

基于多通道和卷积神经网络的极光分类

陈昌红, 刘 彬, 张 浩

(南京邮电大学 通信与信息工程学院 图像处理与图像通信江苏省重点实验室,
江苏 南京 210003)

摘 要:目前,极光图像分类领域多采用传统特征来进行分类。但传统特征提取图像的某种特定特征,比如纹理特征、局部特征、全局特征等,导致或多或少丢失极光图像的某些重要分类信息,造成分类效果不够好。对此,提出一种基于多通道融合和卷积神经网络的极光图像分类方法。采用多通道融合技术将原图信息和指定有效传统特征信息加以融合形成融合图像,利用预训练卷积神经网络自动提取融合图像的有效特征信息,实现多通道特征与深度学习相结合,得到高效表征极光图像的特征。在 2003 年北极黄河站越冬观测的 4 种日侧极光图像数据库上进行实验。在 8 001 幅典型极光图像数据库上,与人工标记对比分类准确率高达 95.2%,高于其他同类方法。实验结果表明该方法能有效用于极光图像分类。

关键词:多通道融合;卷积神经网络;深度学习;预训练;极光图像分类

中图分类号:TN911.73

文献标识码:A

文章编号:1673-629X(2018)12-0200-05

doi:10.3969/j.issn.1673-629X.2018.12.042

Aurora Images Classification Based on Multi-channel Fusion and Convolutional Neural Network

CHEN Chang-hong, LIU Bin, ZHANG Hao

(Key Laboratory on Image Processing & Image Communications of Jiangsu Province, School of Telecommunication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: At present, the traditional feature is used for classification in the field of aurora image classification. However, the certain features of image extracted by traditional feature, such as texture feature, local and global feature, leads to more or less loss of some important classification information of aurora images, resulting in a poor classification effect. For this, we propose an aurora image classification method based on multi-channel fusion and convolutional neural network. The multi-channel fusion technology is used to fuse the original image information with the designated effective traditional feature information to form the fusion image. The convolutional neural network is used to automatically extract the effective feature information of the fusion image, to realize the combination of multi-channel features and deep learning, and to obtain the features of efficiently representing the aurora image. The experiment is carried out on the four kinds of daily aurora image databases in the North Pole of the Yellow River station in 2003, which shows that the classification accuracy in comparison with manual markers in the classic database 8,001 aurora images is as high as 95.2%, higher than other similar methods. The results show that this method can be used in the classification of aurora images.

Key words: multi-channel fusion; convolutional neural network; deep learning; pre-training; classification of aurora images

0 引言

极光是一种出现于星球的高磁纬地区上空,绚丽多彩的发光现象。极光不仅是个光学现象,而且是个无线电现象,可以用雷达进行探测研究,它还会辐射出某些无线电波。极光不仅是科学研究的重要课题,还

直接应用到无线电通信、长电缆通信,以及长的管道和电力传送线等许多实用工程项目中。地球极光的研究已有几十年的历史,极光图像类别研究有着演进过程。Hu 等在 2009 年根据在北极采集的全天空极光图像数据将日侧极光划分为帷幔冕状、极光亮斑、弧状和辐射

收稿日期:2018-01-12

修回日期:2018-05-17

网络出版时间:2018-07-04

基金项目:国家自然科学基金(61571353)

作者简介:陈昌红(1982-),女,博士,副教授,研究方向为智能视频分析、图像理解、模式识别等;刘 彬(1992-),男,硕士,研究方向为图像处理与图像通信。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20180703.1511.034.html>

冕状 4 种类型;杨秋菊等^[1]在 2017 年将极光类型划分为弧状、帷幔冕状、辐射冕状和热点状 4 类。文中采用的是弧状、帷幔冕状、辐射冕状和热点状 4 类的分类方式。

Fu 等^[2]在 2009 年运用形态学分析方法将极光背景区域和纹理区域分离进行分类;Wang 等^[3]在 2010 年基于局部二值模式表征极光图像特征进行分类;韩冰等^[4]在 2013 年采用显著性编码方法对极光图像进行分类;杨曦等^[5]在 2013 年通过分层小波将极光全局特征和局部特征进行结合对极光图像进行分类。总结上述分类方法,采用的是利用分类器对传统特征提取的极光图像信息进行分类。传统特征提取针对某一特定的特征对极光图像进行信息提取,要么提取极光全局特征,要么提取极光局部特征,有时同时提取局部特征和全局特征,但都会或多或少地丢失图像原来的信息,造成极光图像分类结果不够理想。近年来,机器学习、深度学习等快速发展。韩冰等^[6]在 2017 年便采用基于改进的主成分分析网络的机器学习进行极光图像分类,初步将机器学习运用到极光研究中,在极光图像二分类和三分类方面取得了一定的成果,但是仅仅利用了图像结构的整体信息没有考虑到图像结构内部的局部信息,导致极光图像 4 分类准确率不够好。

近年来,卷积神经网络^[7-11](convolutional neural network, CNN)在图像处理、计算机视觉、文本处理、语音处理等领域得到了广泛应用。卷积神经网络是一种前馈神经网络,它的人工神经元可以响应一部分覆盖范围内的周围单元,模拟人类大脑皮层中局部敏感和方向选择神经元功能。

基于上述讨论,文中旨在融合传统特征与深度学习^[12-13]技术,提取极光图像全方位特征实现极光图像普适高效分类,提出一种基于多通道融合和卷积神经网络的极光图像分类方法。利用多通道融合技术将极光原图、LBP^[14]特征图、光流图进行融合,得到处理后的融合图像。融合图像不仅包含极光所有原始信息,还包含有效纹理分类特征,还具有极光图像可扩展的光流运动特征。然后,采用预训练的 CNN 对多通道融合后的特征图进行自动特征学习,提取融合图像中全面有效的分类信息;最后采用基于 SVM^[15]分类,判定待测样本图像的极光类别。

1 极光图像特征提取及分类

极光图像分类,根据在极光图像信息中所反映的不同特征,将不同类别的极光图像区分开来。极光特征的选择对于极光图像分类至关重要。常用的图像特征有颜色特征、纹理特征、形状特征、空间关系特征、全局特征、局部特征等等。文中重在极光图像特征的选

择与融合。选择有极光图像代表性的特征加以融合,利用深度学习技术对融合特征信息自动提取不为人眼察觉的更有效信息。多种有针对性特征融合更具有代表性,利于极光图像高分类准确率。

算法流程如图 1 所示。

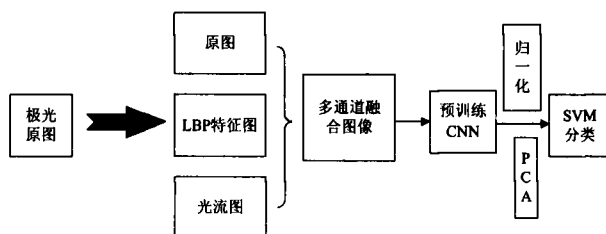


图 1 算法流程

整个模型可以由多特征融合模块和 CNN 特征提取器以及 SVM 分类器三部分组成。首先,将样本图像送入多特征融合模块,经过原图、LBP 特征、光流特征的多通道融合得到融合图像。然后,将融合图像送入 CNN 模型的输入层,经过多次卷积和降采样操作,得到若干幅特征图像。再将特征图像拉伸为一列向量,依旧保留与特征向量全连接的输出层,用于 CNN 特征提取器的训练。最后,利用特征提取器将提取到的特征向量送入 SVM 分类器,分类器进行相关的运算后,输出最终分类的结果。

1.1 多通道融合特征提取

多通道特征融合特征提取基于人工设定提取指定的样本特征(体现极光图像特点),将不同的有代表性的突出极光图像的提取特征图放入图像的多个通道,融合后的图像具有图像多方位多角度的特征,充分体现图像有效可靠的信息。

文中采用三通道融合特征,包含极光原图、极光 LBP 特征图、极光 HS 光流图。用上述三种特征图合成三通道 RGB 图像作为融合后特征图。极光原图没有被任何手段进行处理,保留有完整极光图像信息,将极光原始图像作为第一通道特征图像;LBP(局部二值模式)是一种非参数化图像局部空间结构及纹理描述算子,具有旋转不变性的优点,将极光 LBP 图像作为第二通道特征图像;光流是图像亮度模式的表现运动,表达了图像的变化,包含图像的运动信息,HS 光流图像表征极光图像前后变化幅度,提高分类准确性,HS 光流图像作为第三通道特征图像。

(1)极光原图具有极光所有细节信息及整体信息,对其进行任何的特征提取都会或多或少丢失某些细节信息。极光原图是多通道特征中必不可少的一项,为接下来的 CNN 自动特征学习提取提供最原始数据。由于拍摄设备、极地周边环境和极光活动强度的影响,中国北极黄河站所拍摄的极光原始数据存在各种各样的问题,不能够直接使用。文中的极光原图一

律为相关专家针对极光原始数据的特点,对原始数据进行有效的减暗电流、去除边缘噪声和裁剪、灰度图像拉伸、图像旋转四个预处理步骤后的图像。

(2) 极光 LBP 通道特征。LBP 是由 Ojala 等提出的一种纹理特征描述算子,用于描述图像中每个像素值和其近邻点像素值之间的关系。初始 LBP 的缺陷在于固定的 3×3 纹理单元结构不能够表示大空间尺寸的纹理特征, Ojala 等又对 LBP 做了改进和完善。邻域的选择不再是以前固定的 3×3 方格结构,而是采用更加灵活的圆形结构。圆形邻域由 R 和 P 定义,圆心为中心像素, R 是圆周半径, P 是均匀分布在圆周上的邻域像素个数。假如邻域点没有落在像素中心,可以使用双线性内插求出邻域点的灰度值。

中心像素 LBP 值的计算公式如下:

$$\text{LBP}_{P,R} = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

不同 P 、 R 对应的圆形邻域如图 2 所示。

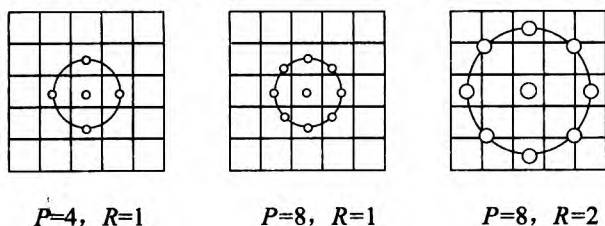


图 2 不同 P 、 R 对应的圆形邻域

在式 1 中, i 取值为 $0 \sim P-1$, g_i 是第 i 个邻域像素的灰度大小, g_c 是中心像素的灰度大小。按照式 1 的计算,选定 P 和 R 后,对应的 LBP 模式共有 2^P 种。对极光图像中的每个像素求 LBP 特征值,用 LBP 特征值替代原始的像素值,得到该极光图像的 LBP 特征图。将该 LBP 特征图放入多通道融合图像的一个通道,作为通道特征。

(3) 光流通道。光流是图像亮度模式的表现运动,表达了图像的变化,包含图像丰富的运动信息。HS 光流法基于物体移动的光学特征的两个假设,运动物体的灰度在很短的时间间隔内保持不变,给定邻域的速度向量场变化是缓慢的。每类极光图像是从每类极光运动序列中抽取出来的,在同类的极光图像用光流特征可以表示每类图像的一个运动及变化信息,增加了极光图像分类的容错性,提高了极光图像的分类准确率。将同类别极光图像放在一起,进行前后两幅图像 HS 光流特征提取,并将得到的光流信息生成灰度图像作为极光 HS 特征图,作为多通道融合的另一通道特征图。

多通道特征图如图 3 所示。

经过上述三通道融合后的图像,兼备极光原图所有完整信息、极光图像代表性纹理特征 LBP 和可伸缩

的极光图像运动特征光流特征。融合图像含有丰富的特征信息,为预训练的卷积神经网络提供可靠有效的输入。

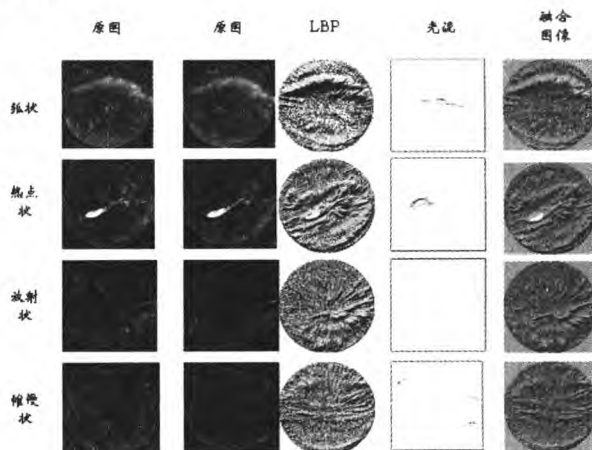


图 3 多通道特征图

1.2 预训练卷积神经网络特征提取

CNN 是一种包含卷积层的深度神经网络,其模型是受脑神经科学研究的启发,模仿视皮层中的简单细胞和复杂细胞处理视觉信息的过程。深度学习 CNN 对极光样本图像进行逐层特征变化,将样本在原空间的特征表示变换到新的特征空间,自动学习到层次化的更具代表性的特征。CNN 是一个前馈式神经网络,能从一个二维图像中提取特征,并采用反向传播算法来优化网络中的参数。预训练卷积神经网络是借助在其他数据库的基础上训练好的卷积神经网络模型初始化极光图像卷积神经网络,既能解决极光数据库数据量过小的问题,又可以加快极光卷积神经网络的训练速度。

CNN 特征提取器包括输入层、卷积层、池化层、全连接层和 Softmax 层。输入层,直接将多通道融合后的图像输入至预训练 CNN 模型的输入层中,不用再对融合图像进行其他处理。卷积层,卷积的主要功能是特征抽取,利用若干个卷积核对上一层图像进行卷积操作,从而得到多个特征图像。卷积层的计算公式为:

$$X_j^l = f(\sum_{i \in M} X_i^{l-1} * k_{ij}^l + B^l) \quad (2)$$

其中, l 为所在层数; k 为卷积核; M 为输入层的感受野; B 为偏置项; f 为激活函数。

卷积层能降低网络的空间分辨率,消除偏移和图像扭曲,实现位移不变性。特征图像个数不因降采样操作发生任何变化,但图像的尺寸会根据降采样窗口和步长发生相应变化。池化层,采用最大池化(max-pooling)操作进行下采样。下采样并不改变特征图的数目,只是将特征图变小,降低特征维度,加速结构训练和特征提取。如果采样窗口的大小是 $m \times m$,经过一次池化后,特征图大小变为原来特征图的 $1/m \times$

$1/m$ 。池化的计算公式为:

$$X_j^i = f(\beta_j^i p(X_j^{i-1}) + B^i) \quad (3)$$

其中, X_j^i 和 X_j^{i-1} 分别表示当前层和前一层的第 j 个特征图; p 表示一个下采样函数; β_j^i 表示当前层第 j 个特征图的乘性偏置; β_j^i 表示第 j 个特征图的加性偏置; f 表示激活函数。

全连接层:池化层的输出是二维数组,将其特征图对应的二维数组转换为一维数组,将每层所有的特征图转化的一维数组串联成一个一维数组作为全连接层的输入。全连接层的计算公式为:

$$H_{w,b}(x) = \theta(w^T x + b) \quad (4)$$

其中, $H_{w,b}(x)$ 表示神经元的输出值; x 表示神经元的输入特征向量; w 表示权值向量; b 表示偏置; θ 表示激活函数。

Softmax 层:一种分类器,当输入给定样本后,每一个神经元输出一个取值在 0 到 1 之间的数值,该数值代表输入样本属于此类别概率,选取输出值最大的神经元对应的类别作为此样本的分类结果。文中将 Softmax 输出神经元数目设置为 4,对应四类极光。

针对目前极光数据库标定量有限的情况,采用预训练 CNN 进行研究。通过在大的图像分类数据集上训练好模型,把卷积神经网络前面那些层的参数固定,初始化极光图像分类的卷积神经网络,修改模型最后一到两层的参数设置符合极光图像分类,实现整个网络参数的极光图像分类化同化。既利于加快训练速度,又解决了极光图像数据库标定量小的问题。

1.3 基于 SVM 的极光图像特征分类

文中分类器选用 SVM 分类器,在用分类器前对特征数据进行重要的归一化、PCA 降维^[16]操作。其中,特征数据归一化是至关重要的,对于最后的分类结果有质的作用。而 PCA 降维也十分重要,对于运算量和运行时间的优化是非常有必要的。

1.3.1 归一化

在进行 SVM 分类之前,对数据进行归一化操作。将训练集和测试集整合为一个数据集,统一归一化时样本的每一维度的最大值和最小值是从训练集和测试集中寻找,然后将样本数据映射到 $[0, 1]$ 的值域范围内。归一化对计算和建模都是必要的,便于数据处理,还能保证程序运行时收敛加快。

1.3.2 PCA 降维

在 CNN 模型极光图像特征提取过程中,随着卷积层次的累加,特征维数会越来越大,导致“维数灾难”,造成时间和空间的浪费。为了解决这个问题,使用 PCA 对得到的 CNN 特征进行降维处理。

设 X 表示原始特征向量,则可根据式 5 对其进行 PCA 变换,得到降维后的特征向量 $Y = [y_1, y_2, \dots,$

$y_n]$ 。

$$Y = CX \quad (5)$$

Y 中各个向量互不相关,并且 y_i 的方差 λ_i 依次递减, y_1, y_2, \dots, y_n 分别为第 1, 第 2, \dots , 第 n 主分量。第 i 个主分量的贡献率定义为: $\lambda_i / \sum_{k=1}^n \lambda_k (i = 1, 2, \dots, n)$ 。

前 m 个主分量的累积贡献率定义为: $\sum_{i=1}^m \lambda_i / \sum_{k=1}^n \lambda_k$ 。选取前 $m (m < n)$ 个主分量替代原始数据进行分析、分类操作,以达到降维效果。

2 实验结果与分析

2.1 极光图像数据库

文中的极光原图一律为相关专家针对极光原始数据的特点,对原始数据进行有效的减暗电流、去除边缘噪声和裁剪、灰度图像拉伸、图像旋转四个预处理步骤后的图像。文中所用的极光图像数据来自于中国极地研究中心的研究人员手动标记的北极黄河站 2003-2004 年越冬观测 19 天数据。因为极光的四种分类机制是结合极光三个波段的特点定义的,因此他们在标记时同时参考了三个波段的图像,其中包含 3 934 幅弧状极光图像,1 786 幅帷幔状极光图像,1 497 幅辐射状极光图像和 784 幅热点状极光图像。

2.2 极光图像四分类实验

本节进行极光图像四分类普适分类实验,对实验数据进行 4 类极光图像(弧状、放射状、帷幔状、热点状)分类。从上面提到的 8 001 幅数据库中按照训练集测试集 4:1 比例进行实验。为了验证多通道融合及 CNN 在极光图像分类上的有效性,对基于极光原图+CNN、极光 LBP 图+CNN、极光原图 LBP 图光流图三通道融合+CNN 的极光图像识别算法进行了比较。实验中预训练 CNN 采用的是 imagenet-vgg-f 训练模型。为减少实验的随机性,实验重复 10 次,每一轮的数据划分都不一样,计算平均分类准确率作为评估准则:

$$\text{分类正确率} = \text{正确分类数} / \text{所有图像数} \quad (6)$$

实验结果如表 1 所示。

表 1 不同算法的识别性能比较

算法	识别率/%
原图+CNN+SVM	90.12
LBP+CNN+SVM	89.52
多通道+CNN+SVM	95.19

表中给出了原图+CNN+SVM、LBP+CNN+SVM 和多通道(三通道:原图、LBP、光流+CNN+SVM 在相同条件下的平均分类正确率对比情况。可以看出,文中的多通道融合由于融合了多种有效表征极光图像特

征对其分类有很大的促进作用。原图虽包含图像原始信息,但由于缺少运动信息,因而分类效果有所影响。LBP 特征图提取极光图像的纹理特征,缺少运动特征及其他原图所携带信息,分类效果有所影响。结果表明多通道融合特征有效提升了分类准确率。

2.3 分类效果对比实验

将文中方法与一些其他的分类方法(WLD(韦伯描述符)、LBP)进行比较,结果如图4所示。

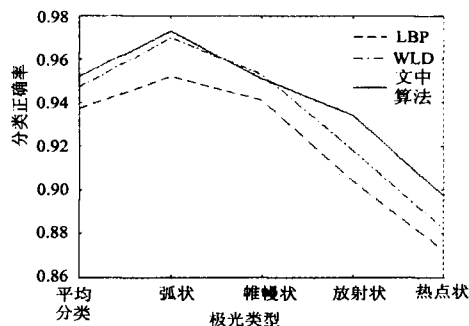


图4 文中算法与其他算法的比较

对极光图像进行自动分类的关键在于有效保证极光图像信息,根本思想是模仿人的感官去区分不同极光类别的差异。WLD是一种纹理描述算子,由心理学韦伯定律发展而来,是一种局部描述符,因此会丢失极光图像全局等信息。LBP也是一种纹理特征,会丢失极光图像运动变化等特征。从图4中可以看出,文中算法由于融合了原图信息、有代表性的传统特征LBP信息和光流信息以及卷积神经网络的自动学习特征,相比其他算法在分类准确率上有所提高。对比弧状、辐射冕状、帷幔冕状和热点状4类极光的结构形态,热点状极光复杂多变,不利于分类识别,而弧状极光由于具有明显的弧形特征最具识别性。实验结果也显示,三种分类方法都呈现出弧状极光分类正确率最高,热点状极光分类准确率最低,辐射冕状极光和帷幔冕状极光分类正确率介于弧状极光跟热点状极光分类正确率之间。

3 结束语

利用多通道融合特征和预训练卷积神经网络对极光图像进行分类。首先通过多通道融合原图、LBP特征图、HS光流特征图构建多通道融合特征图,通过预训练卷积神经网络进行自动特征学习,利用支持向量机进行最终分类。实验结果表明,该方法具有良好的分类性能,解决了热点状极光容易混淆分类的难题。通过已标定好的极光数据库进行训练测试,是有监督的极光图像分类研究。由于极光研究采集了大量样本数据,都是为标定的数据,人工标定费时费力费钱。因此今后的工作将针对无监督数据进行模型训练测试分类,以求将大量未标定数据应用到研究中。

参考文献:

- [1] 杨秋菊,胡泽骏.一种基于形态特征的极光自动分类方法[J].中国科学:地球科学,2017,47(2):252-260.
- [2] FU Rong, LI Jie, GAO Xinbo, et al. Automatic aurora images classification algorithm based on separated texture [C]//IEEE international conference on robotics and biomimetics. Guilin, China: IEEE, 2009: 1331-1335.
- [3] WANG Yuru, GAO Xinbo, FU Rong, et al. Dayside corona aurora classification based on X-gray level aura matrices [C]//Proceedings of the ACM international conference on image and video retrieval. Xi'an, China: ACM, 2010: 282-287.
- [4] 韩冰,仇文亮.一种特征显著性编码的极光图像分类方法[J].西安电子科技大学学报:自然科学版,2013,40(6):180-186.
- [5] 杨曦,李洁,韩冰,等.一种分层小波模型下的极光图像分类算法[J].西安电子科技大学学报:自然科学版,2013,40(2):18-24.
- [6] 韩冰,贾中华.改进的主成分分析网络极光图像分类方法[J].西安电子科技大学学报:自然科学版,2017,44(1):83-88.
- [7] LEE H, GROSSE R, RANGANATH R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations [C]//International conference on machine learning. [s. l.]: ACM, 2010: 609-616.
- [8] GONG Y, JIA Y, THOMAS L, et al. Deep convolutional ranking for multi-label image annotation [J]. Computing Research Repository, 2015, 22(12): 1-9.
- [9] CHAN T H, JIA K, GAO S, et al. PCANet: a simple deep learning baseline for image classification? [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.
- [10] JI Shuiwang, XU Wei, YANG Ming, et al. 3D convolutional neural networks for human action recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 221-231.
- [11] WANG Xiaolong, ZHANG Liliang, LIN Liang, et al. Deep joint task learning for generic object extraction [C]//Advances in neural information processing systems. Cambridge, MA: MIT Press, 2015: 523-531.
- [12] RUSSAKOVSKY O, DENG Jia, SU Hao, et al. Imagenet large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [13] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [14] 卢官明,左加阔.基于二维局部保持鉴别分析的特征提取算法[J].南京邮电大学学报:自然科学版,2014,34(5):1-8.
- [15] 周鹏.基于支持向量机的车牌字符识别方法[J].数学技术与应用,2016(9):91.
- [16] 刘冰冰.基于PCA车牌识别算法的研究与实现[D].长春:长春理工大学,2011.