

# 基于 AlexNet 的小样本水面漂浮物识别

李 宁<sup>1,2</sup> 王雨萱<sup>1</sup> 徐守坤<sup>1</sup> 石 林<sup>1</sup>

<sup>1</sup>(常州大学 信息科学与工程学院 数理学院 江苏 常州 213164)

<sup>2</sup>(福建省信息处理与智能控制重点实验室(闽江学院) 福建 福州 350108)

**摘 要** 针对水面漂浮物识别中图像数据量少、噪声影响多,导致识别精度低的问题,采用一种基于深度学习的小样本水面漂浮物识别方法进行水面常见污染物塑料袋与塑料瓶的识别。采用现有大型数据集中的普通塑料袋与塑料瓶图像构建并训练卷积神经网络模型 AlexNet;采用梯度下降法对模型进行微调,并用融合的光照矫正法处理待识别图像;将网络识别结果与传统的 HOG 特征提取方法进行比较。实验结果表明,该方法相较于传统的提取特征方法,对于水面漂浮物的识别率提高近 15%。

**关键词** 漂浮物图像 小样本 深度学习 AlexNet 光照矫正

中图分类号 TP391.41 文献标识码 A DOI:10.3969/j.issn.1000-386x.2019.02.044

## RECOGNITION OF FLOATING OBJECTS ON WATER SURFACE WITH SMALL SAMPLE BASED ON ALEXNET

Li Ning<sup>1,2</sup> Wang Yuxuan<sup>1</sup> Xu Shoukun<sup>1</sup> Shi Lin<sup>1</sup>

<sup>1</sup>(School of Information Science and Engineering, School of Mathematics and Physics, Changzhou University, Changzhou 213164, Jiangsu, China)

<sup>2</sup>(Fujian Key Laboratory of Information Processing and Intelligent Control(Minjiang College), Fuzhou 350108, Fujian, China)

**Abstract** In the recognition of floating objects on water surface, the small amount of image data and the influence of noise leads to the low recognition accuracy. In order to solve this problem, we adopted floating objects on water surface recognition method with small sample based on deep learning to identify common pollutants, plastic bags and plastic bottles. The convolution neural network model AlexNet was constructed and trained from the images of plastic bags and bottles in the existing large data sets. The gradient descent method was used to fine-tune the model, and the fusion light correction method was used to process the image to be recognized. The network recognition results were compared with the traditional HOG feature extraction methods. The experimental results show that compared with the traditional feature extraction method, the method improves the recognition rate of floating objects on the water surface by nearly 15%.

**Keywords** Image of floating objects Small sample Deep learning AlexNet Light correction

## 0 引 言

随着经济生活的快速发展,水面漂浮物识别在水体污染监控以及水面智能清理机器人等方面扮演着更为重要的角色。然而,目前国内外对水面漂浮物识别的研究比较少,大部分是采用遥感图像或信号传播等

技术,实现水体或水上目标识别<sup>[1-3]</sup>。由于水面环境的复杂性和特殊性,水面图像具有光照影响大、容易被噪声污染等特点,使得水面图像识别具有了其自身的特殊性。而在传统的目标识别中,常用的解决方案是使用各类特征提取方法结合分类器实现<sup>[1,3]</sup>,虽然这些特征提取方式确实能够在某些特定的数据和任务中得到良好的识别效果。但这些特征在受到大量噪声或

其他因素干扰等情况下,很难被较好地提取,这样就会影响到分类器的实现效果,从而无法很好地分类、识别目标。

近年来,深度学习成为模式识别领域的新热点,它允许由多个处理层组成的模型来学习具有多个抽象层次的数据表示。其概念由 Hinton 等于 2006 年提出,现在被广泛应用于计算机视觉、语音识别以及自然语言处理等其他领域<sup>[4-6]</sup>。自 21 世纪初以来,卷积神经网络(ConvNets)<sup>[7]</sup>已被应用于空中物体的图像识别<sup>[8]</sup>。基于深度学习的水面图像识别研究较少,其中主要原因可能是深度学习在图像分类中的成功,就在于使用了大量的训练数据,而水面漂浮物图像的获取总是需要大量的人力和成本,这使得获取大量的样本图像变得困难。但不可否认的是,深度学习相较于传统的特征提取方式,可以实现更好的分类、识别效果,也是未来图像识别领域的发展方向。

因此,在深度学习的基础上,本文研究了小样本容量下,水面图像中漂浮物识别的解决方案,旨在针对水面污染提出一种更有效的污染物识别策略。更具体地说,在摄像机捕捉到的包含漂浮类污染物的普通水面图像中(主要包括塑料袋与塑料瓶两种常见污染物),尝试找到一个有效的简单框架,来解决水面污染物识别问题。本文提出以现有的 AlexNet 网络<sup>[9]</sup>为基础,利用公开数据集 ImageNet<sup>[10]</sup>以及 COCO<sup>[11]</sup>等收集大量普通塑料袋、塑料瓶图像进行网络预训练,然后利用梯度下降法进行网络微调,最后将训练好的网络用于实际采集到的水面污染物图像识别中。同时,对于待识别的水面图像,采用直方图均衡化与对数变换相结合的方式,对图像进行光照不均匀的矫正,在增强图像整体对比度的同时,提高阴影处的亮度。由于本文目标的纹理特征较为明显,因此在传统特征提取方法中,采用 HOG 特征<sup>[12-13]</sup>提取方法与本文方法进行对比。实验结果表明,网络微调的方法可以有效提高传统网络对小样本水面漂浮物的识别效果,相较于传统的特征提取方式具有更高的识别率。另外,光照矫正有效地均匀了图像亮度,削弱了光照影响。

## 1 深度学习与 AlexNet 网络

### 1.1 深度学习

深度学习的概念由 Hinton 等在 2006 年提出,源于对人工神经网络的研究,包含多隐藏层的多层感知器就是一种深度学习结构。深度学习通过组合低层特征实现更加抽象的高层表示属性类别或特征,以此发现

数据的分布式特征表示。它是机器学习研究中的一个崭新的领域,在于建立、模拟人脑进行分析学习的神经网络,模仿人脑的机制来解释数据,例如图像、声音和文本。

深度学习是基于大量数据训练实现的,一般情况下,训练数据越多,实现效果越好。但是在实际应用中,许多特殊领域的图像采集并不是那么简单,或者采集过程需要耗费大量的人力物力。因此在这些领域中,基于深度学习的研究非常少,通常采用传统的特征提取方式实现目标分类或识别。然而,随着深度学习在机器视觉中逐渐表现出更多的优势,深度学习在这些领域中的应用也是一种趋势。

### 1.2 AlexNet 网络体系结构

AlexNet 是 Alex Krizhevsky 在 2012 年提出的,此后更深的神经网络被提出,例如 vgg, GoogleLeNet 以及 ResNet<sup>[14]</sup>等更为复杂的网络结构。相比传统的卷积神经网络例如 LetNet 来说, AlexNet 增添了数据增强、Dropout 和 Relu 激活函数,在很大程度上提高了传统网络的分类效果,到目前为止也是比较经典且实用的网络之一。而相较于更为复杂的网络结构例如 ResNet, AlexNet 具有更简单短小的网络层次,网络结构如图 1 所示。




图 1 AlexNet 网络结构

网络中包含了 8 个有权重的层,其中前 5 个是卷积层,剩下的 3 个是全连接层,最后一个全连接层的输出给到一个 1 000 维的 softmax,最终给出在 1 000 个类标签上的分布。在这种简单的网络架构下, AlexNet 在一般的分类识别任务中都有良好的表现,且这样的网络结构更适用于小平台搭载,可以满足水面清理任务的分类需求,不需要再采用更加复杂的网络来实现。否则不仅会增加运行的成本,也可能造成大量过拟合。因此本文以 AlexNet 为基础实现对小样本水面图像的漂浮污染物识别。

## 2 图像光照矫正算法

相较于普通图像,水面图像具有更易受光照影响的特点,例如水面反射造成部分区域亮度过高,从而影响识别效果。因此本文采用直方图均衡化与对数变换

相融合的方法,对水面图像进行光照不均匀的矫正,然后将矫正后的图像放入训练好的网络中进行识别,在一定程度上提高了对水面漂浮物的识别率。

常用的图像光照不均匀矫正算法有很多,例如顶(底)帽变换、直方图均衡化、拉普拉斯算子增强、对数变换等。其中,顶(底)帽变换通常用于分割算法中的光照矫正,而直方图均衡化以及对数变换属于光照补偿算法,可以有效提高图像的整体亮度和对比度,更适用于本文提出的神经网络识别方法。

## 2.1 直方图均衡化

直方图均衡化是一种常用的光照补偿方法,目的是将原始图像的直方图转换为均匀分布的形式,以增加像素灰度值的动态范围,从而增强图像的整体对比度。对于一幅大小为  $M \times N$  图像,假设该图像的像素值取值范围为  $\{0, 1, 2, \dots, L-1\}$ , 图像中灰度值  $r$  出现的概率,即为该图像的直方图,计算公式如下:

$$P_r = \frac{n_r}{M \times N} \quad r=0, 1, 2, \dots, L-1 \quad (1)$$

式中:  $M \times N$  为图像中像素的总数,  $n_r$  表示该图像中灰度值为  $r$  的像素点个数。

然后通过变换函数,将原始输入图像中灰度值为  $r$  的像素映射到输出图像中灰度值为  $S$  的对应像素,变换函数的计算公式如下:

$$S_r = \sum_{i=0}^r \frac{n_i}{M \times N} \quad (2)$$

直方图均衡化利用图像直方图对对比度进行调整,提高了图像中阴暗部分的亮度,但在某些光照恶劣的图像中表现不佳,容易出现对比度过于强烈的情况。

## 2.2 对数变换

对数变换也是图像增强的一种常见方法,目的在于将输入图像中较窄的低灰度值映射到输出图像较宽的灰度值,对输入图像中灰度值的对数变换公式如下:

$$G_r = c \times \log(r+1) \quad (3)$$

式中:  $c$  是常数,通常取值为  $c = 255/\log(256)$ , 且底数通常默认为  $e$ , 对数变换公式即为:

$$G_r = c \times \ln(r+1) \quad (4)$$

由于对数曲线在像素值较低的区域斜率较大,在像素值较高的区域斜率较小,因此图像经过对数变换后,较暗区域的对比度将有所提升,以此增强图像的暗部细节,但也存在处理后的图像边缘模糊的问题。

## 2.3 矫正后图像融合

将图像进行直方图均衡化可以有效减弱光照影响,此时图像整体对比度明显增强,整体亮度提高,但在光照恶劣的情况下,其实现效果并不理想。而对数

变换处理后的图像较为柔和,但其缺点在于容易出现边缘不清晰的问题。针对两种算法的优缺点,本文提出将直方图均衡化与对数变换处理后的图像,以加权融合的方式进行合并处理,变换如下:

$$f'(x, y) = m \times S(x, y) + (1 - m) \times G(x, y) \quad (5)$$

式中:  $S(x, y)$  与  $G(x, y)$  分别为直方图均衡化以及对数变换处理后的图像,  $m$  ( $0 \leq m \leq 1$ ) 为比例权值,通过  $m$  调整融合效果。

对于权值  $m$  的选择,采用类似大律法中的最大(小)类间方差法,计算图像的整体灰度方差,取使得灰度方差最小的  $m$  为最终权值选择。首先取权值为  $m$ , 然后对两种方法的处理图像进行加权融合,计算融合后图像的整体平均灰度  $\mu$ , 公式如下:

$$\mu = \sum_{r=0}^{L-1} r \times P_r \quad (6)$$

则图像的整体灰度方差  $g$  的计算公式如下:

$$g = \sum_{r=0}^{L-1} P_r \times (r - \mu)^2 \quad (7)$$

当方差  $g$  最小时,即可认为此时图像的平均差异最小,即最佳权值  $m^*$  的判别式为:

$$m^* = \text{Argmin}(g) \quad 0 \leq m \leq 1 \quad (8)$$

## 3 小样本水面图像识别方法

一个卷积神经网络通常有数百万的连接和权重,尽管可以利用现有的连接和共享的权重,仍有大量的权重需要训练。当将卷积神经网络应用于一个大型数据集时,它们通常会取得很好的效果,然而在实际应用中发现,在小样本容量的情况下,网络对于训练集的精度高,对测试集的效果不佳。对水面图像中的漂浮物识别任务来说,一个实际的问题是如何获得足够的样本图像来训练卷积神经网络。在深度信念网络(DBN)<sup>[14-15]</sup>的训练过程的启发下,本文提出了一种在小样本容量情况下,基于深度学习的水面图像中漂浮污染物识别的解决方案,具体来说是利用一组较少的水面漂浮物图像解决水面污染物的识别分类问题。

### 3.1 小样本学习策略

本文提出在小样本容量的情况下,水面漂浮污染物的识别过程主要分为三个阶段:

1) 第一个阶段是用一个比较大的图像数据集来预训练一个卷积神经网络(CNN)。卷积神经网络不仅是一个分类器,而且是一个特征提取器,网络的隐藏层会以一种便于预测目标输出的方式来表示网络的输入。当一个卷积神经网络的训练阶段完成后,预训练的卷积神经网络将对图像的颜色、纹理和边缘等信息

敏感。同时自然图像具有一定的共性,因此用不同于与我们期望识别的图像预先训练一个卷积神经网络是合理的。ImageNet 数据集为我们提供了这样一个可供选择的大型图像数据集,它有超过 1 500 万的高分辨率图像,这些图像属于大约 22 000 个类别,同时网络爬虫技术也同样可以提供大量高质量图像,这为卷积神经网络的预训练提供了数据支持。

2) 第二阶段是用我们所拥有的小样本图像对预训练的卷积神经网络进行微调。多层次的神经网络可以通过随机梯度下降法进行进一步训练,而图像标签中非常有限的信息将会被用来微调预训练中得到的权重。

3) 最后一个阶段是测试训练好的卷积神经网络的性能。如果卷积网络的精度满足应用要求,则可用于图像识别。

### 3.2 梯度下降法微调网络

微调网络阶段,本文采用随机梯度下降 SGD (Stochastic gradient descent) 法进行参数更新。传统的批量梯度下降,将计算整个数据集梯度,但仅进行一次更新,因此处理速度很慢且容易导致内存溢出。而随机梯度下降算法每次只随机选择一个样本来更新模型参数,因此学习速度很快且可以进行在线更新。

对于包含  $N$  个训练样本的样本集,采用梯度下降法更新网络参数,每层的参数  $w^{(i)}$  和  $b^{(i)}$  的计算公式分别如下:

$$w^{(i)} = w^{(i)} - \rho \times \frac{1}{N} \sum_{i=1}^N x^{(i)} (o^{(i)} - y^{(i)}) \quad (9)$$

$$b^{(i)} = b^{(i)} - \rho \times \frac{1}{N} \sum_{i=1}^N x^{(i)} (o^{(i)} - y^{(i)}) \quad (10)$$

式中: $N$  代表输入的样本容量, $\rho$  为学习率, $o^{(i)}$  表示输入  $x^{(i)}$  对应的实际输出, $y^{(i)}$  代表第  $i$  组数据对应的类别标记, $y^{(i)} \in \{1, 2, \dots, k\}$ ,  $k$  是样本的类别数目。

通过梯度下降法更新网络参数,使得网络的输出层误差函数值达到最小,从而对网络实现微调,使网络适用于小样本容量情况下的目标识别。

## 4 实验与分析

### 4.1 实验数据来源

本文所用的实验数据来源于网络的公开数据集 ImageNet、COCO 数据集以及利用网络爬虫技术从网上得到的实验图像。所收集的图像数据包括普通的塑料袋、塑料瓶图像以及水面漂浮物图像,在网络训练之前先对图像做归一化处理,图像数据类型包括 4 种,如图 2 所示,数据集统计如表 1 所示。



(a) 普通塑料瓶 (b) 普通塑料袋 (c) 水面塑料袋 (d) 水面塑料瓶

图 2 图像数据类型

表 1 图像数据集

分类	训练集	验证集	测试集
塑料袋	6 000	2 100	900
塑料瓶	6 000	2 100	900
水面图像	1 400	700	300

### 4.2 光照矫正实验

在实验中,本文利用 VS 2015 软件进行图像的光照矫正,在 OpenCV 环境中分别采用直方图均衡化与对数变换对输入图像进行处理,并将矫正结果与融合图像进行对比,对比结果如图 3、图 4 所示。图 3、图 4 中的原图均为包含水面漂浮物的图像,图 3 中原图像在光照较好时,受水面反射的影响,包含一部分亮度较高的区域以及一部分亮度较低的区域,而图 4 中原图则由于光照不佳,整体较暗。




图 3 光照矫正 1




图 4 光照矫正 2

从图 3 中可以看出,对于包含部分高亮度区域的图像,融合后的图像对暗部区域进行了亮度提高,同时也保留了高亮度区域的目标细节。相较于对数变换融合后图像的物体轮廓更清晰,而对比直方图均衡化的实现结果,融合图像的暗部区域具有更高的亮度和清晰度。

对整体较暗的图 4,融合后的图像提高了图像的整体亮度,使得图像细节更加清晰。对比直方图均衡化的结果,暗区域细节更加明显,对比对数变换保留了更多边缘信息。

从两种实验图像的对比结果来看,融合图像在均匀图像亮度的同时,也提高了图像对比度,同时相较于两种常用的光照矫正算法,保留了更多的细节信息,实现了更接近于真实图像的光照矫正结果。将融合后的图像放入训练好的网络中进行识别,可以有效去除水面反射造成的光照影响。

### 4.3 网络训练与测试

利用自然信号的特性,卷积网络中有四个关键的概念:局部连接、共享权重、池化和多层网络。本文在实验中采用了经典的 AlexNet 网络,每个卷积层的权值都由一个零均值高斯分布初始化,其标准差是 0.01,网络训练参数见表 2。

表 2 网络训练参数

参数	参数值
学习率(Learning rate)	0.01
动量(Momentum)	0.0
损失函数(Loss function)	SoftmaxWithLoss
性能评估(Metric)	Accuracy
Dropout	0.5

#### 4.3.1 样本量与迭代次数

实验中对网络的训练分为两个阶段,第一个阶段分批量测试,检验训练样本数量对网络识别率的影响,选择最佳样本量。网络采用不同样本量的数据集进行训练,根据已有训练集的数据量取 670 为基数,其中按普通图像:水面图像 = 60:7 的比例,取其 5、10、15、20 倍的样本量分别进行网络训练,不同样本量下的识别率如图 5 所示。




图 5 不同训练样本量的识别率

从实验结果中可以看出,随着样本容量的增加,网络的识别率逐渐上升,并且当样本容量达到 10 050 时已基本趋于平稳,此时网络达到收敛状态。另外,网络在最大样本量情况下识别率略有提高,达到 96.66%,因此之后的对比实验均选择采用已有的样本量进行网络训练,并且对样本量不必要再做增加。

网络训练的第二个阶段,采用第一阶段中的样本容量,并分别采用不同的迭代次数进行网络训练,分别取 Epochs 为 5、10、15、20、25、30,识别结果如图 6 所示。




图 6 不同迭代次数下的识别率

从图中可以看出,随着迭代次数的增加,识别率显著提高,当迭代次数达到 20 个 Epochs (大约 2 000 次迭代)时基本稳定,在 25 个 Epochs 时略有提高,因此在之后的对比实验中选择迭代次数为 25 个 Epochs。

网络训练阶段对应的损失函数的输出值(Loss)和预测值(Accuracy)变化分别如图 7 和图 8 所示。




图 7 网络训练的迭代损失




图 8 网络的训练精度

从图中可以看出,训练损失急剧下降,在第 25 个 Epochs(大约 2 500 次迭代)后趋向于 0。而训练精度在最初的 20 个 Epochs 中,验证集的准确性迅速上升,并且在大约 2 500 次迭代后趋向于平稳。

#### 4.3.2 对比实验

在第一组对比实验中,采用没有微调的传统网络分别对测试集中的普通图像与水面图像进行测试,判断传统方法是否适用于此类小样本水面图像的识别。测试中发现,传统网络对普通图像达到了 98.75% 的识别率,而对水面塑料瓶的识别效果最差仅为 46.67%,统计结果如表 3 所示。

表 3 对不同类别图像的识别率 %

网络类别	普通图像	水面塑料袋	水面塑料瓶
传统网络	98.75	77.50	46.67

分析原因可能是由于普通图像中的塑料瓶均为垂直方向,而水面图像中大部分为水平或倾斜角度,因此接下来分别采用单垂直方向、单水平方向以及两者结合的三种普通塑料瓶数据集重新进行网络预训练。

另外,从统计表 3 中传统网络对水面图像的识别率也可以看出,传统方法的确不太适用于小样本的识别。同时考虑到水面图像可能存在的噪声影响,在测试中对两个方向相结合的实验组,采用中值滤波去噪后的水面图像进行识别测试,对比测试结果判断是否需要对待识别图像进行去噪处理。

第二组对比实验中,采用不同方向的图像训练传统网络并进行对比,同时将滤波处理后的识别结果与未处理的识别结果进行对比,判断是否需要对待识别图像进行去噪处理,统计实验中的测试结果如表 4 所示。

表 4 传统网络识别效果 %

分类	识别率			
	单垂直	单水平	两者结合	滤波去噪
普通图像	98.57	97.85	97.14	96.42
水面塑料袋	86.67	53.33	73.33	74.20
水面塑料瓶	46.67	46.67	80.00	76.84

从测试结果中可以看出,对于水面塑料瓶的识别,将两个方向的图像相结合进行训练效果更好,因此对于微调网络选择采用两个方向结合的方式进行训练。另外可以看出,加入滤波去噪对水面塑料袋的识别有略微提高,但同时也降低了对塑料瓶的识别率。因此,滤波去噪对提高网络的识别精度并没有太大的帮助,反而有可能会影响识别效果,因此在后面的实验中不再对待识别图像进行滤波处理。

在第三组对比实验中,采用两个方向相结合的图像分别训练传统网络与微调网络,分别采用普通图像和水面图像对两种方法训练的网络进行测试,统计并记录实验结果进行对比,见表 5。

表 5 不同网络的识别率对比 %

网络类别	识别率		
	普通图像	水面塑料袋	水面塑料瓶
传统网络	97.14	73.33	80.00
微调网络	97.50	92.62	93.50

从表 5 的对比结果中可以看出,在对水面漂浮物的识别中,本文提出的小样本训练策略得到了更好的识别效果。同时在实验中发现,网络在第 25 次迭代时已经得到了较好的效果,在更多次数的迭代时,出现了验证集精度高于测试集精度的现象,符合网络训练时的收敛特性。总体来说,通过多次的对比实验证明了本文提出的训练策略对小样本容量情况下的图像识别是有效的。

第四组对比实验中,首先采用前述的光照矫正方法处理待识别图像,再将矫正后的图像放入训练好的微调网络进行识别,并将识别结果与未矫正实验以及传统的特征提取方法进行对比。由于塑料袋与塑料瓶的边缘特征更为明显,因此实验中参考文献中采用的传统 HOG 特征提取分类与本文方法进行对比,实验的对比结果如表 6 所示。

表 6 光照矫正算法及识别率对比 %

分类	未矫正	已矫正	HOG
普通图像	97.50	\	99.28
水面塑料袋	93.62	95.99	89.67
水面塑料瓶	92.50	95.13	73.63
水面图像平均识别率	93.06	95.56	81.65

从统计表 6 中可以看出,光照矫正对于水面图像的识别有一定的积极作用,在一定程度上提高了网络对水面图像的识别率。另外,普通图像不需要光照矫正,因此未做光照矫正的对比实验。同时,将矫正后的微调网络法与传统的 HOG 特征提取方法对比,可以看到微调网络提高了近 15% 的识别率,表明本文的网络微调方法适用于小样本情况下的水面漂浮物识别。

## 5 结 语

本文针对水面漂浮污染物的识别问题,提出了基于深度学习的小样本学习策略,首先用大量相关样本预训练网络,然后对小样本利用梯度下降法微调网络,同时将直方图均衡化法以及对数变换法两种传统的光

照矫正算法相结合,对两者的处理图像进行加权融合,减弱待识别图像中的光照影响。通过多组对比实验表明,该学习策略在水面漂浮物污染物识别问题上取得了较好的效果,其识别准确率明显优于传统的 HOG 特征提取分类方法。然而水面污染物种类很多,而本文仅以两种常见的水面污染物为例实现小样本学习策略的对比实验。因此在以后的研究中,将对更多类型的污染物进行分类识别研究,以便于部署到水面清理机器人中,为水面环境的智能监控清理提供一种便捷有效的方法。

## 参 考 文 献

- [1] 杨柳, 田生伟. 基于分布式计算的遥感图像水体识别研究[J]. 计算机应用与软件, 2016, 33(6):138-140, 145.
- [2] 赵亮, 王晓峰, 袁逸涛. 基于深度卷积神经网络的船舶识别方法研究[J]. 舰船科学技术, 2016, 38(15):119-123.
- [3] Li S, Zhu H, Chen D, et al. Water quality monitoring based on multiple remote sensing imageries [C]//International Workshop on Earth Observation and Remote Sensing Applications. IEEE, 2016:112-116.
- [4] Guo Y, Oerlemans A, Oerlemans A, et al. Deep learning for visual understanding [J]. Neurocomputing, 2016, 187(C):27-48.
- [5] Noda K, Yamaguchi Y, Nakadai K, et al. Audio-visual speech recognition using deep learning[J]. Applied Intelligence, 2015, 42(4):722-737.
- [6] Young T, Hazarika D, Poria S, et al. Recent trends in deep learning based natural language processing[J]. IEEE Computational Intelligence Magazine, 2018, 13(3):55-75.
- [7] Garcia-Pedrajas N, Hervás-Martínez C, Muñoz-Pérez J. COVNET: a cooperative coevolutionary model for evolving artificial neural networks[J]. Neural Networks IEEE Transactions on, 2003, 14(3):575-596.
- [8] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553):436.
- [9] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]//International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012:1097-1105.
- [10] Deng J, Dong W, Socher R, et al. ImageNet: A large-scale hierarchical image database [C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009:248-255.
- [11] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context [C]//European Conference on Computer Vision, 2014, 8693:740-755.
- [12] 高聪, 王福龙. 基于模板匹配和局部 HOG 特征的车牌识别算法[J]. 计算机系统应用, 2017(1):122-128.
- [13] 岑瑶, 潘新, 郜晓晶, 等. 基于 MB-LBP 和 HOG 的掌纹识别[J]. 计算机应用研究, 2017, 34(3):920-923.
- [14] Targ S, Almeida D, Lyman K. Resnet in Resnet: Generalizing Residual Architectures [EB]. arXiv:1603.08029, 2016.
- [15] 陈翠平. 基于深度信念网络的文本分类算法[J]. 计算机系统应用, 2015, 24(2):121-126.
- ~~~~~
- (上接第 204 页)
- [6] Sukawattanavijit C, Chen J, Zhang H. GA-SVM algorithm for improving land-cover classification using SAR and optical remote sensing data [J]. IEEE Geoscience & Remote Sensing Letters, 2017, 14(3):284-288.
- [7] 徐伟, 陈丹萍. 财务风险预警建模原则及几种预警新模型[J]. 统计与决策, 2016(8):150-153.
- [8] Park S, Lee H S, Kim J. Seed growing for interactive image segmentation using SVM classification with geodesic distance [J]. Electronics Letters, 2016, 53(1):22-24.
- [9] 王波, 杨静, 张健沛. 基于熵分类的个性化隐私匿名方法[J]. 吉林大学学报(工学版), 2013, 43(1):179-185.
- [10] 李学国, 沈应兰, 康先琼. 熵分类优化信息敏感值的个性化隐私匿名算法[J]. 科技通报, 2018, 34(3):155-158.
- [11] 杨仙, 张可能, 岳健, 等. 基于熵度量法的盾构施工过程风险评价[J]. 湖南科技大学学报(自然科学版), 2015, 30(4):64-68.
- [12] Arunkumar N, Ram Kumar K, Venkataraman V. Automatic detection of epileptic seizures using permutation entropy, tsallis entropy and kolmogorov complexity [J]. Journal of Medical Imaging & Health Informatics, 2016, 6(2):526-531.
- [13] 冉琼, 于浩洋, 高连如, 等. 结合超像元和子空间投影支持向量机的高光谱图像分类[J]. 中国图象图形学报, 2018, 23(1):95-105.
- [14] Sriwastava B K, Basu S, Maulik U. Predicting protein-protein interaction sites with a novel membership based fuzzy SVM classifier [J]. IEEE/ACM Trans Comput Biol Bioinform, 2015, 12(6):1394-1404.
- [15] Ai Y, Shao X, Jiang P, et al. Process modeling and parameter optimization using radial basis function neural network and genetic algorithm for laser welding of dissimilar materials [J]. Applied Physics A, 2015, 121(3):1317-1318.
- [16] Dehghanian E, Kaykhaii M, Mehrpur M. Comparison of single best artificial neural network and neural network ensemble in modeling of palladium microextraction [J]. Monatshefte für Chemie—Chemical Monthly, 2015, 146(8):1217-1227.
- [17] 何青, 褚东亮, 毛新华. 基于 EEMD 和 MF-FOA-SVM 滚动轴承故障诊断[J]. 中国机械工程, 2016, 27(9):1191-1197.
- [18] Shamshirband S, Mohammadi K, Tong C W, et al. A hybrid SVM-FFA method for prediction of monthly mean global solar radiation [J]. Theoretical & Applied Climatology, 2016, 125(1/2):53-65.