

结合卷积神经网络多层特征和支持向量机的车辆识别

马永杰*, 马芸婷, 陈佳辉

西北师范大学物理与电子工程学院, 甘肃 兰州 730070

摘要 车辆识别方法计算量大,提取的特征复杂,且传统神经网络利用端层特征进行分类导致特征不全面,为此提出了一种结合卷积神经网络(CNN)多层特征和支持向量机(SVM)的车辆识别方法。该方法在传统 AlexNet 模型基础上构建卷积神经网络模型,通过分析参数变化对测试正确率的影响得到最优车辆识别模型;提取多层车辆特征图,采用串行融合方法与主成分分析降维技术将其构成一个具有多属性的车辆特征向量,以增强特征全面性,减少计算量;利用 SVM 分类器代替 CNN 的输出层实现车辆识别,以提高模型泛化能力与纠错能力。实验结果表明,相比传统方法,所提方法在分类精度和识别速度方面都有显著提高,且具有良好的稳健性。

关键词 图像处理;卷积神经网络;车辆识别;改进 AlexNet 模型;主成分分析;支持向量机

中图分类号 TP391.7

文献标识码 A

doi: 10.3788/LOP56.141001

Vehicle Recognition Based on Multi-Layer Features of Convolutional Neural Network and Support Vector Machine

Ma Yongjie*, Ma Yunting, Chen Jiahui

College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China

Abstract Vehicle recognition has a large amount of computation and complex extracted features, while the traditional neural network has incomplete features defined by end-layer features. Therefore, we propose a new vehicle recognition method based on multi-layer features of the convolutional neural network (CNN) and support vector machine (SVM). Firstly, the CNN model is constructed based on the traditional AlexNet model, while the optimal vehicle recognition model is obtained by analyzing the effect of parameter change on the accuracy. Further, the multi-layer vehicle feature map is extracted, and a multi-attribute vehicle feature vector is formed by the serial fusion method and the principal component analysis to enhance the comprehensiveness of the feature and reduce the computational complexity. Finally, vehicle recognition is realized by using the SVM classifier instead of the output layer of CNN, which improves the generalization and error-correction abilities of the model. The experimental results reveal that the proposed method has remarkable performance in classification accuracy and recognition speed; additionally, it has better robustness, compared with the traditional methods.

Key words imaging processing; convolutional neural network; vehicle recognition; improved AlexNet model; principal component analysis; support vector machine

OCIS codes 100.4996; 100.3008; 150.1135

1 引言

随着汽车工业和交通事业的快速发展,智能交通系统(ITS)^[1]成为影响现代社会发展的一个重要领域,车辆识别作为 ITS 的关键技术,可以实现辅助驾驶,及时提醒驾驶员根据路况进行减速、紧急刹

车等处理,以保障行车安全;同时车辆的自动识别对车流量的统计、车辆的追踪、交通诱导和控制等智能交通管理也具有重要的工程价值。

特征提取是识别系统的核心研究内容,目前关于特征提取算法主要分为两类,一类是采取传统图像特征的目标检测算法,如局部二值模式(LBP)、梯

收稿日期: 2018-12-24; 修回日期: 2019-01-12; 录用日期: 2019-02-17

基金项目: 国家自然科学基金(41461078)

* E-mail: myjmyj@163.com

度直方图(HOG)、Gabor 滤波器等。de Jong 等^[2], Batool 等^[3]利用 Gabor 滤波器组,使所提取特征具有强稳健性和尺度不变性;Li 等^[4]采用 HOG 特征和支持向量机(SVM)训练的车辆分类器,使车辆检测具有良好的泛化能力;陈龙等^[5]提出了一种基于 HOG-LBP 自适应融合特征的禁令交通标志检测方法;为了进一步提高检测精度和速度,杨先风等^[6]结合 HOG 和 LBP,成功地使用主成分分析(PCA)来降低维度,采用 SVM 进行训练并完成车辆的检测,其检测性能比单独的 HOG 有了很大的改进。单一特征难以充分描述目标的所有信息,因此很多算法使用多特征组合算法,但无论单一特征还是多特征组合,传统的图像特征都是基于人工提取的特征。

另一类是基于深度学习的目标检测算法。2006 年, Hinton 等^[7]提出了深度学习的思想,该方法在计算机视觉领域取得了突破性的进展^[8-10],很多分类方法由人工选取特征变为将图像直接输入到卷积神经网络(CNN)中学习生成的特征,均取得了良好的识别效果。2012 年, Krizhevsky 等^[11]提出的 AlexNet 模型刷新了图像分类挑战赛的记录,从此, AlexNet 模型成为 CNN 领域内具有重要历史意义的网络模型,大量研究工作者对其进行了研究及改进^[12-14]。此外, Shima 等^[15-16]通过将预训练的 CNN 模型和 SVM 相结合实现图像分类,达到了较好的识别效果,但是当目标与背景极为相似时,分类结果还是会受到影响;彭清等^[17]在训练好的 CNN 模型的基础上,提取隐含层所有层的特征,结合 SVM 进行车辆识别,比传统 CNN 识别效果更好。这些研究表明,将卷积神经网络结合 SVM 分类器应用于车辆识别是可行的,融合隐含层所有特征虽然提升了识别效果,但是难免存在大量的冗余信息,且融合特征维度高,影响识别速度,造成计算量的浪费。

车辆识别通常存在光照(天气)强度变化、背景多样性、拍摄角度变化等干扰,且单层神经网络提取的图像信息不足,为了减少这些干扰对分类结果的影响以及节省在训练过程中所需的计算能力和存储能力,本文提出一种经 PCA 处理的多层 CNN 融合特征与 SVM 相结合(MCP-SVM)的车辆识别方法。在 AlexNet 的基础上构建 CNN 模型,经过良好的训练之后,提取 CNN 多层车辆特征图,以串行融合方法将其融合,并利用 PCA 降低融合特征维度,提取有用信息,最后输入 SVM 分类器实现分类。实验表明,本文方法获得的车辆识别的正确率得到了明显的提高。

2 MCP-SVM 模型

卷积神经网络是一种层次模型,输入是原始数据,通过卷积、池化和非线性激活函数映射等一系列操作的层层堆叠,可挖掘出数据的多层表征。但传统的 CNN 模型进行分类时,只将最后一层所映射的特征送入分类器,难免会遗漏部分特征,使特征属性单一,影响最终识别结果。为了构建一个适用于车辆识别的 CNN 网络,必须综合考虑网络深度、卷积层个数、卷积核大小以及池化层大小等参数,使之适合实际数据。此外,在很多情况下, SVM 分类器比 CNN 的线性分类泛化能力更好、输出评价机制更可靠。

因此,选择具有分类优势且网络结构和参数大小适中的 AlexNet 模型作为基础网络,充分利用多层特征的全面性以及 SVM 泛化能力好等优势,构建 MCP-SVM 混合模型,如图 1 所示。

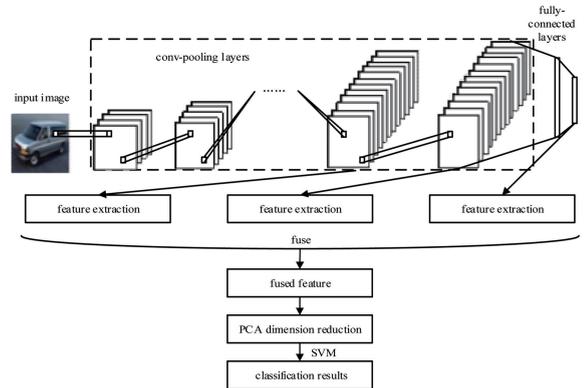


图 1 基于 MCP-SVM 混合模型的车辆识别算法架构
Fig. 1 Structure of vehicle recognition method based on MCP-SVM hybrid model

基于 MCP-SVM 混合模型的车辆识别算法步骤包括:

- 1) 根据实际数据,综合考虑网络参数选择,使其更适用于车辆识别任务;
- 2) 将网络后三层特征进行融合,弥补单层特征输出造成的信息遗漏,并利用 PCA 对高维融合特征作降维处理,去除冗余信息;
- 3) 采用 SVM 分类器代替卷积神经网络输出层,增强网络的泛化能力以及纠错能力。

2.1 数据采集与处理

共采集到 18202 张图片,并将其用于训练、测试网络模型。所采集到的图片全部由实景拍摄,其中包括 8901 张车辆正样本(图片中有车),9301 张非车辆负样本(图片中无车),部分样本如图 2 所示。

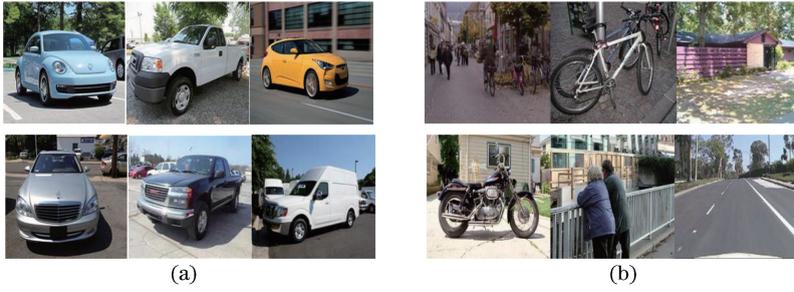


图2 部分图片样本示例。(a)正样本;(b)负样本

Fig. 2 Several images of samples. (a) Positive samples; (b) negative samples

原始图像分辨率因获取设备和来源不同而不同,因此必须进行预处理,步骤如下:

1) 调整图像尺寸。通过深度学习框架 Caffe 中提供的图像转换工具 convert_imageset, 检查所有的数据是否有相同的尺寸,并通过 FLAGS 参数组调用 opencv 库的 resize 函数来对图像缩放以改变图像大小。

2) 归一化图像。为消除公共部分,凸显个体特征,在训练前所有图片均减去训练集图片的像素平均值;将原始图像统一转换成 Caffe 框架支持的 LMDB 文件格式。

2.2 CNN 特征提取

卷积神经网络的性能受许多参数的影响, AlexNet 网络通过训练数据集 ImageNet^[18], 在 1000 个类别上获得了较好的识别效果,而本文车辆识别是二分类问题,在数据和计算资源有限的情况下,须重点关注模型结构的合理性、权值收敛情况、识别的正确率。

1) 在模型的训练过程中,对 AlexNet 模型的输

入数据大小、卷积核以及网络层数进行调整,通过设计 7 种网络结构并训练,分析这些参数对网络性能的影响,选择最佳参数,构建适合车辆识别的卷积神经网络。实验采用小卷积核,这是因为较大的卷积核使得网络难以分离,小卷积核可以使卷积层卷积到更多的图像特征。

2) 在 AlexNet 中使用的池化是可重叠的,重叠池化可以避免过拟合,但同时也容易引入噪声,因此采用 Dropout 技术随机忽略一部分神经元,以避免模型过拟合,同时还引入局部响应归一化(LRN)来建立局部神经元活动的竞争机制,使响应较大的值得到增强,较小的则被抑制,以此强化网络泛化能力。本文采用的这种非重叠池化操作,可以有效地减少噪声。

通过调整 AlexNet 的网络结构,设计了 7 种类型的车辆识别网络,如表 1 所示,C1~C6 表示第 1~6 个卷积层,S1~S5 表示第 1~5 个池化层,通过后续的实验选择性能最优的网络提取车辆特征。

表1 基于 AlexNet 的 7 种网络结构

Table 1 Seven kinds of network structures based on AlexNet

Network name	Image input	Convolution kernel	Network layer	C1	S1	C2	S2	C3	S3	C4	C5	S5	C6
I	28×28	3	8	3×3	2×2	2×2	2×2	3×3	—	2×2	2×2	2×2	—
II	48×48	5	8	5×5	2×2	5×5	2×2	4×4	—	3×3	3×3	2×2	—
III	96×96	5	8	5×5	2×2	5×5	2×2	5×5	2×2	5×5	5×5	2×2	—
IV	28×28	5	8	5×5	2×2	3×3	2×2	2×2	—	2×2	2×2	2×2	—
V	28×28	7	8	7×7	2×2	2×2	2×2	2×2	—	2×2	2×2	2×2	—
VI	28×28	3	7	3×3	2×2	2×2	2×2	3×3	2×2	2×2	—	—	—
VII	28×28	3	9	3×3	2×2	2×2	—	2×2	2×2	2×2	3×3	—	2×2

将车辆图像输入到 CNN 网络中,经过一系列的卷积、激活、池化等操作后,若由卷积层输出,则特征图 \mathbf{X} 为

$$\mathbf{X}^{(l)} = f_{\text{Relu}}[\mathbf{X}^{(l-1)} * \mathbf{K}^{(l)} + \mathbf{b}^{(l)}], \quad (1)$$

式中: l 为网络层数; f_{Relu} 为 Relu 激活函数; $\mathbf{X}^{(l-1)}$

为上一层车辆特征图;* 代表卷积运算; \mathbf{K} 为卷积核; \mathbf{b} 为偏置。若由池化层输出,则特征图 \mathbf{X} 为

$$\mathbf{X}^{(l)} = f_{\text{Relu}}\{\mathbf{w}^{(l)} \text{down}[\mathbf{X}^{(l-1)}] + \mathbf{b}^{(l)}\}, \quad (2)$$

式中: $\text{down}(\cdot)$ 表示池化函数,类似于卷积; \mathbf{w} 为权重系数。

2.3 多层特征融合与降维处理

传统卷积神经网络通过层层堆叠,从原始图像中将高层语义信息逐层抽取出来,在进行分类时,只将最后一层所映射的特征送入分类器中,而不同层级所提取的图像特征属性不同,仅考虑最后一层的特征信息,难免会遗漏少量特征,此时,将不同层级特征与全连接层特征进行融合,可以得到一个多属性特征向量,用于表达车辆多个方面的特征属性。

文献[19]中采用 CNN 提取交通标志最后 3 层特征图,得到了较好的识别特征。受此启发,本文提取了后 3 层的特征图,采用串行融合方法进行融合。融合后的特征向量 \mathbf{Z} 可表示为

$$\mathbf{Z} = [\mathbf{X}^{(l-2)}, \mathbf{X}^{(l-1)}, \mathbf{X}^{(l)}]. \quad (3)$$

为了解决融合特征维度较高、冗余信息增加的问题,采用 PCA 对融合特征向量进行降维压缩,选取最具代表性的车辆特征,以减少算法计算量,提升运算速度。PCA 是一种常用的降维技术,通过计算数据的协方差矩阵得到方差最大的方向,方差越大说明该方向信息量越大,以此作为第 1 个坐标轴,之后依次选择相互正交的方向作为新坐标,使数据从原始空间变换到降维后空间。

通过对高维车辆融合特征进行 PCA 降维,得到一个 k 维的车辆特征,由主成分的累计贡献率决定 k 的取值,结合实验,选取累计贡献率为 0.85 的前 k 个特征向量组成新的车辆特征图,在不影响分类精度的情况下降低维度。

2.4 SVM 分类识别

本文所构建的 MCP-SVM 模型使用 SVM 分类器代替 CNN 的输出层,实现车辆识别。SVM 处理线性不可分的样本时,通过非线性映射算法,将其从低维特征空间转化到高维,利用不同的核函数在高维空间中构建最优超平面,使其线性可分。将 CNN 和 SVM 结合,使其优势互补,得到的混合模型比单个分类器结果要好^[20]。

1) CNN 的学习方法基于经验风险最小化原则,在训练样本足够大的情况下,可得到一个良好的学习效果,但当训练样本不够大时,通常会导致过拟合,即所谓的泛化能力差,而结构风险最小化原则可改善这一点。结构风险最小化原则表示为

$$R_{\text{svm}}(f) \leq R_{\text{emp}}(f) + \varphi\left(\frac{n}{h}\right), \quad (4)$$

式中: $R_{\text{svm}}(f)$ 表示实际风险; $R_{\text{emp}}(f)$ 表示经验风险; $\varphi(n/h)$ 表示置信风险; n 为训练集样本数; h 为

学习机器的复杂程度; f 为模型决策函数。结构风险最小化原则将训练集数据泛化误差最小化,在保证分类精度的同时,降低学习机器的复杂程度,使整个样本集上的期望风险得以控制。因此,CNN 结合泛化能力强的 SVM 后,分类性能得到进一步提升。

2) CNN 模型通过 softmax 函数实现分类,分配一个高值给某一个节点,而给其余节点分配一个低值,结果出现两极化,导致在实际应用中纠错能力下降,而 SVM 输出是计算每一类样本的估计概率值,分类性能更为可靠,改善了 CNN 模型的纠错能力。

综上所述,本文提出的 MCP-SVM 模型,基于 AlexNet 网络对 CNN 模型的输入数据大小、卷积核以及层进行测试,据此设计 CNN 网络结构,提取网络最后 3 层特征进行融合,并利用 PCA 对融合特征降维,最后使用 SVM 分类器实现分类。

3 实验与结果分析

3.1 实验平台

本文采用的实验环境为 Ubuntu16.04 版本的 Linux 操作系统,使用 I5-7500 的处理器,主频 3.4 GHz,内存 16 GB,深度学习框架为 Caffe,软件编程环境为 Python 2.7。

3.2 评价指标

本实验主要通过识别正确率、识别时间对本文算法进行评估。识别正确率计算公式为

$$\alpha = \frac{m}{M} \times 100\%, \quad (5)$$

式中: α 为识别正确率; m 为正确识别的图片数; M 为总图片数。

记录每次实验的训练时间和测试时间,训练时间为对训练集进行特征提取的总时间,测试时间为对测试集进行分类得出识别正确率的总时间。

3.3 网络结构的设计实验

考虑到车辆应用中对实时性和准确性要求较高,利用 AlexNet 模型的分类优势,针对不同的输入数据、卷积核以及网络层数进行测试。分别从两个样本集各自随机选取 1000 张图片作为测试图片,共 16202 张训练样本(其中包含 7901 张车辆正样本,8301 张非车辆负样本),2000 张测试样本。针对表 1 中 7 种网络,进行性能测试。

经过反复实验,确定求解文件参数如下:初始学习率设为 0.001,批训练样本数量设为 32,防止过拟合权重衰减项为 0.0005,动量为 0.9,学习速率变化

因子为 0.1,模型最大迭代次数设为 8000,每训练 200 次进行一次测试,每训练 50 次在显示屏上显示

一次。实验通过 8000 次模型训练找出最大正确率 (以下实验同)。测试结果如表 2 所示。

表 2 7 种网络的分类性能

Table 2 Classification performance of seven kinds of networks

Classification network	I	II	III	IV	V	VI	VII
Training time /h	5.8	11.5	68	5.2	10	6.3	7.5
Accuracy rate /%	97.82	97.62	94.00	96.92	96.72	97.87	97.76

由表 2 可知,7 种网络都具有较好的分类性能,对比网络 I、II、III 发现,当图片大小为 28 pixel×28 pixel 时,正确率达到最高,且用时较少,说明当图像尺寸较大时,图像相邻像素点之间有较大的相似性,导致识别率下降,且训练时间增长。

在网络输入尺寸和网络层数相同(网络 I、IV、V)的前提下,当减小卷积核大小时,网络的分类性能有所提高,说明小卷积核对于车辆样本集特征提取效果更好。使用小卷积核可以捕获更多的上下文关系,并且在达到相同感受野的情况下,小卷积核比较大卷积核

所用参数更少,进而提高了网络的分类性能。

在网络输入尺寸和卷积核大小相同(网络 I、VI、VII)的前提下,网络层数为 7 时,分类性能较好。网络层数决定了网络复杂度,当数据量较大时,模型越复杂越好,但当计算资源一定时,过深的网络反而会导致分类性能变低。

经性能实验确定的 CNN 模型结构如表 3 所示,Fc1~Fc2 表示第 1~2 个全连接层。图 3 表示采用 AlexNet 模型和改进的模型在训练过程中对应的识别正确率和训练损失。

表 3 改进的 CNN 模型结构

Table 3 Structure of improved CNN model

Layer	Layer input	Convolution kernel			Convolution output	Pooling		Pooled output
		Size	Num	Step		Size	Mode	
L1(C1+S1)	28×28×3	3×3	96	1	26×26×96	2×2	Max	13×13×96
L2(C2+S2)	13×13×96	2×2	128	1	12×12×128	2×2	Max	6×6×128
L3(C3+S3)	6×6×125	3×3	256	1	4×4×256	2×2	Max	2×2×256
L4(C4)	2×2×256	2×2	256	1	1×1×256	—	—	—
L5(Fc1)	1×1×256	—	—	—	—	—	—	1024
L6(Fc2)	1024	—	—	—	—	—	—	1024
L7(Softmax)	1024	—	—	—	—	—	—	2

为了验证本文方法,将 AlexNet 模型和本文改进的 CNN 模型应用于车辆识别,结果如表 4 所示。

表 4 CNN 模型对比分析

Table 4 Comparison and analysis of CNN models

Method	Training time /h	Accuracy rate /%
Using AlexNet model	51	96.92
Using improved model	6.3	97.87

由图 3 和表 4 可以看出,改进的 CNN 模型在训练时间上比 AlexNet 模型减少 88.63% [$\approx (51 - 5.8)/51 \times 100\%$] 的情况下,识别率提高了 0.95%,且先达到峰值,说明本文对 AlexNet 模型的改进是合理有效的。

3.4 特征融合结合支持向量机的分类结果

通过融合卷积神经网络的 S3、C4、Fc2 特征后,特征向量的维数为 2304,为降低融合特征维数,采用 PCA 对 2304 维特征进行降维处理,结合 SVM 实现分类。实验使用 python 中 sklearn 模块的 PCA 算法

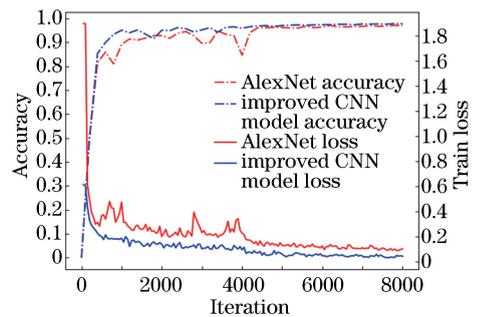


图 3 正确率和训练损失曲线对比图

Fig. 3 Comparison of accuracies and training loss curves

对融合特征实现降维操作,使用 SVC 算法库对训练数据进行训练,通过网格搜索(GridSearchCV)得到最优 SVM 参数,其中选取 RBF 核函数,惩罚系数 C 设为 1。经过测试,在本文车辆识别实验中,选取方差累积贡献率为 85% 时的主成分维数的降维效果较好。经 PCA 变换之后,原来的 2304 维融合特征变为 33 维,大幅减少了计算量。

为了验证本文方法,与文献[20]中的方法比较,设计了3组实验:

1) 文献[20]中的方法,使用SVM分类器代替CNN模型输出层进行识别。

2) MC-SVM(Multi-layer CNN fusion feature combined with SVM)是指多层CNN融合特征与SVM相结合的方法(不使用PCA),对本文改进的CNN模型S3、C4、Fc2层特征进行融合,使用SVM分类器代替CNN输出层进行识别。

3) MCP-SVM为本文算法,对本文改进的CNN模型S3、C4、Fc2层特征进行融合,采用PCA算法对融合特征进行降维处理,使用SVM分类器代替CNN输出层进行识别。

实验结果如表5所示。从表5可以看出,方法2、3识别率都高于文献[20]中的方法,这是因为CNN在逐层提取图像特征时,不同层级所提取的特征属性不同,单层特征并不能充分体现特征的多属性特点,影响了识别效果;多层特征充分利用了特征的多样性,提高了识别率。对比方法2、3发现,方法3的测试时间明显少于方法2,且识别率有所提高,说明当PCA将高维特征变换为低维特征时,有效地去除了冗余信息,减少了计算量。

表5 3种方法分类性能对比

Table 5 Comparison of classification performance of three methods

No.	Method	Accuracy rate / %	Testing time / s
1	Method in Ref. [20]	98.32	88.36
2	MC-SVM	98.72	247.51
3	MCP-SVM	98.73	13.19

3.5 与其他方法的对比

为了验证本文方法对车辆识别的有效性,运用传统方法在车辆数据集上进行对比测试,结果如表6所示。从表6可以看出,CNN模型识别率高于其他传统方法,这是因为CNN只需要简单的计算便

表6 不同方法在车辆数据集的识别率对比

Table 6 Comparison of recognition rates of different methods in vehicle datasets

Method	Accuracy rate / %	Testing time / s
Improved CNN model	97.87	184
Method in Ref. [21]	91.75	1596
Method in Ref. [4]	92.33	1046
Method in Ref. [6]	94.72	292
MCP-SVM	98.73	13

可自动提取出具有强代表性的图像特征;而本文MCP-SVM模型识别率比单一CNN模型提高了0.86%,且识别速度明显高于其他方法,这是因为通过融合多层特征和PCA降维技术避免了图片信息的遗漏,减少了计算量,再利用融合特征来训练泛化能力强的SVM,使分类性能得到明显提高。

4 结 论

为有效提取更具表达能力的车辆特征,提出了一种结合CNN多层特征和SVM的车辆识别方法。该方法利用AlexNet模型的分类优势,在其基础上设计网络模型,通过实验分析了CNN主要结构参数的选择;提取CNN模型S3、C4、Fc2层图像特征进行融合,采用PCA对融合特征降维处理,解决了传统网络仅利用端层特征进行分类导致特征不全面以及计算量大的问题;使用分类性能更可靠的SVM分类器对车辆进行分类。对比实验显示,特征提取在整个识别系统中尤为重要,对后续分类精度有很大影响,与常规CNN模型相比,本文算法能大幅提升车辆识别的准确率,缩短训练和识别时间。但由于构建的数据集还不够完善,受损严重(夜间光照不足、天气条件不良)的图像数量不足,所以在今后的研究中,需要进一步丰富数据集并优化算法模型。

参 考 文 献

- [1] Yan X P, Wu C Z, Liu Q, *et al.* Application of artificial intelligence in intelligent transportation system [C] // 12th National Academic Annual Conference of the Chinese Society of Artificial Intelligence, December 27-31, 2007, Harbin, China. Beijing: Papers Collection of the 12th National Academic Annual Conference of the Chinese Society of Artificial Intelligence, 2007: 1049-1054.
严新平, 吴超仲, 刘清, 等. 人工智能在智能交通系统中的应用[C] // 中国人工智能学会第12届全国学术年会, 12月27日—31日, 2007, 哈尔滨, 中国. 北京: 中国人工智能学会第12届全国学术年会论文集, 2007: 1049-1054.
- [2] de Jong M A, Wollstein A, Ruff C, *et al.* An automatic 3D facial landmarking algorithm using 2D Gabor wavelets [J]. *IEEE Transactions on Image Processing*, 2016, 25(2): 580-588.
- [3] Batool N, Chellappa R. Fast detection of facial wrinkles based on Gabor features using image morphology and geometric constraints [J]. *Pattern Recognition*, 2015, 48(3): 642-658.

- [4] Li X, Guo X S. A HOG feature and SVM based method for forward vehicle detection with single camera[C] // 2013 5th International Conference on Intelligent Human-Machine Systems and Cybernetics, August 26-27, 2013, Hangzhou, China. New York: IEEE, 2013: 263-266.
- [5] Chen L, Pan Z M, Mao Q Z, *et al.* HOG-LBP adaptable fused features based method for forbidden traffic signs detection[J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(2): 191-194. 陈龙, 潘志敏, 毛庆洲, 等. 利用 HOG-LBP 自适应融合特征实现禁令交通标志检测[J]. *武汉大学学报(信息科学版)*, 2013, 38(2): 191-194.
- [6] Yang X F, Yang Y. A method of efficient vehicle detection based on HOG-LBP [J]. *Computer Engineering*, 2014, 40(9): 210-214. 杨先凤, 杨燕. 一种基于 HOG-LBP 的高效车辆检测方法[J]. *计算机工程*, 2014, 40(9): 210-214.
- [7] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [8] Fan J P, Zhao T Y, Kuang Z Z, *et al.* HD-MTL: hierarchical deep multi-task learning for large-scale visual recognition[J]. *IEEE Transactions on Image Processing*, 2017, 26(4): 1923-1938.
- [9] Wang J, Wang Z, Gao C X, *et al.* DeepList: learning deep features with adaptive listwise constraint for person reidentification [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2017, 27(3): 513-524.
- [10] Zhang X N, Zhong X, Zhu R F, *et al.* Scene classification of remote sensing images based on integrated convolutional neural networks [J]. *Acta Optica Sinica*, 2018, 38(11): 1128001. 张晓男, 钟兴, 朱瑞飞, 等. 基于集成卷积神经网络的遥感影像场景分类[J]. *光学学报*, 2018, 38(11): 1128001.
- [11] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C] // *Proceedings of the 25th International Conference on Neural Information Processing Systems*, December 3-6, 2012, Lake Tahoe, Nevada. USA: Curran Associates Inc., 2012, 1: 1097-1105.
- [12] 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): 1015002. 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): 1015002.
- [13] Yuan L S, Lou M Y, Liu Y Q, *et al.* Palm vein classification based on deep neural network and random forest [J]. *Laser & Optoelectronics Progress*, 2019, 56(10): 101010. 袁丽莎, 娄梦莹, 刘娅琴, 等. 结合深度神经网络和随机森林的手掌静脉分类[J]. *激光与光电子学进展*, 2019, 56(10): 101010.
- [14] Chen Q J, Li Y, Chai Y Z. A multi-focus image fusion algorithm based on depth learning [J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071015. 陈清江, 李毅, 柴昱洲. 一种基于深度学习的多聚焦图像融合算法[J]. *激光与光电子学进展*, 2018, 55(7): 071015.
- [15] Shima Y. Image augmentation for object image classification based on combination of pre-trained CNN and SVM [J]. *Journal of Physics: Conference Series*, 2018, 1004: 012001.
- [16] Shu L, Osinski G R, McIsaac K, *et al.* An automatic methodology for analyzing sorting level of rock particles [J]. *Computers & Geosciences*, 2018, 120: 97-104.
- [17] Peng Q, Ji G S, Xie L J, *et al.* Application of convolutional neural network in vehicle recognition [J]. *Journal of Frontiers of Computer Science and Technology*, 2018, 12(2): 282-291. 彭清, 季桂树, 谢林江, 等. 卷积神经网络在车辆识别中的应用[J]. *计算机科学与探索*, 2018, 12(2): 282-291.
- [18] 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*, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 5206848.
- [19] Sun W, Du H J, Zhang X R, *et al.* Traffic sign recognition method based on multi-layer feature CNN and extreme learning machine [J]. *Journal of University of Electronic Science and Technology of China*, 2018, 47(3): 343-349. 孙伟, 杜宏吉, 张小瑞, 等. 基于 CNN 多层特征和 ELM 的交通标志识别[J]. *电子科技大学学报*, 2018, 47(3): 343-349.
- [20] Niu X X, Suen C Y. A novel hybrid CNN-SVM classifier for recognizing handwritten digits [J]. *Pattern Recognition*, 2012, 45(4): 1318-1325.
- [21] Zhang G Q, Wang B, Zheng L. Vehicle image edge detection based on Gabor filter [C] // *International Conference on Informatics, Control and Automation (ICA 2015)*, July 26, 2015, Phuket. USA: DEStech Publications, 2015: 160-163.