

DOI: 10.19650/j.cnki.cjsi.J1905722

基于深度语义分割的遥感图像海面舰船检测研究^{*}

陈彦彤, 李雨阳, 陈伟楠, 张献中, 王俊生

(大连海事大学信息科学技术学院 大连 116026)

摘 要:针对在复杂海况下,遥感图像舰船检测容易受到海杂波、薄云、海岛等影响,导致检测结果可靠性低的问题,引入了端对端的深度语义分割方法,将深度卷积神经网络与全连接条件随机场结合。以 ResNet 架构为基础,首先将遥感图像经过深度卷积神经网络作为输入,对图像进行粗分割,然后经过改进的全连接条件随机场,利用高斯成对势和平均场近似定理建立条件随机场为递归神经网络作为输出,从而实现了端对端的连接。所提方法在 Google Earth 和 NWPU-RESISC45 建立的数据集上与其他模型进行对比,实验表明,所提方法提高了目标检测精度以及捕获图片精细细节的能力,平均交并比为 83.2%,相对于其他模型具有明显优势,且运行速度快,满足遥感图像海面舰船检测的需求。

关键词: 遥感图像;语义分割;卷积神经网络;空洞卷积;全连接条件随机场

中图分类号: TP753 TH766 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Sea surface ship detection based on deep semantic segmentation using remote sensing image

Chen Yantong, Li Yuyang, Chen Weinan, Zhang Xianzhong, Wang Junsheng

(Department of Information Science and Technology, Dalian Maritime University, Dalian 116026, China)

Abstract: Under complex sea conditions, the ship detection using remote sensing image is easily affected by sea clutter, thin clouds and islands, which results in low reliability of detection. In this study, an end-to-end deep semantic segmentation method is proposed, which combines the deep convolution neural network with the fully connected conditional random field. Based on ResNet architecture, the remote sensing image is roughly segmented by deep convolution neural network. Using the method of Gaussian pairwise and mean field approximation, the conditional random field is established as the output of the recurrent neural network. In this way, the end-to-end connection is achieved. On the dataset provided by Google Earth and NWPU-RESISC45, the comparison between the proposed method and other models is implemented. Experimental results show that the proposed method can improve the accuracy of target detection and the ability of capturing fine details of images. The mean intersection over union is 83.2%, which has obvious advantage than other models. And it can also run fast, which meets the requirements of ship detection in remote sensing images.

Keywords: remote sensing image; semantic segmentation; convolution neural network; atrous convolution; fully connected conditional random field

0 引 言

近年来,随着航天遥感技术的飞速发展,利用航天遥感图像^[1-3]进行舰船检测的研究在海洋领域得到了高度重视。我国海洋资源丰富,无论是在军用或民用方面,开展基于遥感图像的舰船检测都至关重要。例如在军事方

面,港口专为军队舰船提供驻泊、修理等保障,加强对港口内舰船目标的检测分类识别具有重要的意义。民用方面,在恶劣的天气状况下,舰船遇险失联事件时有发生,利用航天遥感图像能够快速准确的检测遇难船只的位置,有利于救援工作展开。

传统的遥感图像舰船检测方法有:1)基于显著性视觉的检测方法^[4-5],模拟了人类视觉感知机制,但在检测

港口舰船的同时会检测到其他显著目标。2) 基于边缘信息的检测方法^[6], 结合舰船的形状特征以及舰船边缘信息, 来获取舰船目标候选区域。3) 基于分形模型的检测方法^[7], 根据舰船目标及其他背景是否具有明显的分形特征来完成自动检测工作。但这两种方法在复杂海况下检测效果较差。4) 基于语义分割^[8-9]的分类检测方法, 它是将图像中属于相同类别的像素聚类为一个区域, 可以将舰船与周围背景明确地分开, 与图像分类或目标检测相比, 语义分割对图像有更加细致的了解。用于语义分割的传统分类方法有: 1) 随机决策森林 (random decision forests)^[10-11], 利用多棵树对样本进行训练并预测的一种分类方法。2) 马尔科夫随机场^[12] (Markov random fields), 它是一种无向图模型, 为每个像素分配定义标记的问题。3) 条件随机场^[13-14] (condition random field, CRF), 表示的是给定一组输入随机变量 X 的条件下另一组输出随机变量 Y 的马尔可夫随机场。其中全连接条件随机场 (fully connected condition random field, fully connected CRF) 克服了传统 CRF 漏掉细小结构的缺点。但是这些传统方法的分类效果依然较差。

近年来, 深度学习^[15]已经广泛应用于计算机视觉^[16]领域, 尤其在图像分类方面获得了突破性的成功: Long 等^[17]提出了全卷积网络 (fully convolutional networks, FCN), Xian 等^[18]提出了语义投影网络 (semantic projection network, SPNet), 应用于语义分割中, 它们都取得了较高的准确率。DeepLab 模型^[19-20]是由 Google 团队提出的一种用于语义分割的办法, 利用空洞卷积准确调节分辨率, 扩大感受野, 降低计算量, 并用空洞卷积金字塔池化 (atrous spatial pyramid pooling, ASPP) 模块进行多尺度特征提取, 得到局部和全局特征。最后用全连接条件随机场, 优化边缘效果, 解决了因为传统深度卷积神经网络 (deep convolutional neural network, DCNN)^[21-23]中连续的池化和降采样导致空间分辨率明显下降的问题, 近一步提升分割效果。但是 Deeplab 模型依然存在一些问题, 例如先用深度卷积神经网络进行粗分割, 再利用全连接条件随机场进行细分割, 无法实现端对端的训练, 这样会导致分类精度低, 耗时长; 且复杂海况下舰船检测的精细节较差。

针对以上问题, 本文以 Deeplab 模型为基础, 提出一种新的卷积神经网络形式的复杂海面以及港口舰船语义分割模型, 将 CRF 与深度卷积神经网络^[24]相结合, 利用高斯成对势和平均场近似定理, 建立条件随机场作为递归神经网络 (recurrent neural networks, RNN)^[25], 它作为神经网络的一部分, 获得一个兼具卷积神经网络特性和 CRF 特性的深层端对端网络, 并将其命名为深度语义分割 (deep semantic segmentation, DSS)。在复杂海况下如薄雾、油污等, 以及港口舰船进行检测识别, 近一步提高模型捕获精细细节的能力以及运行时间。

1 Deeplab 模型

Deeplab 模型利用空洞卷积^[20]对特征图做采样, 扩大感受野, 缩小步幅。空洞卷积扩展了标准的卷积网络操作, 其通过调整卷积滤波器的感受野来捕捉多尺度的上下文内容信息, 输出不同分辨率的特征。对于一维卷积结构, 输出特征图 y 的每个位置 i , 卷积滤波器 w , 输入特征图 x , 空洞卷积计算如式 (1) 所示。二维卷积结构原理如图 1 所示。

$$y[i] = \sum_k x[i + r \cdot k]w[k] \tag{1}$$




图 1 空洞卷积原理

Fig.1 The principle of atrous convolution

Deeplab 模型以 ResNet 架构为基础, 将 ResNet 的全连接层转化为卷积层, 最后两个池化层去掉下采样, 后续卷积层的卷积核改为了空洞卷积, 并对 ResNet 的权重进行微调, 这样网络最后输出的特征图分辨率提高, 感受野变大。然后进行多尺度提取, ASPP 模块如图 2 所示, 在给定的输入特征图上以 $r = (6, 12, 18, 24)$ 的 3×3 空洞卷积并行采样, 并使用批量归一化 (batch normalization, BN) 方法加快网络训练速度。ASPP 各个空洞卷积分支采样后结果最后融合到一起, 得到最终预测结果, 实际上就是通过不同的空洞卷积来对图像进行不同程度的缩放, 获得了更好的分割效果。最后使用全连接条件随机场细化图片。




图 2 ASPP 模块原理

Fig.2 The principle of ASPP module

2 复杂海况下遥感图像舰船检测

海洋遥感图像具有复杂多变的特点,图像中小岛、薄云、海杂波等因素都会对目标检测产生影响,特别是当舰船停泊在港口时,Deeplab 模型检测结果会受到周围背景的干扰,导致分割效果不好。本文以 Deeplab 模型为基础,输入的遥感图像经过深层卷积神经网络对其进行粗略分割,然后以改进的全连接条件随机场看作循环神经网络作为输出,再次对图像细分割,实现了深层卷积神经网络与全连接 CRF 端对端的连接,将两个模型的优势结合在一个统一的端对端框架中。

2.1 全连接条件随机场

传统的条件随机场用于平滑噪声,将邻近结点耦合,有利于把相同标记分配给空间上接近的像素。但是现阶段深度卷积神经网络架构,得分图通常非常平滑,目标是要恢复详细的局部结构,在这种情况下,使用传统的条件随机场模型会漏掉细小结构。而全连接条件随机场可以捕获精细细节,从而克服这个缺点。首先将像素标签建模为随机变量,在全局观测条件下形成马尔科夫随机场,设图片为 $\mathbf{I}$, x_i 为像素 i 的标注,从标签 L_i 中取值, $\mathbf{X}$ 为随机变量 $x_1, x_2, \dots, x_N$ 产生的向量, $\mathbf{I}$ 和 $\mathbf{x}$ 的关系可以建模为条件随机场,如式(2)所示。

$$P(\mathbf{X} = \mathbf{x} | \mathbf{I}) = \frac{1}{Z(\mathbf{I})} \exp(-E(\mathbf{x} | \mathbf{I})) \quad (2)$$

由此可定义吉布斯分布如式(3)所示。

$$E(\mathbf{x}) = \sum_i \psi_u(x_i) + \sum_{i < j} \psi_p(x_i, x_j) \quad (3)$$

$$\psi_p(x_i, x_j) = \mu(x_i, x_j) \sum_{m=1}^M w^{(m)} K_G^{(m)}(f_i, f_j) \quad (4)$$

式中: $\sum_i \psi_u(x_i)$ 为衡量像素 i 取标签 x_i 的损失,由深层卷积神经网络获得; $\sum_{i < j} \psi_p(x_i, x_j)$ 为衡量像素 i, j 同时取标签 x_i, x_j 的损失,依赖于图像平滑项,使得相似像素更有可能标注相同标签,具体如式(4)所示; f_i, f_j 为像素 i, j 的特征向量,一般取二维坐标和颜色向量; m 表示高斯核的个数,取 1 或 2。每一个 $K_G^{(m)}$ 为作用于特征向量的高斯核; $w^{(m)}$ 为权重线性组合; $\mu(x_i, x_j)$ 为兼容性函数,即惩罚项。

2.2 条件随机场看作循环神经网络

根据式(3),最小化吉布斯分布 $E(\mathbf{x})$ 就可以得到标注结果,但是过程相对复杂且算法比较耗时,因而本文引入了平均场近似最大后验分布进行推理^[26],其中 $Q(\mathbf{x})$ 为条件随机场 $P(\mathbf{x})$ 的近似,并将其作为 RNN 重构。平均场近似推理迭代算法如下。

算法:平均场定理用于将 CRF 分解为常见的 CNN 操作

$$Q_i(I) \leftarrow \frac{1}{Z_i} \exp(U_i(I)) \text{ for all } i \quad \text{初始化}$$

While not converged do

$$\tilde{Q}^{(m)}(I) \leftarrow \sum_{j \neq i} k^{(m)}(f_i, f_j) Q_j(I) \text{ for all } m \quad \text{消息传递}$$

$$\check{Q}_i(I) \leftarrow \sum_m w^{(m)} \tilde{Q}_i^{(m)}(I) \quad \text{权值调整}$$

$$\hat{Q}_i(I) \leftarrow \sum_{l' \in L} l' \mu(l, l') \check{Q}_i(I) \quad \text{兼容性转换}$$

$$\hat{Q}_i(I) \leftarrow U_i(I) - \hat{Q}_i(I) \quad \text{传递误差微分}$$

$$Q_i \leftarrow \frac{1}{Z_i} \exp(\hat{Q}_i(I)) \quad \text{归一化}$$

end while

1) 初始化过程为初始概率值,其中 U 为卷积神经网络的结果。这个过程相当于在每个像素的所有标签上对一元电位应用一个 softmax 函数,不包含任何参数,可以看作神经网络的 softmax 层。2) 应用高斯滤波器来实现消息传递,即概率转移。就是对 $Q(x)$ 进行高斯模糊,相当于神经网络的卷积运算。3) 权值调整,对于每个类标签 l ,计算出上一步高斯滤波器输出的加权和,可视为 1×1 的卷积层,对多个特征图进行卷积运算。4) 兼容性转换,通过考虑不同标签之间的兼容性并相应的分配惩罚,可以获得更好的结果,即如果将不同的标签分配给具有类似属性的像素,则会受到惩罚,可视为卷积层。5) 用一元势减去兼容性转换步骤的输出,传递误差微分,表示最终概率由卷积神经网络的结果 U 和全局概率转移结果 $\hat{Q}_i(I)$ 共同决定。6) 归一化操作,将步骤 5) 的结果归一化传到下一次循环神经网络迭代作为初始概率,可以看作另一个没有参数的 softmax 操作。

本文在平均场近似推理迭代算法的基础上对步骤 2) 和 3) 进行了改进,原始的高斯核考虑了 x, y 的位置向量和颜色向量,即高斯核为 2,实际上颜色向量在 DCNN 层中决定了分类的先验概率,所以可以不考虑颜色向量的高斯距离,仅考虑位置差异,即高斯核为 1,距离越远差异就越小。并用全图距离权重网络代替传统的高斯核距离,将距离权重置于全图卷积网络中,该网络的权值由训练样本得到,步骤 2) 和 3) 概率转移和权值调整合并变为新的算法,相当于卷积运算,如式(5)所示,其中 a_i 为距离权重, l 为类别, $Q_j(I)$ 为每个点的类别概率。

$$\bar{Q}_i(I) = \sum_{l \in l_j} a_{i,j} Q_j(I) \quad (5)$$

该算法的迭代过程可表示为多个卷积神经网络层,如图 3 所示。 f_0 表示迭代带来的变化。多层平均场迭代可以重复上述过程实现,每一次迭代都来源于之前迭代的结果,这就相当于将迭代平均场视为一个循环神经网络,网络方程如式(6~8)所示, T 为平均场的迭代次数, $H_1(t)$ 初始值为 DCNN 归一化的结果, $H_2(t)$ 为一次 CRF 过程。

$$H_1(t) = \begin{cases} \text{softmax}(U), & t = 0 \\ H_2(t - 1), & 0 < t \leq T \end{cases} \tag{6}$$

$$H_2(t) = \{f_0(U, H_1, I), 0 \leq t \leq T\} \tag{7}$$

$$Y(t) = \begin{cases} 0, & 0 \leq t \leq T \\ H_2(t), & t = T \end{cases} \tag{8}$$




图 3 平均场近似推理算法迭代过程

Fig.3 Iterative process of the mean field approximation reasoning algorithm

通过上述改进,模型整体流程如图 4 所示,深层卷积神经网络作为网络的第一部分,提供了 CRF 一元电位,进入循环卷积神经网络后,需要迭代 t 次才能离开循环,使用反向传播算法和随机梯度下降方法进行端到端的培训,一旦离开循环,softmax 层进行网络的终止。该算法统一了卷积神经网络与 CRF 的优势,形成了端对端的连接。




图 4 DSS 流程

Fig.4 Flowchart of DSS

3 实验结果与分析

实验对复杂海况下遥感图像舰船目标进行检测,并与其他先进方法进行对比,验证本文模型的优越性。本实验使用了 Linux 下的 Caffe 平台,并建立了高质量的舰船遥感图像数据集,其来源于 Google Earth 和 NWPU-RESISC45 数据集中舰船的光学遥感图像,共 5 260 张,图像中背景包括港口、平静海面、小岛、薄云等,其中 1 660 张为离岸舰船图像,3 600 张为近岸舰船图像。然后分别从离岸图像和近岸图像集中随机选择 60% 作为训练集,20% 作为验证集,20% 作为测试集。最后进行了数据增强,即对每张图像旋转 90° 、 180° 、 270° 的随机旋转,最终得到了包含 10 520 张图像的数据集。实验包括舰船语义分割分类的结果、定量分析以及时间对比分析。

3.1 语义分割分类结果

首先实验对比了平静海面下、以及存在海杂波、港口、薄云、小岛情况的海面下,CRF-RNN、Deeplab、SPNet 以及本文所提方法对遥感图像舰船检测分类的结果,如图 5~9 所示。

图 5 所示为简单海面下舰船检测分类的结果,可以




图 5 简单海面下舰船语义分割图

Fig.5 Semantic segmentation of ships under simple sea surface




图 6 海杂波下舰船语义分割图

Fig.6 Semantic segmentation of ships under sea clutter




图 7 港口内舰船语义分割图

Fig.7 Semantic segmentation of ships within a port




图 8 薄云下舰船语义分割图

Fig.8 Semantic segmentation of ship under the thin cloud




图 9 海岛下舰船语义分割图

Fig.9 Semantic segmentation of ships under the island

看出 4 种模型的分类效果都比较好,SPNet 模型的检测结果边缘较模糊,而本文算法捕获目标精细细节能力较强,细化了目标边缘。海杂波下舰船检测分类结果如图 6 所示,CRF-RNN 模型分割结果最差,Deeplab 由于深度学习与全连接条件随机场的结合,捕获了图片的部分细节,但边缘细节模糊。SPNet 的边缘相对较好。本文所提出的方法由于改进了平均场定理,实现了深度卷积神经网络与全连接条件随机场端对端的连接,细化了分割边缘,使分割精度近一步提升。

如图 7 所示,舰船停泊在港口内时,CRF-RNN 模型将一只舰船错误分类成海面背景,Deeplab 模型模型也错误分类了一只舰船。SPNet 模型虽然正确分类了舰船以及港口,但对目标边缘比较模糊。本文模型可以克服了前两种模型的缺点,提升了分割精度。薄云下舰船语义分割图如图 8 所示,4 幅图都克服了薄云的干扰,本文算法捕获了目标边缘精细细节。图 9 所示为小岛下舰船语义分割图,CRF-RNN 模型将舰船与海面背景归为一类,导致了错误分类。SPNet 模型的舰船没有被完整分类,而本文算法正确分类了小岛以及舰船,且边缘细节较好。通过实验分析,本文所提出的算法无论是在简单海面下,还是在存在海杂波、港口内部、薄云以及海岛的情况下,分割效果均优于其他模型且细节处理较好。

3.2 定量分析

平均交并比 (mean intersection-over-union, mIOU) 是语义分割的标准度量。在所建立的数据集上将本文模型与其他先进模型进行 mIOU 对比,如表 1 所示。FCN-8 s 模型的效果最差,mIOU 值为 62.2。而 SPNet 模型的

mIOU 值相对较高,CRF-RNN 为 73.1,Deeplab 仅次于本文提出的模型,达到了 78.3。本文提出的方法与其他先进方法相比效果较好,mIOU 达到 83.2,具有明显优势。

表 1 不同模型 mIOU 对比

Table 1 MIOU Comparison of different models

算法	mIOU
FCN-8s ^[27]	62.2
DeepLab-MSc ^[28]	71.6
CRF-RNN ^[29]	73.1
Deeplab ^[20]	78.3
HDC ^[30]	75.4
SPNet ^[18]	79.7
H-ReNet+DenseCRF ^[31]	76.8
OxfordTVG HO CRF ^[32]	77.9
本文算法	83.2

端对端模型迭代次数对实验的影响如表 2 所示,由表 2 可知,当迭代次数达到 5 以上,mIOU 提高的不是很明显,考虑迭代次数多所占用的时间,所以本文选用迭代次数为 $T=5$ 。

表 2 迭代次数对模型的影响

Table 2 The influence of the number of iterations on the model

Iteration	1	2	3	4	5
mIOU	81.5	82.1	82.5	82.9	83.2
Iteration	6	7	8	9	10
mIOU	83.3	83.4	83.5	83.6	83.7

本文利用了交叉熵损失函数 (cross entropy cost function) 来计算损失, 定义为式(9)。交叉熵表示真实概率分布与预测概率分布之间的差异, epoch 表示训练集中全部样本训练一次, 学习率的初始值为 0.001, 权重衰减为 0.000 5, 动量因子为 0.9。损失函数收敛曲线如图 10 所示。

$$H(p,q)=-\sum_{i=1}^np(x_i)\log(q(x_i))$$

(9)

式中: $p(x_i)$ 表示真实概率分布; $q(x_i)$ 表示预测概率分布。




图 10 损失函数曲线
Fig.10 Loss function curve

3.3 时间分析

表 3 所示为在本文建立的数据集上与其他先进方法的时间对比, 由表 3 可知 Deeplab 模型耗时为 1 s, 是因为没有实现深度卷积神经网络与全连接条件随机场端对端的连接。耗时最短的为 FCN-8 s 模型, 比 Deeplab 模型减少了 0.5 s。而本文所提出的 DSS 模型耗时相对较短, 基本与 FCN-8 s 模型处于一个数量级上且保证了检测精度。

表 3 不同模型耗时分析

Table 3 Time-consuming analysis of different models

算法	运行时间/s
FCN-8 s	0.5
Deeplab	1
DeepLab-MSc	1.2
本文算法	0.75

4 结 论

Deeplab 模型主要以深层卷积神经网络为基础, 空洞卷积代替最大池化层, 并融入了多尺度, 但是与全连接条件随机场未实现端对端连接。本文通过将全连接条件随

机场看作循环神经网络, 获得一个既有卷积神经网络特性又具有 CRF 特性的深层网络, 并实现了端对端的连接, 克服了舰船检测中边缘模糊的问题, 提升了捕获舰船目标精细细节的能力。无论是在简单海面下, 还是在存在海杂波、港口内部、薄云以及海岛的情况下, 均优于其他模型。在建立的 Google Earth 数据集和 NWPU-RESISC45 数据集上的 mIOU 达到了 83.2。未来研究的重点是在保证一定速度的前提下, 如何近一步提升分割的精度问题。

参考文献

[1] 李莎. 遥感图像处理技术在测绘领域中的应用分析[J]. 世界有色金属, 2019, 6(14): 235, 237.
LI SH. Application analysis of remote sensing image processing technology in surveying and mapping [J]. World Nonferrous Metals, 2019, 6(14): 235, 237.

[2] 郭玥, 于希明, 王少军, 等. 遥感图像云检测的多尺度融合分割网络方法[J]. 仪器仪表学报, 2019, 40(6): 31-38.
GUO Y, YU X M, WANG SH J, et al. Cloud detection in remote sensing images with multilevel scale fused network[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 31-38.

[3] 刘尚旺, 侯旺旺, 赵欣莹. 基于 DPMM 和 MRF 的高分辨率遥感图像无监督对象分割[J]. 仪器仪表学报, 2018, 39(11): 222-231.
LIU SH W, HOU W W, ZHAO X Y. Unsupervised object segmentation of high-resolution remote sensing image based on DPMM and MRF[J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 222-231.

[4] 陈彦彤, 李雨阳, 姚婷婷. 复杂海况下遥感图像舰船目标检测方法研究[J]. 激光与光电子学进展, 2019, 56(18): 152-160.
CHEN Y T, LI Y Y, YAO T T. A novel method for ship detection in remote sensing image under complex sea conditions[J]. Laser & Optoelectronics Progress; 2019, 56(18): 152-160.

[5] 赵宏伟, 陈霄, 刘萍萍, 等. 视觉显著目标的自适应分割[J]. 光学精密工程, 2013, 21(2): 531-538.
ZHAO H W, CHEN X, LIU P P, et al. Adaptive segmentation for visual salient object [J]. Optics and Precision Engineering, 2013, 21(2): 531-538.


[6] SHI Z W, YU X R, JIANG Z G, et al. Ship detection in high-resolution optical imagery based on anomaly detector and local shape feature [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52 (8): 4511-4523.

[7] 刘宁波, 丁昊, 田永华, 等. 基于组合分形特征的海杂

- 波中目标检测方法[J]. 航空兵器, 2018, 4(2): 38-42.
- LIU N B, DING H, TIAN Y H, et al. Target detection method in sea clutter based on combined fractal characteristics [J]. Aero Weaponry, 2018, 4(2): 38-42.
- [8] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1520-1528.
- [9] PENG J, ZHANG Z H, HE H. A method for detecting abnormality of CAN bus in vehicle[J]. Instrumentation, 2017, 4(2): 28-33.
- [10] SHOTTON J, JOHNSON M, CIPOLLA R. Semantic texton forests for image categorization and segmentation[C]. International Conference on Computer Vision and Pattern Recognition, 2008: 1-8.
- [11] 熊鹏文, 林虹, 宋爱国, 等. 基于随机森林回归的手臂末端力的软测量方法[J]. 仪器仪表学报, 2017, 38(10): 2400-2406.
- XIONG P W, LIN H, SONG A I G, et al. Soft measurement method of end-of-arm force based on random forest regression [J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2400-2406.
- [12] RANALLI M, LAGONA F, PICONE M, et al. Segmentation of sea current fields by cylindrical hidden Markov models: A composite likelihood approach [J]. Journal of the Royal Statistical Society: Series C (Applied Statistics), 2018, 67(3): 575-598.
- [13] VARMA K I, KRISHNAMOORTHY S, PISIPATI R K. Natural language querying with cascaded conditional random fields: U.S. Patent 9,280,535[P]. 2016-03-08.
- [14] 汪萍. 基于多尺度条件随机场的语义图像分割深度卷积网络[J]. 宿州学院学报, 2019, 34(7): 69-74.
- WANG P. Deep Convolutional network with multi-scale conditional random field for semantic image segmentation[J]. Journal of Suzhou University, 2019, 34(7): 69-74.
- [15] 荣凡稳, 郑伟, 陈冉, 等. 基于深度学习的运动心率测量系统[J]. 电子测量与仪器学报, 2017, 31(12): 1912-1917.
- RONG F W, ZHENG W, CHEN R, et al. Sportive heart rate measuring system based on deep learning [J]. Journal of electronic measurement and instrumentation, 2017, 31(12): 1912-1917.
- [16] 王清晨, 景军锋. 采用机器视觉的金属表面横向裂纹检测[J]. 电子测量与仪器学报, 2018, 32(11): 71-77.
- WANG Q C, JING J F. Horizontal crack detection of metal surface based on machine vision [J]. Journal of electronic measurement and instrumentation, 2018, 32(11): 71-77.
- [17] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [18] XIAN Y, CHOUDHURY S, HE Y, et al. Semantic projection network for zero-and few-label semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 8256-8265.
- [19] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [20] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFS [C]. International Conference on Learning Representations, 2015: 1-14.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [22] SAINATH T N, MOHAMED A, KINGSBURY B, et al. Deep convolutional neural networks for LVCSR[C]. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 2013: 8614-8618.
- [23] 卢来, 邓文, 吴卫祖. 基于改进深度卷积神经网络的步态识别算法[J]. 电子测量与仪器学报, 2019, 33(2): 88-93.
- LU L, DENG W, WU W Z. Gait recognition algorithm based on improved deep convolution neural network [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 88-93.
- [24] 包俊, 叶波, 王晓东, 等. 基于 SSDAE 深度神经网络的钛板电涡流检测图像分类研究[J]. 仪器仪表学报, 2019, 40(4): 238-247.
- BAO J, YE B, WANG X D, et al. Research on eddy current detection image classification of titanium plate based on SSDAE deep neural networks [J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 238-247.
- [25] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks [C]. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 2013: 6645-6649.

- [26] ZHENG S, JAYASUMANA S, ROMERA-PAREDES B, et al. Conditional random fields as recurrent neural networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1529-1537.
- [27] LIN G, SHEN C, REID I, et al. Efficient piecewise of deep structured models for semantic segmentation [C]. International Conference on Computer Vision and Pattern Recognition, 2016: 3194-3203.
- [28] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [J]. Computer Science, 2014(4):357-361.
- [29] CHEN L C, BARRON J T, PAPANDREOU G, et al. Semantic image segmentation with task-specific edge detection using CNNs and a discriminatively trained domain transform [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 4545-4554.
- [30] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation [C]. IEEE Winter Conference on Applications of Computer Vision, 2018: 1451-1460.
- [31] YAN Z, ZHANG H, JIA Y, et al. Combining the best of convolutional layers and recurrent layers: A hybrid network for semantic segmentation [J]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1-17.
- [32] ARNAB A, JAYASUMANA S, ZHENG S, et al. Higher order potentials in end-to-end trainable conditional random fields [J]. Computer Science, 2015: arXiv: 1511.08119.

作者简介



E-mail: chenyantong1@yeah.net

Chen Yantong received his B. Sc. degree from Jilin University in 2012 and received his Ph. D. degree in Changchun Institute of Optics, Fine Mechanics and Physics from Chinese Academy of Sciences in 2017. He is currently a lecturer in the School of Information Science and Technology at Dalian Maritime University. His research interests include remote sensing image processing and target recognition.



E-mail: wangjsh@dlmu.edu.cn

Wang Junsheng (Corresponding author) received his B. Sc. degree and Ph. D. degree both from Harbin Institute of Technology in 2002 and 2007, respectively. He is currently a professor in the School of Information Science and Technology at Dalian Maritime University. Now, he is the academic leader of signal and image processing theory and technology. His research interests include signal processing technology and application, micro fluidics and image processing.

陈彦彤, 2012 年于吉林大学获得学士学位, 2017 年于中国科学院长春光学精密机械与物理研究所获得博士学位, 现为大连海事大学信息科学技术学院讲师, 主要从事遥感图像处理及目标识别方面的研究。

王俊生 (通信作者), 2002 年和 2007 年分别于哈尔滨工业大学获得学士学位和博士学位。现为大连海事大学信息科学技术学院教授, 校内信号与图像处理理论技术学术方向带头人, 主要从事信号处理技术及应用、微流控、图像处理等方面的研究。