

基于多尺度卷积特征融合的台风等级分类模型

卢鹏^{**}, 邹佩岐, 邹国良^{*}

上海海洋大学信息学院, 上海 201306

摘要 为提高卷积神经网络对图像多尺度变化的感知能力, 增加网络的尺度不变性, 提出一种基于多尺度卷积特征融合的台风等级分类模型。在卷积神经网络中添加多尺度感知层, 对卷积特征进行多尺度感知并进行级联。将多尺度正则化项添加到损失函数中, 通过反向传播来最小化隐含层权重的残差, 优化模型的特征提取能力。最后将多尺度高层语义特征通过 Softmax 分类层归一化成各图像类别的概率值, 取最大概率值为最后图像的分类结果。为有效验证本模型的多尺度感知能力, 选用红外卫星台风云图作为数据集, 实验结果表明, 本模型能有效感知并提取台风云图的局部特征, 并在两个通用数据集 MNIST 和 CIFAR-10 上验证了本模型的泛化能力。

关键词 大气光学; 台风等级分类; 卷积神经网络; 多尺度特征; 尺度不变损失函数

中图分类号 TP3

文献标识码 A

doi: 10.3788/LOP56.160101

Typhoon Classification Model Based on Multi-Scale Convolution Feature Fusion

Lu Peng^{**}, Zou Peiqi, Zou Guoliang^{*}

College of Information Technology, Shanghai Ocean University, Shanghai 201306, China

Abstract In order to enhance the perception for the multi-scale image variation and improve the scale invariance of convolutional neural networks, this study proposes a typhoon classification model based on multi-scale convolutional feature fusion. A multi-scale perception layer is added to convolutional neural networks; then, convolutional features are multi-scale perceived and cascaded. A multi-scale regularization term is then incorporated into the loss function. The residual error of hidden layer weight is minimized and the feature extraction ability is optimized with backpropagation. Finally, multi-scale high-level semantic features are normalized to the probability value of each category using Softmax. The maximum probability value is used as the final classification result of the image. Infrared satellite cloud images are used as the dataset in our experiments to validate the multi-scale perception ability of the model. Experimental results show that the model can effectively perceive and extract the local features of the typhoon cloud map. The generalization ability of the model is verified using two general datasets, i. e., MNIST and CIFAR-10.

Key words atmospheric optics; typhoon classification; convolutional neural network; multi-scale feature; loss function with scale invariance

OCIS codes 010.1615; 100.4145; 100.2000

1 引言

近年来, 在以全球变暖为主要特征的气候变化背景下, 极端气象灾害的发生频次和破坏程度明显上升, 其中台风对我国沿海地区构成的威胁尤为明显。红外卫星云图作为近年来台风研究的主要数据

来源, 可通过提取重要特征来实现台风等级的快速分类。卫星云图在台风发生、发展、成熟、消亡的过程中表现出多种特征, 如纹理、形状等, 因此云图分类过程中存在着类间间距相对较小、类内间距相对较大、涡旋结构变化细微以及噪声干扰等问题。然而, 传统的特征提取过程繁琐且特征深度不够, 不能

收稿日期: 2019-01-28; 修回日期: 2019-03-03; 录用日期: 2019-03-21

基金项目: 国家自然科学基金(41501419)

* E-mail: glzou@shou.edu.cn; ** E-mail: plu@shou.edu.cn

较好地分类提供高层语义特征。

近期,深度学习在图像识别、音频识别等计算机应用领域得到广泛应用^[1-3]。卷积神经网络(CNN)作为一种典型的深度学习算法,能够以端到端的学习方式逐层对输入的图像进行高层次、抽象化的特征提取,在图像分类上取得了不错的效果^[4-5]。但对于复杂且需要感知局部细微变化的数据集,网络提取的单一尺度特征不能表征图像的多尺度特征^[6-7]。文献[8]中利用两个卷积层增加模型的非线性表征能力,并使用大小不同的滤波器提取不同区域的图像特征,实验结果表明该方法具有良好的表现性和稳健性。Cui等^[9]使用卷积网络集成的方式进行人脸表情识别,利用脸部关键点剪裁不同区域的图片作为各个网络的输入样本,并将结果融合得到最终的识别结果。

基于此,本文在卷积神经网络的基础上提出一种基于多尺度特征融合的分类模型 MS-TyCNN 并运用在台风云图数据集上。MS-TyCNN 利用不同层的卷积特征建立多尺度感知层,对台风图像进行多尺度表征,并将尺度不变性指标^[10]与交叉熵函数结合,构成模型的损失函数,以此来有效增强图像特征的尺度不变性。实验证明,该模型能有效提高台风云图局部区域的感知能力,从而提高台风等级分类性能并在手写字体库 MNIST 数据集、CIFAR-10 数据集上验证了该模型的泛化能力。

2 卷积神经网络

在卷积神经网络中,卷积层和池化层通过激活函数对图像进行非线性特征提取;全连接层对提取的特征进行降维整合,再利用 Softmax 函数得到每类标签的概率值,预测图像类别。在输出最终预测值之前,网络通过层间信号传输对比前向传播的预测值与真实值。在此过程中,隐含层利用损失函数来最小化两者的误差,最终得到图像的分类结果。

2.1 卷积和池化层

卷积神经网络通过卷积层和池化层交替学习图像特征。卷积层通过滑窗以步长的方式选取局部图像区域,并对其加权求和,得到的局部线性特征再通过激活函数对特征作非线性变换;池化层选择最大池化方式缩减空间维度,以降低卷积特征的网络空间分辨率,消除冗余干扰特征,提高位移不变性^[11]。因此,为保证提取特征的丰富性,使用卷积特征作为融合对象。

将通过预处理归一化得到的样本 $\mathbf{X} = (\mathbf{x}_1, \dots,$

$\mathbf{x}_n)$ 经过第 l 层卷积操作,其过程为

$$\mathbf{X}^{(l)} = \xi(\mathbf{w}_1^{(l)} * \mathbf{x}_1^{(l-1)} + \mathbf{w}_2^{(l)} * \mathbf{x}_2^{(l-1)} + \dots + \mathbf{w}_n^{(l)} * \mathbf{x}_n^{(l-1)} + \mathbf{b}^{(l)}) = \xi\left(\sum_{i=0}^n \mathbf{w}_i^{(l)} * \mathbf{x}_i^{(l-1)} + \mathbf{b}^{(l)}\right), \quad (1)$$

式中: $\mathbf{X}^{(l)}$ 为第 l 层输出的特征; $\mathbf{w}_i^{(l)}$ 、 $\mathbf{b}_i^{(l)}$ 为第 i 个样本第 l 层隐含层的权重和偏置项; \mathbf{x}_i 为第 i 个样本数据; $\mathbf{x}_i^{(l-1)}$ 为第 i 个样本的第 $l-1$ 层输出; n 为样本总数; $\xi(\cdot)$ 为激活函数。对于卷积特征 \mathbf{X} 输入到第 l 层池化,其输出形式为

$$\mathbf{X}^{(l)} = \gamma^{(l)} \delta(\mathbf{X}^{(l-1)}) + \mathbf{b}^{(l)}, \quad (2)$$

式中: $\gamma^{(l)}$ 为第 l 层池化层权重系数; $\delta(\cdot)$ 为最大池化函数。此处采用线性整流函数(ReLU),公式为

$$\xi(x_{ij}) = \begin{cases} x_{ij}, & x_{ij} > 0 \\ 0, & x_{ij} \leq 0 \end{cases}, \quad (3)$$

式中: x_{ij} 为第 i 个样本第 j 个神经元的输出,即 \mathbf{x}_i 中的第 j 个元素。

2.2 损失函数

损失函数的作用是在反向传播时更新网络权重并判定模型分类性能。卷积神经网络通常采用 Softmax 层作为网络的分类器,其作用是多个神经元的输出映射到 $(0, 1)$ 之间且和为 1。设 z 为 Softmax 函数的输入,那么网络的输出层中第 j 个神经元的值表示为

$$\sigma(z_j) = \frac{\exp(z_j)}{\sum_{k=1}^K \exp(z_k)}, \quad (4)$$

式中: z_j 第 j 个神经元的输入; K 为样本类别数; $j=1, \dots, K$ 。

经过 Softmax 层的预测标签后,卷积神经网络根据损失函数反馈来更新网络的权重,使得预测标签无限接近真实标签。对于一个训练集 (\mathbf{X}, \mathbf{Y}) , \mathbf{Y} 为对应标签,其交叉熵损失函数表示为

$$L_{CR} = -\frac{1}{N} \sum_{r=1}^n \mathbf{y}_r^T \ln \sigma(\mathbf{x}_r), \quad (5)$$

式中: \mathbf{y}_r 为第 r 个样本 \mathbf{x}_r 对应的标签; $\sigma(\mathbf{x}_r)$ 为第 r 个样本 \mathbf{x}_r 对应的网络输出值; N 为批尺度。

3 MS-TyCNN 模型

卷积神经网络的隐含层所提取的特征具有层次性^[12-13]。将卷积层中滤波器提取的多通道特征进行叠加并进行可视化处理,得到的特征如图 1 所示。浅层的卷积核能敏感地感知图像的局部特征,如边

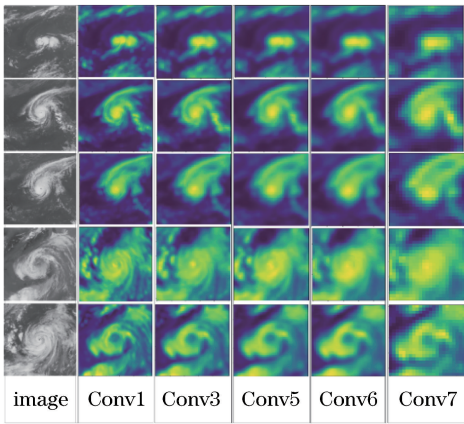


图 1 卷积特征可视化

Fig. 1 Convolutional feature visualization

缘特征、颜色特征等,这些特征对于不同的任务对象具有通用性^[14];通过底层特征的累积,深层卷积核提取的中、高层语义特征针对任务目标具有独特性。卷积神经网络在隐含层间传递学习到的权重参数具有一定的偏好性,并且因其递进式的学习方式和

端到端的传输形式,神经元易学习到大量无用特征并在层与层间传递信号时易忽略细小局部特征^[15]。

因此,采用特征融合的方式对传统卷积神经网络进行改进。在传统卷积神经网络中添加多尺度感知层,提取粗细不同尺度的特征,提高网络对图像特征提取的尺度不变性。改进后的分类模型 MS-TyCNN 主要分为两个部分:图像预处理阶段和图像分类阶段,其流程图如图 2 所示。图像预处理阶段,为进一步提高模型的图像分类能力,使用双线性差值和中值滤波的方法对台风云图预处理;图像分类阶段,在卷积神经网络的基础上,提取不同阶段的卷积特征。模型通过空间金字塔池化层构成多尺度特征池,并将多尺度特征进行归一化处理以方便特征的提取。将特征池中的多个特征进行级联,并作为下一隐含层的输入值。为了达到模型的最优权重分布,隐含层在反向传播过程中通过最小化多尺度损失函数来修正神经元的权重。

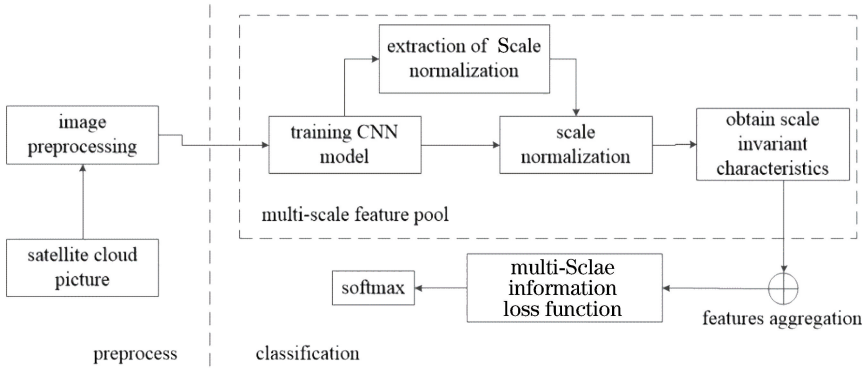


图 2 MS-TyCNN 模型的流程图

Fig. 2 Flow chart of MS-TyCNN model

3.1 数据预处理阶段

红外卫星台风云图在传输过程中对周围环境十分敏感,容易产生各种噪声。因此在进行特征提取之前,需要采用适当的方法进行降噪处理。实验中

采用台风云图,原数据大小为 512×512 ,为方便后续操作,采用双线性插值法将图像缩放至 227×227 ,再通过 3×3 窗口的中值滤波器对台风云图进行噪声抑制,图像预处理过程如图 3 所示。




图 3 卫星云图预处理过程

Fig. 3 Preprocessing of satellite cloud images

3.2 图像分类阶段

3.2.1 网络结构

为了能有效地提取台风云图不同尺度的特征，




图 4 MS-TyCNN 模型的网络结构图

Fig. 4 Network structural diagram of MS-TyCNN model

首先,利用 AlexNet 网络对预处理后的图像进行特征提取,然后通过多尺度感知层对提取的特征进行尺度归一化,并将得到的多尺度特征进行级联。由于每条特征对图像的贡献程度不同,不同特征对分类结果的影响不同,故使用全连接层将级联后的特征进行加权求和,聚合成新的全连接特征。最后,使用全连接特征训练 Softmax 分类器进行台风等级分类。在卷积神经网络训练过程中,不同层的卷积核能够感知图像的不同区域和尺度,因此建立多尺度感知层将这些特征进行融合,从而可以学习到强判别力的表征形式。

3.2.2 多尺度感知层

多个卷积特征直接通过全连接层容易造成计算负担并且破坏特征的空间不变性,因此,本文通过空间金字塔池化层^[16](SPP)对卷积特征进行多尺度降维,并提取出不同尺度的特征,然后将生成的特征聚合成一维特征,从而提高特征的空间尺度不变性。

本模型的空间金字塔池化层结构如图 5 所示。将输入的特征根据大小分成 3 种不同的尺寸块,设置总尺度变换系数为 $T_c=1/C$, C 为空间金字塔池化层的总尺度。假设有 M 个大小为 $a \times a$ 的卷积特征图谱, p 为金字塔池化层的尺度变换层数,则设置池化层的滑动窗口大小为 $\text{ceiling}(a/p \times a/p)$,步长设置为 $\text{floor}(a/p)$ 。本文设置 $p=3$,并且特征图的大小为 $13 \times 13 \times 256$,按照上述模型结构,将卷积层分成 $4 \times 4, 2 \times 2, 1 \times 1$ 的特征块,即 $T_{21}=21$,再利用最大池化操作,留下每个特征块中的最大值,将其级联得到大小为 21×256 的多尺度特征。

3.2.3 尺度不变性损失函数

为更好地在反向传播中修正滤波器的权重,从

在 AlexNet 网络结构的基础上提出 MS-TyCNN 分类模型,其结构如图 4 所示(c 表示卷积层, p 表示池化层, FC 表示全连接层)。

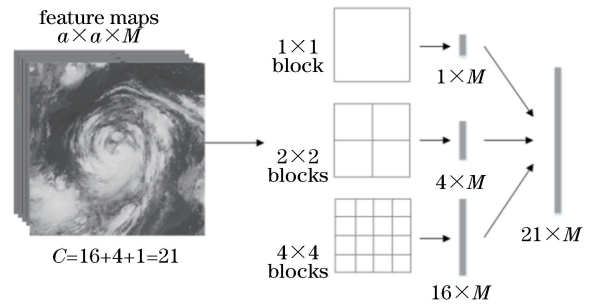


图 5 空间金字塔池化层结构图($T_{21}=1/21$)

Fig. 5 Structure of spatial pyramid pooling layer ($T_{21}=1/21$)

而获得具有判别力的多尺度特征,本文在卷积神经网络的损失函数 L 中添加尺度不变性的正则化项 L_{CR} 来提高特征的尺度不变性,公式为

$$L = L_{CR} + \frac{1}{\kappa} L_{SI}, \quad (6)$$

式中: κ 为损失函数的影响因子,本文设置 $\kappa=N$; L_{SI} 为针对特征构造的尺度不变性约束项。对于具有尺度不变性的神经元来说,无论输入端的尺度如何变化,都能激活提取同一特征的神经元。将此原理应用到多尺度特征融合算法中,构成尺度不变性约束,公式为

$$f(i) = \begin{cases} 1, & h_i(x) > t_i(x) \\ 0, & \text{otherwise} \end{cases}, \quad (7)$$

$$G(i) = E[f(i)], \quad (8)$$

$$L_{SI} = T_1 \frac{1}{G(i)} \sum_{x=0}^N 1[h(x) > 0] - T_c \frac{1}{G(i)} \sum_{x=0}^N f(i), \quad (9)$$

式中: $1[\cdot]$ 表明满足条件取值为 1; $E[\cdot]$ 为期望; i

为隐含层神经元; $t_i(x)$ 为神经元的激活阈值; $h_i(Q)$ 为第 i 神经元的输出; $G(i)$ 为全局激活率; T_1 为变换尺度前的总尺度变换系数, 即 $T_1=1$ 。定义函数 $f(i)$ 表示神经元 i 在满足 $h_i(x) > t_i(x)$ 条件时被激活。全局激活率 $G(i)$ 表示在随机刺激下神经元 i 被激活的概率值。为保证神经元在随机状态下仍有 1% 的概率被激活, 本文选取满足条件 $G(i)$ 等于或略大于 0.01。

4 实验结果与分析

仿真实验的主要硬件环境为 16 GB RAM, Intel Core i7-6700 CPU, NVIDIA GeForce GTX 1060 GPU。其软件环境是基于 python 语言搭建的深度学习框架 TensorFlow。

4.1 台风云图数据集

自 1977 年以来, 日本相继发射的“Himawari”系列地球同步气象卫星位于约东经 140° 的地球静止转移轨道上, 可观测云图通道 16 个, 全盘图观测频率可达到 10 min/次。本文选用“Himawari”系列

卫星观测西北太平洋的红外通道云图及其强度信息作为实验数据, 数据来源于日本国立情报学研究所 (NII) 网站所提供的年鉴资料, 其中云图信息每间隔 1 h 记录一次。数据集包含 1978~2016 年约 1000 多个台风过程, 并根据日本气象台提供的台风等级标准制定 5 类台风强度等级标签, 如表 1 所示。

表 1 台风等级分类标准

Table 1 Typhoon classification standard

Label	Level of typhoon	Maximum wind speed / ($\text{m} \cdot \text{s}^{-1}$)
Class 1	Tropical storm	≤ 24.4
Class 2	Severe tropical storm	24.5-32.6
Class 3	Typhoon	32.7-41.4
Class 4	Violent typhoon	41.5-50.9
Class 5	Super typhoon	≥ 51.0

根据台风等级分类标准, 将多个台风过程制成相应等级标签的台风强度数据。该数据集共 10000 张, 训练集 7500 张, 测试集 2500 张, 原始分辨率为 512×512 , 部分红外卫星云图数据集如图 6 所示。




图 6 部分台风标签样本

Fig. 6 Partial samples of typhoon labels

4.2 仿真实验

本文提出的 MS-TyCNN 是在 AlexNet 网络模型的基础上针对台风云图数据集进行微调, 实验批尺度为 100, 模型迭代 300 次, 并设置总尺度变换系数为 $T_{21} = 1/21$ 。同时实验设置初始学习率为 0.00005, 采用以 0.9 为衰减率的线性衰减策略对模型进行学习及优化。为防止出现过拟合情况, 在权重层添加正则项 L2, 并在全连接层之后设置丢弃率为 0.7 的丢弃层。

4.2.1 实验结果分析

将本文提出的多尺度特征融合模型 MS-TyCNN 与不同网络结构做对比实验, 其训练和测试的准确率如表 2 所示。

从表 2 中可以看出, LeNet-5 网络在实验数据集上的测试准确率比 AlexNet 网络的测试准确率低 8.93%, 证明了在一定程度上, 网络层数越深, 卷积层提取的台风特征越具有判别力。对比 AlexNet

表 2 不同模型在台风数据集上的准确率

Table 2 Accuracies of different models on typhoon datasets

Model	Train accuracy	Test accuracy
LeNet-5	0.8657	0.8559
AlexNet	0.9508	0.9432
Hybrid Model ^[17]	0.9714	0.9366
SIFT + CNN ^[18]	0.9272	0.9205
MS-TyCNN	1.0000	0.9988

网络以及两种改进模型 Hybrid Model^[17] 和尺度不变特征变换 (SIFT) + CNN^[18] 的训练集和测试集的准确率, MS-TyCNN 模型的训练和测试准确率均有明显上升, 其中测试集准确率比 AlexNet 网络上升了 5.36%, 表明在复杂的图像数据集中, 多尺度特征的融合能够加强特征的尺度不变性, 提高图像的分类性能。

图 7 是 5 种网络模型在台风云图数据集中的分类性能, 从图中可看出, 在 5 类网络结构中, MS-TyCNN 的准确率最终收敛在 0.9988, 达到最高。

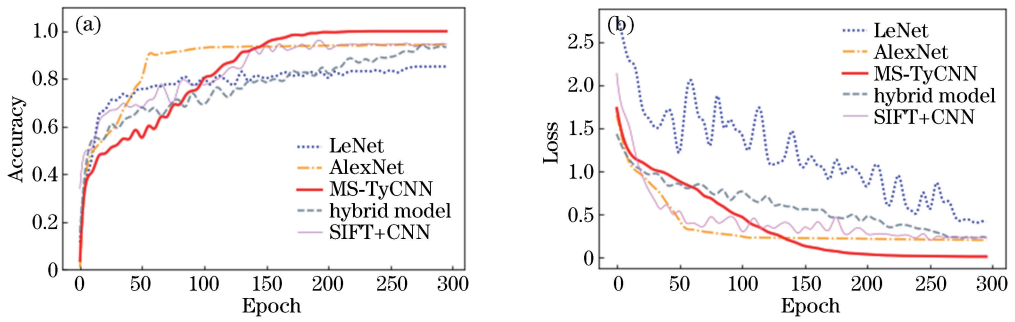


图7 台风云图数据集分类结果对比。(a)验证集精度曲线;(b)验证集损失曲线

Fig. 7 Comparison of classification results of typhoon cloud map datasets. (a) Accuracy of test set; (b) loss of validation set

LeNet-5 收敛速度较快,MS-TyCNN 收敛速度较慢。这是因为前期 MS-TyCNN 模型提取大量台风云图的多尺度特征进行级联,易造成特征冗余;且前期多尺度正则化项在目标函数中的惩罚力度较大,导致特征学习的速度较慢。但随着网络不断迭代和参数逐渐成熟,MS-TyCNN 模型加强了网络对图像的尺度不变性,逐渐体现出特征的多样性,最终提高台风等级分类的性能。

4.2.2 泛化性实验

为了验证 MS-TyCNN 的泛化性,本文使用两种通用数据集(MNIST、CIFAR-10)对该方法进行泛化能力对比验证。MNIST 数据集包含有 0~9 的手写字体图片,共 52000 张;CIFAR-10 包含 10 类相互独立的自然图片 60000 张。两种数据集在实

验中的训练样本和测试样本设计如表 3 所示。

表3 数据集的分布

Table 3 Distribution of datasets

Dataset	Number of training sample	Number of testing sample	Class
MNIST	42000	10000	10
CIFAR-10	50000	10000	10

MNIST 数据集输入大小为 28×28 ,CIFAR-10 图片输入大小为 32×32 ,网络结构参数以同比例的方式进行微调。实验迭代 300 次,MS-TyCNN 模型的实验结果如表 4 所示,模型在 MNIST、CIFAR-10 两类数据集中准确率分别达到 98.14% 和 87.63%,证明 MS-TyCNN 模型具有较好的泛化性。

表4 MS-TyCNN 模型的泛化能力

Table 4 Generalization of MS-TyCNN model

Dataset	LeNet-5	AlexNet	Hybrid model	SIFT+CNN	MS-TyCNN
MNIST	0.9637	0.9806	0.9725	0.9837	0.9814
CIFAR-10	0.7320	0.8431	0.8926	0.8759	0.8763

5 结 论

红外卫星台风云图具有结构复杂、信息分布不均的特点,而传统的卷积神经网络模型在感知图像的尺度不变性方面较弱,对台风云图的分类效果不佳。为此,提出了一种基于多尺度卷积融合的图像分类模型 MS-TyCNN,用以提高模型的尺度不变性,并将其运用到台风云图的特征提取中。一方面,模型通过添加多尺度感知层实现特征上的尺度不变性;另一方面,在目标函数中添加多尺度正则化项,使得改进后的网络在逐层筛选特征的过程中保持尺度不变性。通过台风等级分类实验证明,MS-TyCNN 模型在执行复杂图像分类任务时,其多尺度感知能力在一定程度上优于目前主流的分类模

型。相应的泛化实验结果表明,本文模型对简单图像数据库分类时也能取得较好的效果。

参 考 文 献

- [1] Huang S P, Yu L, Feng Z Y. A survey on image categorization using supervector coding [J]. Electronic Technology & Software Engineering, 2013 (4): 32-37.
黄双萍,俞龙,冯子勇.基于超级向量编码的图像分类系统研究[J].电子技术与软件工程,2013(4):32-37.
- [2] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.

- [3] Huang H, He K, Zheng X L, *et al.* Spatial-spectral feature extraction of hyperspectral image based on deep learning[J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 101001.
黄鸿, 何凯, 郑新磊, 等. 基于深度学习的高光谱图像空-谱联合特征提取[J]. *激光与光电子学进展*, 2017, 54(10): 101001.
- [4] LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [5] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks [M] // Fleet D, Pajdla T, Schiele B, *et al.* *Computer vision-ECCV 2014*. *Lecture notes in computer science*. Cham: Springer, 2014, 8689: 818-833.
- [6] Luo J H, Wu J X. A survey on fine-grained image categorization using deep convolutional features [J]. *Acta Automatica Sinica*, 2017, 43(8): 1306-1318.
罗建豪, 吴建鑫. 基于深度卷积特征的细粒度图像分类研究综述[J]. *自动化学报*, 2017, 43(8): 1306-1318.
- [7] Wang L L, Liu J H, Fu X M. Facial expression recognition based on fusion of local features and deep belief network [J]. *Laser & Optoelectronics Progress*, 2018, 55(1): 011002.
王琳琳, 刘敬浩, 付晓梅. 融合局部特征与深度置信网络的人脸表情识别[J]. *激光与光电子学进展*, 2018, 55(1): 011002.
- [8] Niu L Q, Chen X Z, Zhang S N, *et al.* Model construction and performance analysis for deep consecutive convolutional neural network[J]. *Journal of Shenyang University of Technology*, 2016, 38(6): 662-666.
牛连强, 陈向震, 张胜男, 等. 深度连续卷积神经网络模型构建与性能分析[J]. *沈阳工业大学学报*, 2016, 38(6): 662-666.
- [9] Cui R X, Liu M Y, Liu M H. Facial expression recognition based on ensemble of multiple CNNs[M] // You Z S, Zhou J, Wang Y H, *et al.* *Biometric recognition*. *Lecture notes in computer science*. Cham: Springer, 2016, 9967: 511-518.
- [10] Goodfellow I J, Le Q V, Saxe A M, *et al.* Measuring invariances in deep networks [C] // *Proceedings of the 22nd International Conference on Neural Information Processing Systems*, December 7-10, 2009, Vancouver, British Columbia, Canada. USA: Curran Associates Inc., 2009: 646-654.
- [11] Gu J X, Wang Z H, Kuen J, *et al.* Recent advances in convolutional neural networks [J]. *Pattern Recognition*, 2018, 77: 354-377.
- [12] Zeiler M D, Krishnan D, Taylor G W, *et al.* Deconvolutional networks[C] // *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE, 2010: 2528-2535.
- [13] Wang M, Hao J, Yao C H, *et al.* Sign language semantic recognition based on optimized fully convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2018, 55(11): 111010.
王民, 郝静, 要趁红, 等. 基于优化全卷积神经网络的手语语义识别[J]. *激光与光电子学进展*, 2018, 55(11): 111010.
- [14] Ivanovsky L, Khryashchev V, Lebedev A, *et al.* Facial expression recognition algorithm based on deep convolution neural network [C] // *2017 21st Conference of Open Innovations Association (FRUCT)*, November 6-10, 2017, Helsinki, Finland. New York: IEEE, 2018: 141-147.
- [15] Chen H J, Wang Q Q, Yang G W, *et al.* SSD object detection algorithm with multi-scale convolution feature fusion[J]. *Journal of Frontiers of Computer Science and Technology*, 2019, 13(6): 1049-1061.
陈幻杰, 王琦琦, 杨国威, 等. 多尺度卷积特征融合的SSD目标检测算法[J]. *计算机科学与探索*, 2019, 13(6): 1049-1061.
- [16] He K M, Zhang X Y, Ren S Q, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904-1916.
- [17] Lee S H, Chan C S, Mayo S J, *et al.* How deep learning extracts and learns leaf features for plant classification[J]. *Pattern Recognition*, 2017, 71: 1-13.
- [18] Iwahori Y, Takada Y, Shiina T, *et al.* Defect classification of electronic board using dense SIFT and CNN[J]. *Procedia Computer Science*, 2018, 126: 1673-1682.