  是目标函数特征变化约束项,主要作用于遮挡前后的训练样本  $X$  和  $T_\varphi X$  上,通过约束项计算清晰样本以及遮挡样本特征误差,再通过优化减小其误差,当误差减小到一定程度时,可以将清晰样本的特征近似成遮挡样本的平均特征,强制使它们共享相似的特征.该约束项  $L_c$  定义为

$$L_c = \frac{1}{N} \sum_{x_i \in X} \text{logcosh}(O_{\text{FC}}(x_i) - \overline{O_{\text{FC}}(T_\varphi x_i)}). \quad (5)$$

这里:  $N$  是  $X$  中初始训练样本的总数;  $O_{\text{FC}}(x_i)$  是 FC 层的输出,也是作为训练样本  $x_i$  的 InceptionV3-FC 特征;  $\overline{O_{\text{FC}}(T_\varphi x_i)}$  表示遮挡的训练样本  $T_\varphi x_i$  的平均 InceptionV3-FC 特征,即

$$\overline{O_{\text{FC}}(T_\varphi x_i)} = \frac{1}{K} (O_{\text{FC}}(T_{\varphi_1} x_i) + O_{\text{FC}}(T_{\varphi_2} x_i) + \dots + O_{\text{FC}}(T_{\varphi_K} x_i)). \quad (6)$$

整理式(3)~(5),得到目标函数

$$L = -\frac{1}{N+NK} \sum_{x_i \in X} \sum_{k=1}^C y_{x_i}[k] \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^C e^{W_j^T x_i + b_{y_j}}} [k] + \frac{\lambda}{N} \sum_{x_i \in X} \text{logcosh}(O_{\text{FC}}(x_i) - \overline{O_{\text{FC}}(T_\varphi x_i)}). \quad (7)$$

为了能够更加清晰地观察 InceptionV3 与 InceptionV3-FC 所提取特征的差异,将 logits 层的 InceptionV3 和 InceptionV3-FC 的特征分别提取出来.为了便于可视化,将提取到的 2048 维特征通过主成分分析 (principal component analysis, PCA) 得到 64 维主特征,并通过直方图的形式表达出来,如图 5(a)

和图5(c)所示. 图5中所选取的航母样本的遮挡程度分别为0、0、30、50、70,光源半径分别为0、300、300、0、0. 随着遮挡程度的加深,InceptionV3网络的直方图的变化比较明显,而InceptionV3-FC网络的直方图几乎没有变化. 为了更细致地分析变换趋势,将遮挡程度分别为30、50、70的样本以及光源半径为300的样本特征与清晰样本特征做差,并将特征差值用折线图的方式表达. 图5(b)为InceptionV3特征差

折线,图5(d)为InceptionV3-FC特征差折线,可以看出InceptionV3网络的特征变化更为明显. 于此同时,通过清晰样本与光源半径为300的样本比较可以看出,InceptionV3网络的特征变化较大,而InceptionV3-FC网络特征变化较小,说明InceptionV3-FC网络模型对光照也有较高的鲁棒. 因此,通过目标函数的约束,将遮挡图像的特征约束到与清晰图像的特征相似,为后续提高识别率以及鲁棒性奠定基础.

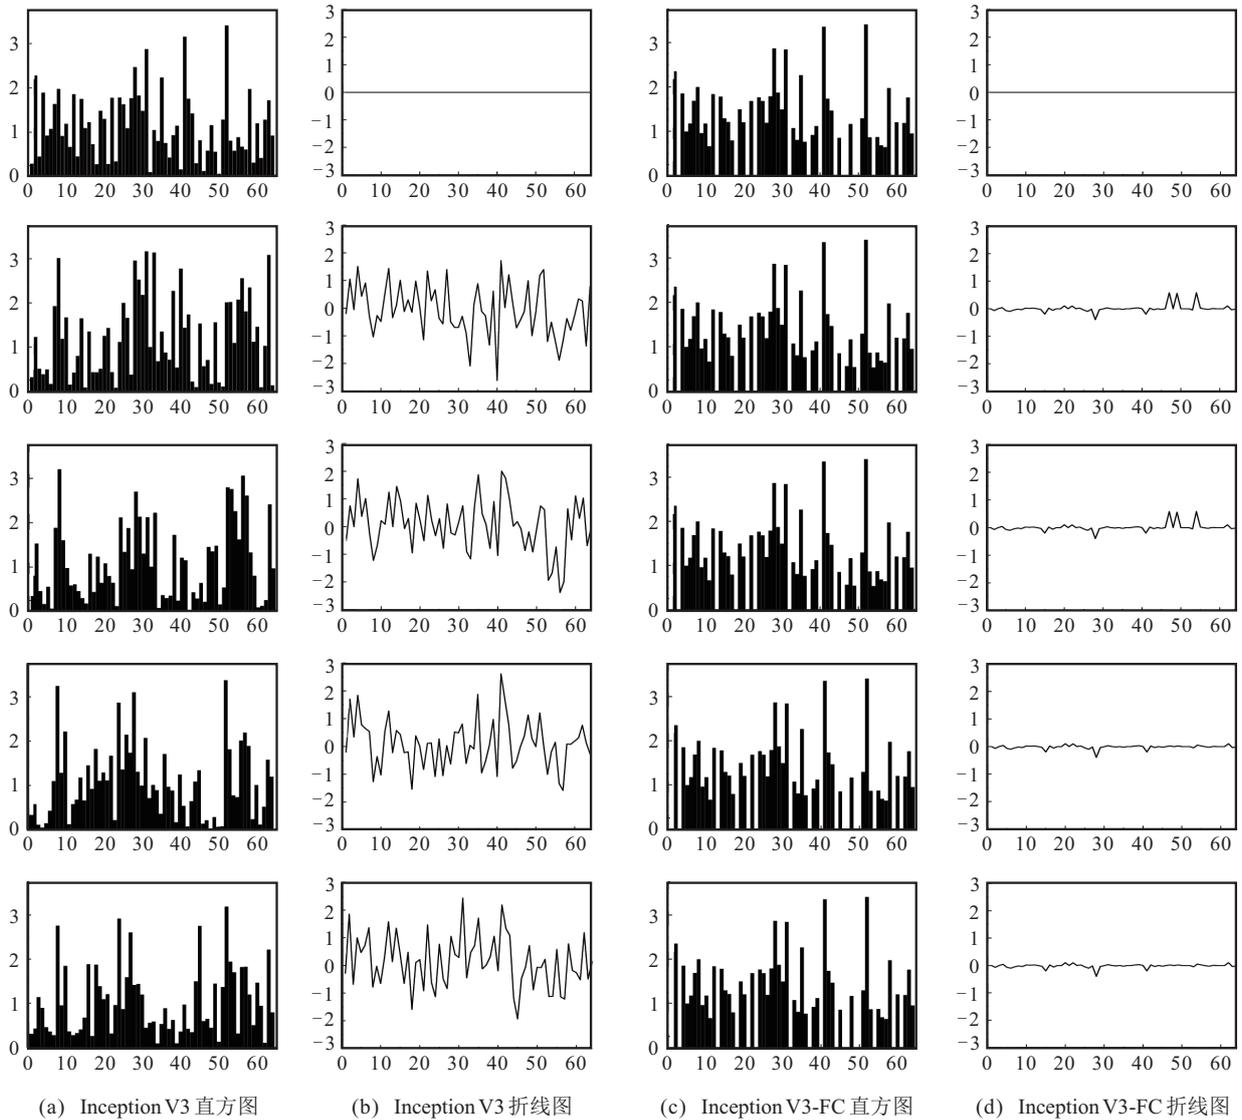


图5 遮挡程度为0、0、30、50、70,光源半径为0、300、300、0、0的航母特征直方图与特征折线图

### 3 实验结果与验证

本文实验环境为: Intel i5-7300HQ(2.5 GHz),显卡GPU为 GeForce GTX1060. InceptionV3-FC网络的学习率为0.001,训练的batchsize为32,参数 $\lambda$ 的取值为 $\lambda = \{0.01, 0.005, 0.001, 0.0005\}$ ,在不同参数 $\lambda$ 下进行识别率的变化测试. 通过实验测试可知,当参数 $\lambda$ 为0.001时,总的平均识别率最高,因此选取参数 $\lambda$ 为0.001,迭代次数为30 000.

本文选择InceptionV3作为基础网络,而不选择InceptionV4的主要原因是:InceptionV3每步约耗时0.316 s,InceptionV4约耗时0.621 s,两者相差0.305 s;训练速度上InceptionV3比InceptionV4快得多. 另外,从图6中可以看出InceptionV4识别率略高于InceptionV3,但是当遮挡程度达到70时,两者基本相似,考虑到时间成本,本文最终选择InceptionV3作为基础网络.

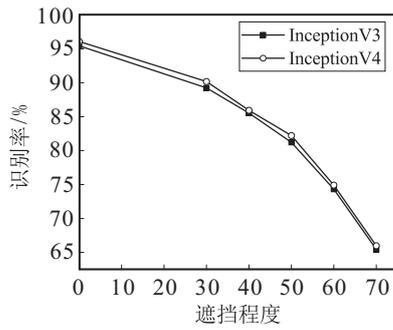
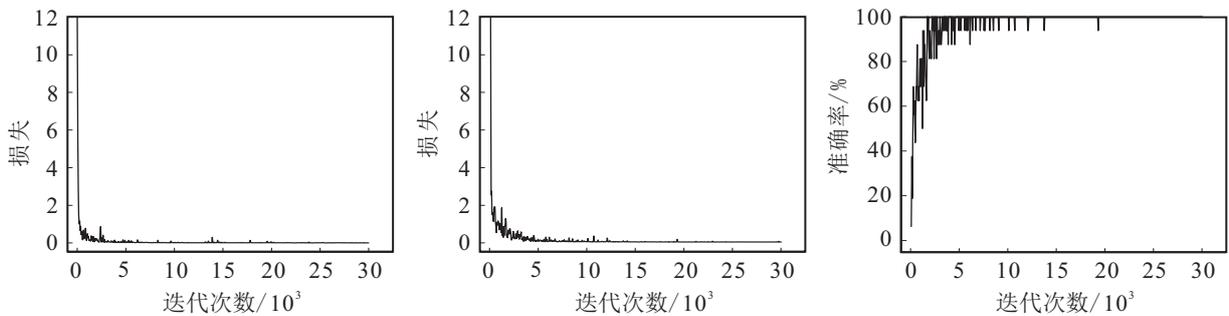


图6 InceptionV3与InceptionV4平均识别率曲线

图7给出了网络的loss曲线以及accuracy曲线. 其中: 图7(a)为InceptionV3-FC网络所有参数进行训练的loss曲线; 图7(b)是加载Google预训练模型, 固定前面层, 仅训练auxlogits、logits以及FC层的loss曲线; 图7(c)为InceptionV3-FC的accuracy曲线. 可以看出, 对于所有参数都参与训练的loss曲线的收敛速度更快, 而仅训练最后几层的loss曲线的收敛速度较

慢. 这说明对于所有层的训练效果要比仅训练末端层的效果好, 但是训练所有层会增加时间成本.

为了测试InceptionV3-FC网络模型的性能, 本文将InceptionV3网络、InceptionV4网络<sup>[11]</sup>、SVDNet网络<sup>[12]</sup>、PCANet网络<sup>[13]</sup>、去云雾算法<sup>[14]</sup>、传统方法<sup>[20]</sup>进行实验对比. 测试数据为遮挡程度分别为0、30、40、50、60、70的图像各600张. 各个网络模型经过训练后, 使用不同遮挡程度的测试集进行测试, 得到表1以及图8各个网络模型的平均识别率. 从表1和图8中曲线可以看出: 随着遮挡程度的加深, 各个算法网络的平均识别率都有所下降, 且当遮挡程度大于50时, InceptionV3网络模型、InceptionV4网络模型与传统方法的平均识别率显著下降; InceptionV3-FC、SVDNet、PCANet对于遮挡样本都有较好的识别率, 但是对比每一个遮挡程度的识别率可以看出, InceptionV3-FC的识别率优于其他网络算法.



(a) 所有参数都参与训练的loss (b) 仅训练auxlogits、logits、FC层参数的loss (c) InceptionV3-FC网络训练的准确率

图7 InceptionV3-FC网络训练的准确率和loss

表1 光源半径为0的各个网络模型的平均识别率

遮挡程度	InceptionV3	InceptionV3-FC	InceptionV4	SVDNet	PCANet	去云雾算法+InceptionV3	SVM+Hog
0	95.44±0.12	96.09±0.14	96.07±0.11	95.60±0.26	95.12±0.11	95.77±0.21	90.47±0.17
30	89.23±0.18	92.46±0.15	90.17±0.21	91.21±0.31	90.32±0.26	91.74±0.13	82.24±0.22
40	85.53±0.21	90.32±0.18	85.93±0.14	87.37±0.22	86.66±0.17	89.00±0.27	78.26±0.15
50	81.22±0.22	85.66±0.23	82.21±0.22	84.16±0.21	83.44±0.15	84.82±0.31	75.57±0.12
60	74.32±0.14	83.62±0.17	74.91±0.21	81.84±0.14	81.58±0.21	82.54±0.11	70.11±0.12
70	65.45±0.17	81.12±0.13	65.98±0.23	79.14±0.11	78.47±0.17	79.88±0.24	58.21±0.24

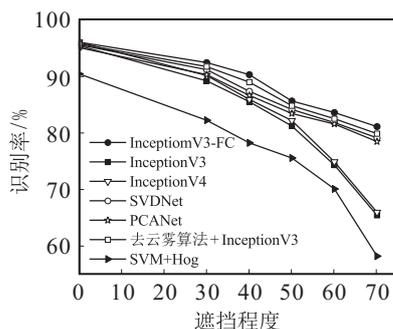


图8 各个算法的平均识别率曲线

为了测试InceptionV3-FC对不同光照的鲁棒性, 选择光源半径为300, 遮挡程度分别为0、30、40、50、60、70的图像各600张. 各个网络模型经过训练后, 使用不同遮挡程度的测试集进行测试, 得到表2. 从表1和表2中可以看出, 光照对所有模型都有影响, 而对于InceptionV3、InceptionV4、PCANet、去云雾算法以及传统方法, 随着遮挡程度的加深, 光照的影响更为明显. 为了更加清晰地表现不同光照对模型的影响, 选择影响较大的InceptionV3以及影响较小的

SVDNet 和 InceptionV3-FC 模型在不同光源半径下的目标识别率进行对比,如图9所示. 从图9(a)和图9(b)中可以看出,随着光源半径的增大,InceptionV3 和 SVDNet 识别率都有所下降. 从图9(c)中可以看出,

随着光源半径的增大,InceptionV3-FC 的识别率未发生明显变化. 因此,InceptionV3-FC 模型对光照具有较好的鲁棒性.

表2 光源半径为300的各个网络模型的平均识别率

%

遮挡程度	InceptionV3	InceptionV3-FC	InceptionV4	SVDNet	PCANet	去云雾算法+InceptionV3	SVM+Hog
0	94.01±0.11	95.91±0.15	94.64±0.11	95.11±0.21	93.69±0.21	94.34±0.12	89.87±0.26
30	88.04±0.18	92.27±0.21	88.98±0.14	90.63±0.15	89.13±0.12	90.55±0.14	81.05±0.31
40	83.79±0.14	89.95±0.13	84.19±0.16	86.73±0.16	84.92±0.25	87.26±0.17	76.52±0.22
50	79.43±0.16	85.41±0.13	80.42±0.21	83.75±0.14	81.65±0.18	83.03±0.23	73.78±0.21
60	73.35±0.21	83.44±0.15	73.94±0.10	81.18±0.13	80.06±0.23	81.57±0.14	69.14±0.14
70	63.47±0.22	80.95±0.18	64.00±0.17	78.71±0.15	76.49±0.22	77.90±0.17	56.23±0.11

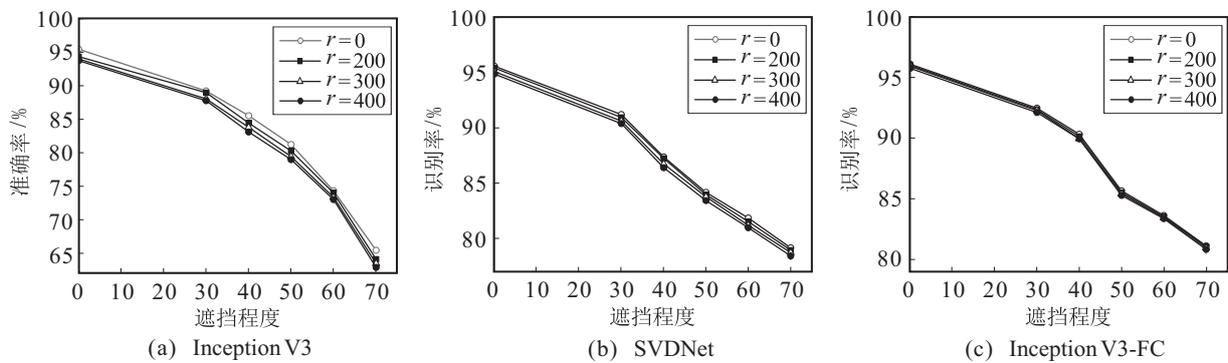


图9 InceptionV3、SVDNet、Inception-FC模型在不同光源半径下的平均识别率曲线

为了验证InceptionV3-FC模型的实时性,计算该网络模型每步迭代的计算时间以及测试识别时间,并与InceptionV3、InceptionV4、SVDNet、PCANet、去云雾算法以及传统方法进行对比,得到各个网络模型的实时计算时间,如表3所示,其中识别时间为各种遮挡程度的平均识别时间. 从表3中可以看出,PCANet网络模型每步计算时间最短,而在各种遮挡程度的平均识别时间中传统方法时间最短.

表3 各个网络模型的实时计算时间 s

model	forward time	recognize time
InceptionV3	0.316±0.005	8.322±0.012
InceptionV3-FC	0.405±0.002	8.432±0.031
InceptionV4	0.621±0.003	9.012±0.018
SVDNet	0.336±0.003	9.126±0.041
PCANet	0.321±0.005	8.303±0.024
去云雾算法+InceptionV3	0.231±0.003	8.573±0.017
SVM+Hog	0.251±0.003	6.465±0.021

#### 4 结论

针对遥感图像中被云雾遮挡的舰船目标识别率低的问题,本文通过改进InceptionV3网络的目标

函数,将被云雾遮挡的图像的特征与清晰图像的特征约束成近似,从而提高了舰船目标的识别率及鲁棒性. 通过与改进前的模型InceptionV3相比:当光源半径为0时,即无光照影响时,被云雾遮挡达到30%、50%、70%的舰船目标平均识别率分别提高了3.23%、4.44%、15.67%;当光源半径为200时,被云雾遮挡达到30%、50%、70%的舰船目标平均识别率分别提高了3.35%、5.28%、16.97%;当光源半径为300时,被云雾遮挡达到30%、50%、70%的舰船目标平均识别率分别提高了4.23%、5.98%、17.48%;当光源半径为400时,即光照最强时,被云雾遮挡达到30%、50%、70%的舰船目标平均识别率分别提高了4.35%、6.30%、17.95%. 可以明显地看出本文所采用的方法优于其他方法,识别率显著提升,改善了云雾遮挡后的舰船识别率快速下降以及识别率低的问题,并且对光照影响具有很好的鲁棒性.

目前,遥感图像的数据愈来愈庞大,如何有效利用这些数据是亟待解决的问题. 该方法以遥感图像为基础,应用深度学习的方法改善舰船遮挡目标识别率,可有效应用于民用和军事等海面监控、检测、海上作业保障等领域.

## 参考文献(References)

- [1] Zhu C R, Zhou H, Wang R S, et al. A novel hierarchical method of ship detection from spaceborne optical image based on shape and texture features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(9): 3446-3456.
- [2] Bi F K, Liu F, Gao L N. A hierarchical salient-region based algorithm for ship detection in remote sensing images[C]. Advances in Neural Network Research and Applications. Heidelberg, 2010: 729-738.
- [3] Xia Y, Wan S H, Jin P Q, et al. A novel sea-land segmentation algorithm based on local binary patterns for ship detection[J]. International Journal of Signal Processing, Image Processing and Pattern Recognition, 2014, 7(3): 237-246.
- [4] 袁爱民. 基于不变矩和支持向量机理论的舰船目标识别[J]. 舰船科学技术, 2017, 39(5X): 171-173.  
(Yuan A M. Based on moment invariants and the theory of support vector machine ship target recognition[J]. Ship Science and Technology, 2017, 39(5X): 171-173.)
- [5] 袁昕, 陈潇君, 陈祖爵. 不变伪线矩算法在运动船只目标识别中的应用[J]. 江苏大学学报: 自然科学版, 2010, 31(1): 82-87.  
(Yuan X, Chen X J, Chen Z J. Application of invariant pseudo-line moment method on target recognition of moving vessels[J]. Journal of Jiangsu University: Natural Science Edition, 2010, 31(1): 82-87.)
- [6] Sutskever I, Hinton G E, Krizhevsky A. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2): 1097-1105.
- [7] Cheng G, Zhou P C, Han J W. Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7405-7415.
- [8] 刘峰, 沈同圣, 马新星. 特征融合的卷积神经网络多波段舰船目标识别[J]. 光学学报, 2017, 37(10): 240-248.  
(Liu F, Shen T S, Ma X X. Convolutional neural network based multi-band ship target recognition with feature Fusion[J]. Acta Optica Sinica, 2017, 37(10): 240-248.)
- [9] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, 2015: 1-9.
- [10] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818-2826.
- [11] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-V4, inception-resnet and the impact of residual connections on learning[C]. The 31st AAAI Conference on Artificial Intelligence. San Francisco, 2017: 4278-4284.
- [12] Zou Z X, Shi Z W. Ship detection in spaceborne optical image with SVD networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 5832-5845.
- [13] Chan T H, Jia K, Gao S H, et al. PCANet: A simple deep learning baseline for image classification?[J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.
- [14] 朱锡芳, 吴峰, 庄燕滨. 基于Mallat算法遥感图像去云雾处理的改进方法[J]. 遥感学报, 2007, 11(2): 241-246.  
(Zhu X F, Wu F, Zhuang Y B. An improved approach to remove cloud and mist from remote sensing digital images based on mallat algorithm[J]. Journal of Remote Sensing, 2007, 11(2): 241-246.)
- [15] 黄文坚, 唐源. Tensorflow 实战[M]. 北京: 电子工业出版社, 2017: 142-143.  
(Huang W J, Tang Y. Tensorflow combat[M]. Beijing: Publishing House of Electronics Industry, 2017: 142-143.)
- [16] Dong W S, Zhang X Y, Zhang C J. Generation of cloud image based on Perlin noise[C]. 2010 International Conference on Multimedia Communications. Hong Kong: IEEE, 2010: 61-63.
- [17] 陈亮, 王志茹, 韩仲, 等. 基于可见光遥感图像的船只目标检测识别方法[J]. 科技导报, 2017, 35(20): 77-85.  
(Chen L, Wang Z R, Han Z, et al. A review of ship detection and recognition based on optical remote sensing image[J]. Science & Technology Review, 2017, 35(20): 77-85.)
- [18] Mao C L, Wan S H. A water/land segmentation algorithm based on an improved chan-veese model with edge constraints of complex wavelet domain[J]. Chinese Journal of Electronics, 2015, 24(2): 361-365.
- [19] Kingma D P, Ba J. Adam: A method for stochastic optimization[J]. 2014, arXiv: 1412.6980.
- [20] Zhang D F, Zhang J S, Yao K M, et al. Infrared ship-target recognition based on SVM classification[J]. Infrared and Laser Engineering, 2016, 45(1): 167-172.

## 作者简介

刘坤(1982-), 女, 副教授, 博士, 从事模式识别与智能系统、图像处理等研究, E-mail: kunliu@shmtu.edu.cn;

于晟焘(1994-), 男, 硕士生, 从事遥感图像处理、目标识别的研究, E-mail: 1095962982@qq.com.

(责任编辑: 李君玲)