

# 基于深度学习模型 LeNet-5-L 的车牌识别算法

陶星珍<sup>1</sup>, 李康顺<sup>2</sup>, 刘 玥<sup>1</sup>

(1. 江西应用技术职业学院 信息工程学院, 江西 赣州 341000;

2. 华南农业大学 数学与信息学院, 广州 510642)

**摘要:** 针对车牌中汉字识别率低和识别速度慢问题, 提出一种基于深度学习的车牌识别网络 LeNet-5-L, 该网络把车牌识别分为两个阶段, 运用 OpenCV 库函数对车牌图像预处理, 结合垂直投影分割方法将车牌分割为 7 个独立字符图像, 降低了图像特征提取难度, 从而提高车牌中各个的字符识别率和整个车牌识别速度; 运用卷积神经网络解决车牌字符识别问题, 基于 LeNet-5-L 设计一种车牌字符识别网络 LeNet-5-L, 有效提高车牌中首字符汉字识别率; 实验结果表明, 该网络对车牌中各个字符的识别准确率均高于 99.97%, 单个车牌识别时间仅需 0.83 ms, 该方法有效的提高车牌识别的正确率和识别速度。

**关键词:** 深度学习; LeNet-5; 字符分割; 车牌识别

## License Plate Recognition Algorithm Based on Deep Learning Model LeNet-5-L

Tao Xingzhen<sup>1</sup>, Li Kangshun<sup>2</sup>, Liu Yue<sup>1</sup>

(1. College of Information Engineering, Jiangxi College of Applied Technology, Ganzhou 341000, China;

2. School of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China)

**Abstract:** Aiming at the problems of low recognition rate and slow recognition speed of Chinese characters in license plate, a license plate recognition network LeNet-5-L based on deep learning is proposed. This network divides license plate recognition into two stages, using OpenCV library function to preprocess license plate image, combining with vertical projection segmentation method to divide license plate into seven independent character images, so as to reduce character recognition feature dimension and improve character recognition rate and speed; using volume neural network to solve the problem of license plate character recognition, a license plate character recognition network LeNet-5-L is designed based on LeNet-5-L can effectively improve the recognition rate of the first Chinese character in the license plate. The experimental results show that the recognition accuracy of the network is higher than 99.97%, and the recognition time of a single license plate is only 0.83 ms. This method effectively improves the recognition accuracy and recognition speed.

**Keywords:** deep learning; LeNet-5; character segmentation; license plate recognition

## 0 引言

随着城市发展, 地面“停车难、乱停车”现象不断加剧, 严重影响了城市环境和交通秩序, 地下车库智能化的发展是必然趋势。智能停车场中车牌的识别是关键技术之一, 由于车牌识别系统中图像是从应用环境中获取, 受地下停车场的光照、坡度等因素的影响, 获取的图像质量不高, 使得分割出的车牌字符存在着断裂、粘连、模糊、毛刺等问题<sup>[1]</sup>, 因此如何准确地识别出车牌字符成为难点<sup>[2]</sup>。

对车牌识别问题, 主要解决方法分为两大类。第一种, 将车牌字符分割后再识别; 第二种是不分割车牌字符而直接识别。金亚飞<sup>[3]</sup>针对复杂场景中车牌识别采用了第一种

方法, 先对车牌字符添加矩形框来分割字符, 采用传统图像处理技术, 然后用卷积神经网络对字符进行识别, 识别率最高达到 97.3%。周文婷<sup>[4]</sup>仅对车牌中首字符汉字进行垂直投影分割, 其余字符不分割, 对汉字和剩余字符分别设计识别网络, 识别率达到 97.6%。张文超等<sup>[5]</sup>运用第二种方法, 提出一种车牌定位到识别通道化模型, 该模型不需要分割字符, 实现车牌的一次性识别, 通过在识别模型中共享卷积神经网络, 实现字符的多任务分类, 同时降低了对复杂背景环境对字符识别的影响; 模型应用在车牌识别中取得较好效果, 识别率达到 94.56%。曹正凤等<sup>[6]</sup>针对传统的车牌检测和识别任务, 提出一个可以同时完成车牌

收稿日期: 2020-11-18; 修回日期: 2020-12-08。

基金项目: 国家重点研发计划项目(2018YFC0831100); 国家自然科学基金项目(61773296, 61703170); 广东省重点领域研发项目(2019B020219003); 广州市对外科技合作计划项目(201907010021); 东莞市科技重大专项(2018215121005); 广州市黄埔开发区国际合作项目(2018GH09); 赣州市科技重大专项([2018]50)。

作者简介: 陶星珍(1988-), 女, 江西鄱阳人, 硕士, 讲师, 主要从事模式识别方向的研究。

李康顺(1962-), 男, 江西兴国人, 博士后, 教授, 主要从事演化计算方向的研究。

引用格式: 陶星珍, 李康顺, 刘 玥. 基于深度学习模型 LeNet-5-L 的车牌识别算法[J]. 计算机测量与控制, 2021, 29(6): 181-187.

的检测和无分割识别任务的模型,不仅可以避免误差的累积,而且可以进一步加速神经网络的收敛,提高神经网络的泛化性,识别率达到 95.4%。

对比两种识别方法,由于车牌中的字符特征各不相同,没有统一的轮廓,尤其汉字特征复杂,对于同时识别车牌所有字符,会导致识别率低,第一种方法识别率明显高与第二种。因此,本文提出一种车牌字符识别网络 LeNet-5-L,将车牌字符识别分为两个阶段,首先运用 OpenCV 库函数和垂直投影字符分割方法对车牌进行识别前的预处理,依次进行车牌图像二值化、车牌字符分割,分割后的单个字符结构特征相对简单,降低卷积神经网络特征提取难度,从而提高字符识别速度;然后运用卷积神经网络对图像进行字符识别,通过对经典字符识别网络 LeNet-5 进行修改,设计一种能完成车牌字符分类的卷积神经网络 LeNet-5-L,解决车牌中汉字字符识别率不高的问题。

## 1 目标识别算法

### 1.1 字符分割

为了提高图像中字符的识别率,对于由多字符组成的图像,一般在字符识别前先进行字符分割,即把图像中的每一个字符从图像中分离出来,降低识别难度。常用的字符分割方法有投影法、基于聚类分析法及模板匹配法等。对于车牌图像中字符分割,由于其字符排列整齐,一般采用投影分割法<sup>[7]</sup>。

投影分割方法的基本思路就是对图像进行行列扫描,横向扫描,切割出行字符,在对行字符进行总线扫描,分割出每个字符。该方法首先将图像进行二值化后,得到黑白图像,一般黑色为背景,接下来只需对图像像素灰度值按垂直方向累加。具体分割原理分为 3 个阶段:

1) 确定字符最大高度。通过水平方向投影,获取图像的直方图,分析直方图,计算出图像中字符的最大高度,以及图像边框位置。

2) 去除第一步后确定的图像边框。

3) 确定字符分割间距。通过对步骤 2) 之后的图像进行垂直方向的投影,获得直方图,计算出图像中字符间最大中心距,从而确定分割阈值。

4) 运用步骤 3) 中的分割阈值,完成图像中字符分割。

投影分割法运用广泛,许多开发工具包实现了该功能,经常被应用在车牌、轮渡等标识的分割任务中。这种分割方法程序算法简单,程序员可以运用简单的控制语句实现,同时程序简洁,系统可以快速执行,节省分割时间。

### 1.2 字符识别

字符识别技术是指从图像图形数据中自动提取字符信息,并且进行字符识别<sup>[8]</sup>。目前,字符识别方法主要有字符模板匹配法、字符特征统计法和机器学习方法等<sup>[9]</sup>。

#### 1.2.1 基于模板匹配的字符识别

模板匹配是图象识别方法中使用非常早的一种方法,由于使用简便,至今仍广泛应用。它的识别思路是:从图

像或图像区域  $I(i, j)$  中提取的若干特征向量,接着与事先构造好模板  $T(i, j)$  中对应的特征向量逐个进行比对。基于模板匹配的字符识别方法将字符识别分为三个步骤:首先将要识别字符图像处理为黑白图像,同时修改二值化后的字符图像尺寸,使其尺寸与模板库图像一致,然后与模板库中的字符一一比对,最后匹配系数最优的为最终识别结果。计算匹配系数采用如式 (1):

$$R(x, y) = \frac{\sum_{i,j} [T(i, j)I(x+i, y+j)] \sum}{\sqrt{\sum_{i,j} T(i, j)^2 \sum_{i,j} I(x+i, y+j)^2}} \quad (1)$$

其中:  $R(x, y)$  阈值的取值为  $[0, 1]$ 。

#### 1.2.2 特征统计字符识别法

基于特征统计的识别与模板匹配方法一样需要进行匹配工作,但是该方法的模板库更为复杂,需要构建的不同字符的特征集合。在进行字符识别时首先建立每个字符的特征向量,并将字符特征分类,比如外轮廓特征、笔画变化特征和内部结构特征等,需要经过大量的统计才能得到所用的特征集合,最后将字符特征与字符库特征集合进行匹配,得出待识别字符的识别结果。

#### 1.2.3 深度学习字符识别法

深度学习的强大的图像特征提取功能,近年来大量地运用在字符识别中,深度学习识别方法需要先对对象预处理之后,采用卷积操作对图像提取特征,最后对提出的特征进行组合完成字符识别。其中特征提取可以采用人工提取特征或者卷积神经网络来提取图像特征<sup>[11]</sup>。卷积神经网络是当前最适合做字符识别的一种神经网络模型,具有局部感知野和权值共享的特征,极大地减少了计算复杂度,对于简单分类或特定对象的分类,通过借用机器学习的方法,只需要比较少的数据集可以达到一个比较好的效果<sup>[12]</sup>。卷积神经网络最基本的架构包括卷积层、池化层、全连接层。

1) 卷积层。卷积运算是卷积神经网络的基石,该运算的目的是提取输入图像的不同区域的特征信息,为图像识别做好准备。网络中可以由多个卷积层,从低层到高层,分别提取浅层特征和高级特征。卷积操作过程如图 1 所示,对输入的图像进行卷积操作时,需要设计一个可训练的滤波器  $f_x$  向量,计算时用该向量乘以一个输入的对象(第一层卷积对象为输入图像向量,后面卷积对象为上一层卷积特征图向量),然后加一个偏置向量  $b_x$ ,得到卷积层  $C_x$ 。




图 1 卷积运算过程

卷积操作中卷积核大小的设计和卷积核窗口滑动的大小是关键参数<sup>[13]</sup>。卷积层计算是通过矩阵来完成操作的,步长不够时需要进行填充操作,填充大小根据情况而定。

卷积层通过权重共享降低计算量, 一个神经元就代表图像的一个特征, 一层卷积操作完成图像的一次局部特征提取<sup>[14]</sup>。卷积操作可以使特征提取效果不降低的前提下, 大大减少了参数数量, 有效防止了过拟合问题。卷积层的过滤器定义如下:

(1) 观察窗口大小  $F$  一般都是奇数 ( $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$ );

(2) 窗口移动的步长  $S$  为每次移动的像素大小, 一般为一个像素;

(3) 计算公式: 输入体积大小为  $H_1 \times W_1 \times D_1$ , 4 个参数 Filter 数量  $K$ , Filter 大小  $F$ , 步长  $S$ , 零填充大小  $P$ , 输出体积大小为  $H_2 \times W_2 \times D_2$ 。

$$H_2 = (H_1 - F + 2P) / S + 1 \quad (2)$$

$$W_2 = (W_1 - F + 2P) / S + 1 \quad (3)$$

$$D_2 = K \quad (4)$$

通过上述公式, 计算出网络中某一层通过卷积操作之后通道组成情况。

2) 池化层。池化的过程和卷积的过程有些类似, 同样采用过滤器方式, 但计算方式不同, 池化层中采用最大池化和平均池化的操作, 也就是说在一个过滤器尺寸内求矩阵的最大值或者平均值, 图像中相邻的特征总会相似, 所以可以除掉特征图中一些不重要的特征数据, 从而减少卷积操作时的参数数量<sup>[15]</sup>。深度学习中的池化操作过程如图 2 所示, 相邻的 4 个像素通过求和变为一个像素, 然后对它进行加权  $W_{x+1}$ , 同时加偏置矩阵  $b_{x+1}$ , 最后通过一种激活函数 sigmoid, 得出特征图  $S_{x+1}$ , 该特征图大小仅有原特征图的四分之一。




图 2 池化运算过程

在池化层中, 可以有效地缩小特征图矩阵的大小, 但深度一般不会改变, 从而有效减少全连接神经网络中的参数, 以达到加快计算速度和防止过拟合问题出现的效果。根据车牌特点, 有些字符之间相似, 为了提高识别准确率, 采用最大值池化, 从而保留更多的边缘特征。

3) 全连接层。卷积神经网络中的卷积层和池化层主要完成图像局部特征提取, 那么全连接层的功能就是将前面提取的局部特征进行整合, 即将前面卷积操作输出的二维特征图转化成一维向量, 达到分类效果, 实际上全连接层在整个卷积神经网络中充当“分类器”的角色<sup>[16-17]</sup>, 计算过程如图 3 所示。

图 3 中  $x_1, x_2$  为输入,  $y$  为输出,  $a_1, a_2, a_3$  为中间结果,  $w_{11}^{(1)}, w_{12}^{(1)}, w_{13}^{(1)}$  为神经元  $x_1$  到  $a_1, a_2, a_3$  的权重  $w_{21}^{(1)}, w_{22}^{(1)}, w_{23}^{(1)}$  为神经元  $x_2$  到  $a_1, a_2, a_3$  的权重  $w_{11}^{(2)}, w_{21}^{(2)}, w_{31}^{(2)}$  为神经元  $a_1, a_2, a_3$  到  $y$  的权重。根据卷积神经




图 3 全连接计算过程

网络计算公式 (5), 得到计算结果  $y$ 。

$$z = w * x + b \quad (5)$$

令:

$$x = [x_1 \quad x_2]$$

$$w^{(1)} = \begin{bmatrix} w_{11}^{(1)} & w_{12}^{(1)} & w_{13}^{(1)} \\ w_{21}^{(1)} & w_{22}^{(1)} & w_{23}^{(1)} \end{bmatrix}$$

$$w^{(2)} = [w_{11}^{(2)} \quad w_{21}^{(2)} \quad w_{31}^{(2)}]$$

则:

$$a^{(1)} = [a_1 \quad a_2 \quad a_3] = x * w^{(1)}$$

$$y = a^{(1)} * w^{(2)}$$

### 1.3 卷积神经网络 LeNet-5

LeNet-5 模型是 Yann LeCun 教授于 1998 年在论文《Gradient-based learning applied to document recognition》中提出的, 用于手写体字符识别<sup>[18]</sup>, 对 MNIST 数据集的分识别准确度可达 99.2%, 它是一种高效的字符识别卷积神经网络。LeNet-5 模型一共有 7 层<sup>[19-20]</sup>, LeNet-5 模型的架构如图 4 所示。




图 4 LeNet-5 卷积神经网络结构

由于 LeNet-5 网络包含了卷积神经网络中的卷积层, 池化层, 全链接层所有基本层, 是一种非常好的参考模型的<sup>[21]</sup>。对 LeNet-5 各层计算原理进行深入分析, 加深了对与卷积层和池化层的理解, 为设计车牌字符识别网络奠定基础, 下面对 LeNet-5 的每一层进行详细的分析。

1) 输入层 Input: 该层输入图像, 图像需要经过预处理, 将尺寸归一化为  $32 \times 32$ , 该层仅为输入识别对象, 并不是 LeNet-5 网络的计算层。

2) 卷积层 C1: 输入图像后, 经过 6 个可训练的  $5 \times 5$  卷积核进行卷积操作, 得到特征图 C1, 卷积操作过程如图 5 所示。由前面卷积原理和公式 (3) 可知, 输出特征图尺寸为  $(32-5+1) \times (32-5+1) = 28 \times 28$ , 神经元数量为  $6 \times 28 \times 28$ , 在 C1 层产生 6 个  $28 \times 28$  的特征向量图, 可训练参数有  $6 \times (5 \times 5 + 1) = 156$ , 连接数为  $(5 \times 5 + 1) \times 6 \times 28 \times 28 = 122\ 304$ , 为了加快网络训练, 需要减少连接数, 由于局部像素关联性较强, 所以神经元在空间维度进行局部连接, 同时通过统一深度切片权重共享实现连接数

大幅下降。




图 5 卷积计算原理

3) 池化层 S2: 将 C1 层中的尺寸为  $28 \times 28$  的特征图, 经过 6 个  $2 \times 2$  采样区域, 得到池化层 S2。输出尺寸为  $(28/2) \times (28/2) = 14 \times 14$ , 特征图尺寸大小为 C1 的  $1/4$ 。计算过程如图 6 所示, 首先是  $2 \times 2$  单元里的值相加, 然后再乘以训练参数  $w$ , 再加上一个偏置参数  $b$ , 然后取 sigmoid 值 (S 函数: 0-1 区间), 作为对应的该单元的值。




图 6 池化计算原理

4) 卷积层 C3: 第一次池化后得到的 S2 经过 16 个  $5 \times 5$  卷积核进行卷积操作, 得到 C3。格局公式 (3) 得到输出特征图尺寸大小为  $(14-5+1) \times (14-5+1) = 10 \times 10$ , 由于 S2 有 6 个  $14 \times 14$  的特征图, C3 有 16 个  $10 \times 10$  特征图, 这样的不对称性连接, 需要对 S2 的特征图特殊组合计算才能得到的 16 个特征图。具体如图 7 所示, C3 的前 6 个特征图 (0~5) 与 S2 层中相邻的 3 个特征图映射, 后面 6 个特征图 (6~11) 与 S2 层中相邻的 4 个特征图映射, 后面 3 个特征图 (12~14) 则与 S2 层部分不相连的 4 个特征图映射, 只有最后一个特征图 (15) 与 S2 层的所有特征图相连。

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	X			X	X		X		X	X	X		X		X	X
1	X	X			X		X	X		X	X		X	X		X
2	X	X	X				X	X	X		X		X	X		X
3		X	X	X			X	X	X	X			X	X		X
4			X	X	X		X	X	X	X			X	X		X
5				X	X	X		X	X	X			X	X		X

图 7 S2 到 C3 映射关系

5) 池化层 S4: 与 S2 层类似, C3 经过 16 个  $2 \times 2$  卷积核池化操作之后得到 S4, 该层与 C3 一样共有 16 个特征图, 每个特征图的大小为  $(10/2) \times (10/2) = 5 \times 5$ , S4 的大小为 C3 的  $1/4$ , 连接的方式与 S2 层类似。

6) 卷积层 C5: 将 S4 层的所有特征图经过 120 个  $5 \times 5$  卷积核进行卷积之后得到 C5。该层大小为  $(5-5+1) \times (5-5+1) = 1 \times 1$ , 从而达到完成向量化, 输入到全连接神经网络, 输出  $120 \times 1 \times 1$  个神经元。

7) 全连接层 F6: C5 的 120 个神经元经过最后一次卷

积操作得到 F6。计算输入向量和权重向量之间的点积, 再加上一个偏置, 结果通过 sigmoid 函数输出。

F6 层有 84 个节点, 对应于一个  $7 \times 12$  的比特图, -1 表示白色, 1 表示黑色, 这样每个符号对应的比特图中的黑白色就对应于一个编码。ASCII 编码如图 8 所示。



图 8 ASCII 编码图

8) 输出层 Output: 输出层由 10 个欧几里得径向基函数 RBF (Radial Basis Function) 核构成, 计算公式如式 (6) 所示:

$$y_i = \sum_j (x_j - w_{ij})^2 \quad (6)$$

式中,  $x$  是上一层的输入,  $y$  是 RBF 函数的输出, 代表输入字符  $x$  的编码与 ASCII 编码的差值,  $w_{ij}$  的值由  $i$  的比特图编码确定,  $i$  从 0 到 9,  $j$  取值从 0 到  $7 \times 12 - 1$ 。RBF 函数输出的值反应了识别字符与 ASCII 编码的差异大小, 如果差异越小, 也就是越接近于 0, 则为字符  $i$  的概率越大。

## 2 车牌识别算法

### 2.1 车牌识别网络

针对汉字字符识别正确率低和速度慢的问题, 本文提出一种基于深度学习的字符识别网络 LeNet-5-L, 将该字符识别网络运用在车牌识别中, 把车牌字符识别分为两个阶段。首先运用传统字符识别方法对车牌进行字符分割, 减少识别目标干扰因素, 降低特征提取难度, 从而提高字符识别率; 然后运用高效的卷积神经网络对图像提取特征, 通过对经典字符识别网络 LeNet-5 进行修改, 设计一种能完成车牌字符分类的卷积神经网络, 解决车牌中汉字识别率低的问题。网络结构如图 9 所示, 图中上面部分为车牌字符分割, 下面部分为字符识别卷积神经网络 LeNet-5-L。

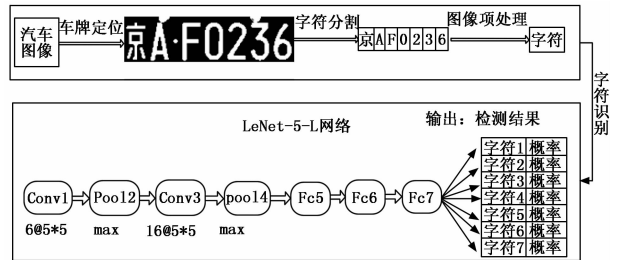


图 9 基于 LeNet-5-L 的车牌字符识别过程

### 2.2 车牌字符分割

通过观察图 10 所示的车牌可知, 车牌字符具有不同类别字符特征, 特征区分明显, 同一类别的字符变化性小, 并且底色为蓝色, 容易进行字符轮廓提取及分割。因此,

在字符识别网络的第一个阶段, 完成车牌字符分割, 为设计一个简化高效的卷积神经分类网络提供基础。



图 10 车牌字符组成结构

本文充分结合车牌自身的特点, 车牌尺寸一致、为单行字符、字符间距一致、高度一致等等, 对车牌区域进行垂直方向的投影, 利用车牌中各个字符之间的空白间隙, 将车牌中的 7 个字符图像依次切割开来。本文采用 Python + OpenCV 库完成车牌字符分割, OpenCV 库中实现了图像处理 and 计算机视觉方面的很多通用算法方法, 在程序中引用该库, 可以很方便对字符进行分割以及二值化处理, 具体流程如下。

第一步: 调用函数 imread () 读取图像, 通过函数 cvtColor () 将图像转换为灰度图像, 并用函数 imshow () 显示处理之后的图像, 处理结果如图 11 所示。



图 11 车牌灰度图

第二步: 调用库函数 threshold () 将灰度图像二值化, 设定阈值是 100, 处理结果如图 12 所示。



图 12 车牌二值化效果

第三步: 通过函数 imwrite () 保存黑白图片。

第四步: 分割字符, 经过了预处理后的图像干扰少, 易于分割, 车牌字符间大小一致, 排列规则, 本文选择垂直投影分割法, 具体分割流程如图 13 所示。

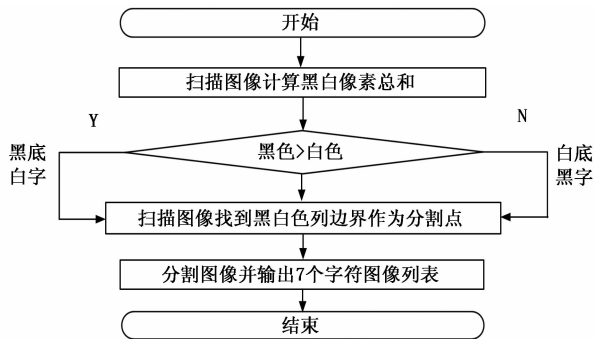


图 13 字符分割流程图

车牌字符分割后得到图 14 所示的 7 张独立图像, 这样处理后使得图片含的有效信息更加突出, 干扰信息大大降。从而降低了深度学习网络识别的难度。对于这样的输入数据, 通过深度学习理论可知, 只需要极少的数据训练一个简单的网络就能完成分类任务, 而不会出现过拟合和欠拟

合现象。



图 14 车牌字符分割

### 2.3 车牌字符识别网络 LeNet-5-L

经过前面对识别图像的预处理之后, 由于车牌中的字符种类多、汉字特征复杂, 如果继续采用传统特征提取方法, 比较困难, 为此我们选用深度学习网络结构 LeNet-5 作为我们的字符识别第二个阶段的分类网络, 运用卷积神经网络的高效特征提取能力, 提高识别效率。

LeNet-5 用于 10 个手写体数字字符识别取得了很好的效果, 它包含了深度学习的基本模块: 卷积层、池化层及全链接层, 是设计其他深度学习模型的基础, 前面我们已经对该网络进行了详细的分析。然而该网络最初是用于识别手写数字的, 输入的类别数目为 10 个, 车牌与数字相比, 除了 10 个阿拉伯数字, 还包括 31 个汉字和 24 个英文字母, 所以针对车牌字符组成与手写数字之间的区别, 对传统的 LeNet-5 进行重新构建, 设计一种结构简洁的字符识别卷积神经网络 LeNet-5-L, 用于字符分类, 如图 15 所示。




图 15 卷积神经网络 LeNet-5-L 结构

传统 LeNet-5 网络是一个 7 层卷积神经网络, 为了提高车牌中的相似字符汉和字的识别率, 结合前面介绍的卷积神经网络原理, 将卷积层 C5 改为全连接层 Fc5, 同时增加全连接层 Fc7, 卷积神经网络 LeNet-5-L 各层参数配置设计如表 1 所示。

表 1 LeNet-5-L 参数配置

层名称	参数配置
输入层	32 * 32
卷积层 Conv1	6@5 * 5, s=1
池化层 Pool2	6@2 * 2
卷积层 Conv2	16@5 * 5, s=1
池化层 Pool3	16@2 * 2
全连接层 Fc5	120@5 * 5
全连接层 Fc6	84@1 * 1
全连接层 Fc7	65@1 * 1
输出层	65 类输出

本文设计车牌字符识别网络 LeNet-5-L 将字符识别分为 3 个阶段, 首先是运用两层卷积层和两层池化层提取字符的局部特征, 然后运用三层全连接层将局部特征组

合得出全局特征，最后在输出层采用函数 softmax ( ) 输出字符分类概率值。模型用于车牌字符识别，输出互斥类别，故选用函数 softmax ( ) 对输出结果进行处理，该函数如式 (7) 所示，其中而约等于 2.718 28。

$$\text{softmax}(Z_j) = \frac{e^{z_j}}{\sum_{k=1}^k e^{z_k}} \quad \text{for } j = 1, \dots, k \quad (7)$$

对经典卷积神经网络模型 LeNet-5 进行调整，主要有如下调整：

1) 增加全连接层：考虑到实验环境和实验数据集的局限性，减少一层卷积层，防止因数据集少造成的过拟合现象。同时为了提取更多的特征信息，增加两层全连接层，目的是提高网络分类的维度，由于特征表较复杂，前面几层卷积层提出来的特征信息还无法实现线性可分，增加全连接层可以让网络在更高的维度去对待特征，从而进行分类。

2) 输出层类别增加：中国民用车牌由 65 种字符组成，而经典 LeNet-5 为手写阿拉伯数字识别问题，输出层为 10 个字符标签，所以本文将输出层更改为 65 个独立通道，输出识别字符及概率值。

### 3 实验

#### 3.1 实验环境

实验运行环境为 Win10 64 位操作系统，CPU 为英特尔 i5，主频率为 3.2 GHz，内存大小为 4 GB，采用 TensorFlow 程序框架进行程序编辑。数据集来自网络收集，总共有图片 5 771 张，每张图片均由一个字符组成，部分数据集图像如图 16 所示。



图 16 车牌字符数据样本

#### 3.2 实验过程

神经网络工作过程分为 3 个步骤：首先建立神经网络；然后，将测试数据输入到神经网络进行训练，得到需要的网络模型；最后，将测试数据输入到训练得到的网络模型中，获取识别结果。将本文设计的网络运用在车牌识别中，首先对车牌字符分割，将分割后的每一个字符输入到训练后的卷积神经网络中，输出识别结果和对应的概率值 (0~1)。实验流程如图 17 所示。

具体实验步骤如下：

1) 对数据进行分类整理，分为训练数据集和验证数据集。训练数据集图片个数为 5 539 张，验证数据集图片个数为 232 张。

2) 读取数据。首先在程序中建立图片文件路径以及对

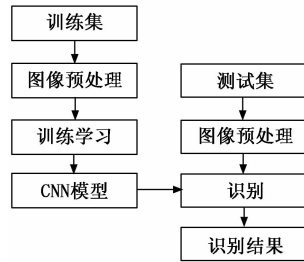


图 17 LeNet-5-L 网络模型识别过程

应标签的列表，然后使用 TensorFlow 官方接口依据列表数据按随机队列的方式读取图片。

3) 预处理数据。对于读取到的图片数据需要做两步处理。首先重新调整尺寸为 32 \* 32 \* 1，使数据能够输入到模型中。然后做增强数据处理，主要操作就是随机裁剪字符图片。这样做主要是防止数据量过少，网络训练不出来。

4) 训练模型。把处理后的数据输入给模型，启动梯度计算，并更新权值参数。通过观察正确率变化结果调整超参数，最后调试结果。在实验中设置超参数值如下：训练轮数设为 256。学习速率为 0.001。

5) 验证模型效果。把验证数据输入到训练好的模型里，得出正确率，如果跟训练时正确率相差不多，说明网络已经训练成功，训练结果如图 18 所示，整个网络训练时间约 1.5 h。

6) 对模型进行测试。读取车牌，进行预处理，二值化图像，分割出车牌中独立的 7 个字符图片，然后输入到卷积神经网络模型中，得出预测结果，如图 19 所示。

```

19890 1.0
19900 0.953125
19910 0.953125
19920 0.984375
19930 0.984375
19940 0.96875
19950 0.9375
19960 0.984375
19970 1.0
19980 0.96875
19990 1.0
FINISHED TRAINING.
>>>
京 1.0
A 1.0
F 1.0
0 0.9999995
2 0.9999994
3 0.99999857
6 1.0
19980 0.96875
19990 1.0
预测运行时间: 0.8279383182525635
>>>

```

图 18 LeNet-5-L 网络模型训练完成结果图

图 19 LeNet-5-L 网络模型车牌识别结果

为了更好地测试模型识别效果，开发了一个小型应用测试系统，其中车牌定位是基于边缘和颜色特征，具体算法如下：

1) 高斯去噪，去掉图像中不会是车牌的区域，找到图像边缘，使用开运算和闭运算让图像边缘成为一个整体，查找图像边缘整体形成的所有矩形区域，车牌就在其中一个矩形区域中；

2) 根据矩形区域长宽比在 2~5.5 之间参数要求，一一排除不是车牌的矩形区域；

3) 矫正矩形的倾斜问题，避免车牌边缘被排除；

4) 根据车牌颜色再定位，缩小边缘非车牌边界，最终得到车牌矩形。

实验选取多张车辆正前面照片作为测试对象, 将文中设计的卷积深度网络作为识别网络, 测试结果如图 20 所示。



图 20 车牌识别测试结果

### 3.3 实验结果与分析

运用本文提出的字符识别网络, 运用在车牌识别中, 通过选取 10 张不同车牌图像进行测试, 车牌中字符的识别率均高于 99.97%, 整个车牌识别平均时间为 0.83 ms。与其它识别算法比较结果如表 2 所示, 表中识别算法均为车牌的字符识别, 识别模型训练数据集同为省份汉字、字符和数字, 算法应用在车牌测试时, 选取的车牌图像不同, 但车牌规格一致, 不影响比较结果。结果表明本文针对地下停车场设计的车牌字符识别算法, 识别率高, 识别时间短, 能够实现车辆快速出入。

表 2 车牌字符识别算法比较 %

模型	文献[3]	文献[5]	文献[6]	本文
识别率	97.3	94.56	95.4	99.97

## 4 结束语

本文提出了一种基于深度学习的车牌字符识别算法, 该算法将传统字符识别方法和卷积神经网络结合, 将该算法运用在车牌识别中, 字符识别正确率均高于 99.97%, 同时识别单张车牌时间仅需 0.83 ms, 比传统字符识别速度快, 同时比端到端车牌识别方法识别率高, 从而有效解决地下停车场因车牌识别效率低而导致的车辆出入缓慢问题。本文重点设计了网络模型训练数据为分割之后的字符图片, 所以在最后的整体测试中, 整体车牌的识别情况会受到车牌定位和字符分割的影响, 将在今后的研究中继续改进。

### 参考文献:

[1] 邓嘉诚, 黄贺声, 杨林, 等. 车辆牌照识别技术现状 [J]. 现代信息科技, 2019, 3 (16): 78-83.  
 [2] 陈政. 车牌识别系统研究综述 [J]. 现代信息科技, 2019,

3 (11): 193-195.  
 [3] 金亚飞. 复杂场景下高效率车牌识别研究 [D]. 合肥: 安徽大学, 2019.  
 [4] 周文婷. 大角度倾斜的车牌识别算法研究 [D]. 北京: 北方工业大学, 2019.  
 [5] 张文超, 胡玉兰. 多级细粒度特征融合的端到端车牌识别研究 [J]. 沈阳理工大学学报, 2018, 37 (5): 24-30.  
 [6] 曹正凤, 李少丁, 王栋梁, 等. 基于深度学习的端到端车牌检测识别系统 [J]. 中国交通信息化, 2018 (9): 88-91.  
 [7] Li K, Wang H, Tang F, et al. A mobile node localization algorithm based on the angle self-adjustment model for wireless sensor networks [J]. Pattern Recognition and Artificial Intelligence, 2019, 33 (2): 1-18.  
 [8] 刘华春. 卷积神经网络在车牌识别中的应用研究 [J]. 计算机技术与发展, 2019, 29 (4): 128-132.  
 [9] 章琳, 袁非牛, 张文睿, 等. 全卷积神经网络研究综述 [J]. 计算机工程与应用, 2020, 56 (1): 25-37.  
 [10] Wang F, Zhang H, Li K, et al. A hybrid particle swarm optimization algorithm using adaptive learning strategy [J]. Information Sciences, 2018: 436.  
 [11] 李祥鹏, 闵卫东, 韩清, 等. 基于深度学习的车牌定位和识别方法 [J]. 计算机辅助设计与图形学学报, 2019, 31 (6): 979-987.  
 [12] 马李昕, 李凤坤. 一种轻量级的车牌字符识别算法 [J]. 计算机科学, 2019, 46 (s1): 239-241, 258.  
 [13] Li K S, Chen Y, et al. Improved gene expression programming to solve the inverse problem for ordinary differential equations [J]. Swarm and Evolutionary Computation, 2018, 38: 231-239.  
 [14] 邓婷. 基于特征统计的车牌非汉字字符识别方法 [J]. 广西师范学院学报 (自然科学版), 2009, 26 (4): 88-92.  
 [15] 张泽苗, 霍欢, 赵逢禹. 深层卷积神经网络的目标检测算法综述 [J]. 小型微型计算机系统, 2019, 40 (9): 1825-1831.  
 [16] 高攀. 基于卷积神经网络的车牌识别关键技术的研究与应用 [D]. 北京: 北京邮电大学, 2019.  
 [17] 张达峰. 基于深度卷积神经网络的文字识别算法研究 [D]. 贵阳: 贵州大学, 2019.  
 [18] Li K S, Liang Z Z, et al. Performance analyses of differential evolution algorithm based on dynamic fitness landscape [J]. Cognitive Informatics and Natural Intelligence, 2019, 13 (1): 36-61.  
 [19] 赵艳芹, 童朝娣, 张恒. 基于 LeNet-5 卷积神经网络的车牌字符识别 [J]. 黑龙江科技大学学报, 2019, 29 (3): 382-386.  
 [20] 李瑞辰, 姚宇峰, 蒋元华. 基于 LeNet-5 的编组站内机车车号识别系统的研究 [J]. 铁路计算机应用, 2019, 28 (9): 16-20.  
 [21] 张明军, 俞文静, 李伟滨, 等. 一种基于机器学习的车牌识别系统的设计 [J]. 计算机技术与发展, 2020, 30 (5): 216-220.