

doi:10.6041/j.issn.1000-1298.2018.S0.006

# 多类农田障碍物卷积神经网络分类识别方法

薛金林 闫嘉 范博文

(南京农业大学工学院, 南京 210031)

**摘要:** 针对农田作业场景中可能会遭遇更大生命财产损失的人和其他农业车辆等动态障碍物, 提出了一种基于卷积神经网络的农业自主车辆多类障碍物分类识别方法。搭建了包括1个输入层、2个卷积层、2个池化层、1个全连接层和1个输出层的卷积神经网络识别模型; 建立了人和农业车辆的障碍物数据库, 其中包括训练集和检测集; 利用 $5 \times 5$ 卷积核对训练样本进行卷积操作, 将所获取的特征图以 $2 \times 2$ 邻域进行池化操作, 再次经过 $3 \times 3$ 卷积核的卷积操作和 $2 \times 2$ 池化操作后, 通过自动学习获取并确定网络模型参数, 得到最佳网络模型。试验结果表明, 障碍物的检测准确率可达94.2%, 实现了较好的识别效果。

**关键词:** 农业自主车辆; 障碍物; 分类识别; 卷积神经网络

中图分类号: S24; TP391.4 文献标识码: A 文章编号: 1000-1298(2018)S0-0035-07

## Classification and Identification Method of Multiple Kinds of Farm Obstacles Based on Convolutional Neural Network

XUE Jinlin YAN Jia FAN Bowen

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

**Abstract:** In the process of obstacle avoidance control and path planning of autonomous agricultural vehicles, it is not enough to only detect obstacles. If the obstacles are classified and identified more accurately with types and danger degree, it can be served as an important basis for controlling the speed of agricultural vehicles and planning the trajectory during obstacle avoidance, and it will make the process of obstacle avoidance control and path planning of autonomous agricultural vehicles more accurate and reasonable. A convolutional neural network model was designed to realize the identification of multiple obstacles for unmanned agricultural vehicles. The model included an input level, two convolution levels, two pooling levels, a full connection level and an output level. And databases of human and agricultural vehicles were built according to MIT database and website data respectively. Then, the convolution operation was performed on the training set with  $5 \times 5$  convolution kernel and the acquired feature graphs were pooled in a  $2 \times 2$  neighborhood. After the convolution operation with  $3 \times 3$  convolution kernel and  $2 \times 2$  neighborhood pooling operation, the network model parameters were obtained by using automatic learning and the optimal network identification model was achieved. The experimental results showed that high recognition accuracy of obstacle identification was obtained, which was 94.2%.

**Key words:** autonomous agricultural vehicles; obstacles; classification and identification; convolutional neural network

## 0 引言

农业机械的自动化、智能化是现代农业发展的必然趋势, 自主导航和有效避障则是农机自动化、智能化的重要研究方向, 而对障碍物高效、准确地检测

是实现自主导航和有效避障的前提和基础<sup>[1-3]</sup>。韩永华等<sup>[4]</sup>针对基于颜色或高度信息的农田障碍物检测方法仅能实现部分障碍物检测的缺点提出了基于频率信息的检测方法, 实现了更多类障碍物的检测。姬长英等<sup>[5]</sup>针对传统双目视觉的局限性提出

收稿日期: 2018-07-15 修回日期: 2018-08-20

基金项目: 江苏省科技计划项目(BK20151436)和江苏高校“青蓝工程”项目

作者简介: 薛金林(1974—), 男, 教授, 博士, 主要从事农业车辆测控技术和智能化研究, E-mail: xuejinlin@njau.edu.cn

基于点云图的障碍物距离与尺寸的检测方法,距离和尺寸平均检测误差小于3%。CAMPOS等<sup>[6]</sup>提出了一种新的视频自动分析策略,通过时空分析来检测农业环境中的静态和动态障碍物。HERNANDEZ-ACEITUNO等<sup>[7]</sup>将Kinect传感器用于室外环境的障碍物检测,通过一系列的滤波技术将传感器获得的深度图像转换为潜在障碍物区域图,结果显示Kinect的检测结果比立体视觉技术更准确。

然而,在无人驾驶农业车辆避障控制和路径规划的实际应用过程中,仅检测到障碍物的存在是远远不够的<sup>[8]</sup>,如果能够根据障碍物的种类和危险程度对其进行更准确的分类识别,并作为规划避障路线与控制农业车辆行驶速度的重要依据,将使农业自主车辆的自主行驶过程更加精确和合理。但是,目前对于农田障碍物分类识别的研究成果较少。

卷积神经网络算法在有关领域的样本分类识别中得到了广泛应用,并普遍取得了良好的效果<sup>[9-11]</sup>。JIAO等<sup>[12]</sup>提出了基于深度卷积神经网络的高尔夫挥杆数据分类方法,试验结果表明该模型可以满足高尔夫球摆分类精度的要求并优于支持向量机方法。高震宇等<sup>[13]</sup>基于卷积神经网络设计了一套鲜茶叶分选系统,可对鲜茶叶中的单芽、一芽一叶、一芽两叶等进行类别分选,准确率不低于90%。刘德营等<sup>[14]</sup>将卷积神经网络应用于白背飞虱的分类识别中,试验表明识别准确率不低于94.14%。卢伟等<sup>[15]</sup>利用卷积神经网络进行面部特征识别从

而实现拖拉机驾驶员疲劳检测。

为了有效地识别出农田作业场景中可能会造成财产损失、威胁人身安全的作业人员和农业车辆等动态障碍物,本文提出一种基于卷积神经网络的障碍物分类识别方法,以期农业自主车辆的应用发展提供技术支撑。

## 1 卷积神经网络设计

卷积神经网络(Convolutional neural network, CNN)结构一般包含输入层、卷积层、池化层、全连接层和输出层,其中卷积层与池化层构成隐藏层。将样本图像输入后对图像的每一层用多个过滤器进行卷积操作,然后进行池化操作,提取卷积后矩阵的特殊值形成一个新的矩阵。再次对新的矩阵进行卷积和池化操作,循环往复直至所有的隐藏层完成。隐藏层中的每一次卷积与池化都会进一步提取图像不同的特征。全连接层的输入是隐藏层的输出,它会将所有的特征输入进行分类,并输出某一特定类别特征的概率,概率最大的那一类则视为图像识别的结果。对大量已经标记分类好的图片进行训练,让卷积神经网络逐渐调整参数直至找到局部最优解,最终在检测图像输入时能迅速地判断不同区域图像的种类。

根据卷积神经网络的结构特征,并结合待检测样本的特征,构建了包含输入层、二级隐藏层、一级全连接层和输出层的卷积神经网络模型,如图1所示。

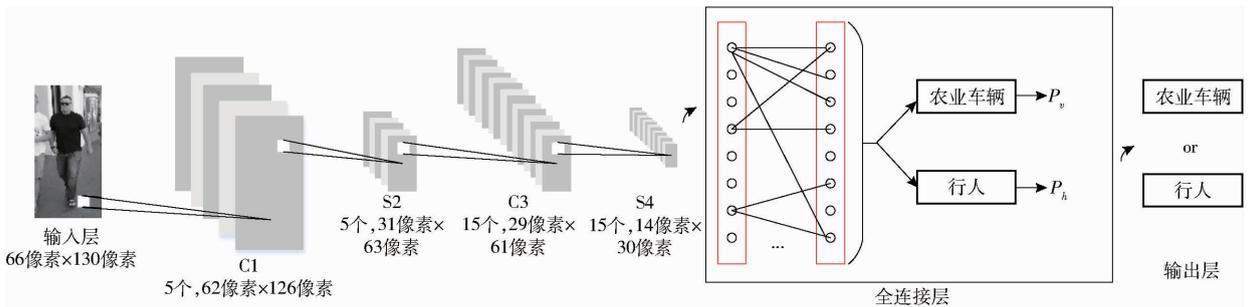


图1 卷积神经网络结构

Fig. 1 Structure of designed CNN

### (1) 输入层

输入层即为经过图像预处理后的66像素×130像素的正负样本图像。

### (2) 卷积层 C1

卷积过程分为窄卷积和宽卷积。窄卷积后的图像矩阵缩小,宽卷积则是在输入矩阵的上下和左右预先加上一行/列的零向量使卷积后的矩阵大小与输入图像一致,宽卷积对图像边缘的检测效果较好。由于本文的卷积核大小相对输入矩阵较小,故采用

窄卷积方法进行特征提取。

卷积核的大小依据输入图像矩阵的大小和经验确定。若卷积核尺寸过小,一是增加了卷积核滑动过程的运算量,另一方面可能造成特征的过度提取,对于浅层的卷积神经网络无法很好识别;若卷积核尺寸偏大,则对图像边缘的检测效果欠佳。因此,卷积层C1中卷积核依据经验设置为5×5,则第1次卷积后输出的矩阵为62×126。理论上卷积核的数目越多,提取的特征越完善,设定第1层卷积核的深

度为5,即有5个不同的卷积核,卷积后输出的特征矩阵数目为5。

在每个卷积层后一般都会立即应用一个激活函数,这是由于线性模型的表达能力不够,若只能表达线性映射,即使有再多的隐藏层,其整个神经网络和单层神经网络是等价的,只有加入了激活函数之后,深度神经网络才具有了分层的非线性映射学习能力。目前常见的是分段线性和具有指数形状的非线性函数。除了有明显缺陷的激活函数,在神经网络构建中激活函数的选择主要是依靠经验和试验,在多次训练中找出效果最好的激活函数,从而予以采用。在比较不同激活函数的收敛时间和检测准确率后,采用了ReLU函数。ReLU函数能够有效缓解梯度消失问题,减少模型训练的时间,加快模型的收敛速度,从而直接以监督的方式训练深度神经网络,无需依赖无监督的逐层预训练,ReLU函数的数学表达为

$$f(x) = \begin{cases} 0 & (x \geq 0) \\ x & (x < 0) \end{cases} \quad (1)$$

尽管 $x < 0$ 时该函数依然会出现饱和问题,但是在大于0时却不存在这样的问题,从而缓解梯度消失问题。

### (3) 池化层 S2

池化的本质就是采样,既可以看做是对上层数据进行压缩,也可以看成对特殊数据的选取。由于使用池化可以看成是增加了一个很强的先验,即该层的函数必须具有对少量平移的不变性,所以各池化方法大同小异。本文的训练中采用最常使用的最大池化法提取特征,即找出图像中某个搜索区域的局部最大值并将该值作为输出结果,池化窗口为 $2 \times 2$ ,因此共输出5个 $31 \times 63$ 的特征矩阵。

### (4) 卷积层 C3

卷积层C3的卷积核设置为 $3 \times 3$ ,卷积核数目为3,第2次卷积后输出 $29 \times 61$ 的15个特征矩阵。

### (5) 池化层 S4

池化层S4同样使用 $2 \times 2$ 的池化窗口进行最大池化,输出15个 $14 \times 30$ 的特征矩阵,将所有的矩阵转换为向量,输入至全连接层。

### (6) 全连接层

全连接层实际上是个分类器。完全连接层观察上一层的输出,其表示了更高级特征的激活映射,并确定这些特征与哪一分类最为吻合,并输出各类可能的概率。

例如,如果该程序预测某一图像的内容为狗,那么激活映射中的高数值便会代表一些爪子或4条腿之类的高级特征。同样地,如果程序测定某一图片

的内容为鸟,激活映射中的高数值便会代表诸如翅膀或鸟喙之类的高级特征。大体上来说,完全连接层观察高级特征和哪一分类最为吻合和拥有怎样的特定权重,因此当计算出权重与先前层之间的点积后,将获得不同分类的正确概率。

### (7) 输出层

输出层直接输出分类识别结果。在本分类识别任务中,识别种类有行人和农业车辆2种,所以输出层有2个输出。

## 2 卷积神经网络的训练

### 2.1 样本构建与标定

#### 2.1.1 样本构建

依据所需识别的障碍物种类构建样本数据库,数据库中应该包含训练样本、检测样本和负样本。本文中的行人样本来自MIT数据库,包含了人的正面、背面和各个侧面,训练样本共900幅,测试集样本200幅。农业车辆的样本来自网络,共700幅,其中500幅为训练样本,200幅为检测样本,农业车辆样本集中包含了车辆各个角度的照片。图2为数据库中部分样本集。为了便于训练,所有的正样本均设置为66像素 $\times$ 130像素,农业车辆样本与行人样本像素一致。



图2 数据库部分正样本

Fig. 2 Part positive samples in database

由于在训练时有较多背景的干扰,包括路面、树木、墙体、电线杆等,不同行人和车辆的背景差异性也较大,这样在卷积时会产生较多的冗余特征提取,也容易对训练结果造成影响。因此,为了降低仅仅训练人和农业车辆的正样本集带来的检测误差率,在训练时还需加入负样本集。负样本集包含了各类型的农田背景和常见的景物,并且在负样本的图像中没有其他行人或农业车辆。图3为数据库中的部分负样本,负样本共1000幅,负样本的分辨率与正样本一致。

MIT数据库和百度图片提供了本文研究所需的样本数据,数据丰富、全面且来源于真实应用场景,采用该数据的效果不亚于现场采集的人和农业车辆

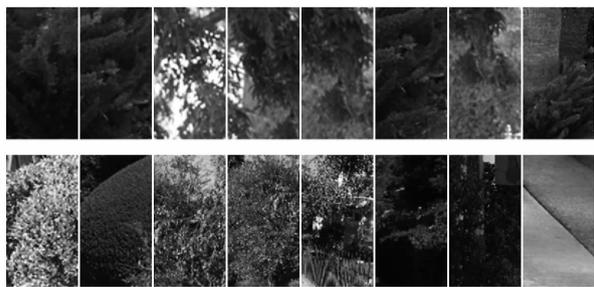


图3 数据库部分负样本

Fig.3 Part negative samples in database

数据。

### 2.1.2 样本标定

首先对数据库中所有的正负样本进行归一化处理。正负样本都设置为66像素×130像素,但在实际训练时效率较为低下,这是由于输入彩色图像时,彩色图像有R、G、B3个色彩空间,所以第1个卷积层中的所有卷积核也同样是三维的,在卷积处理时计算量为灰度图像的3倍。因此将所有的图像样本用均值处理的方法转换为灰度图像,这样既能满足卷积与池化时特征提取的需要,训练的效率也较RGB图像大大提高。

然后对数据库中所有样本添加标签。本研究将行人障碍物的标签设置为[1, 0],将农业车辆障碍物的标签记为[0, 1],所有负样本的标签均为[0, 0]。每个标签位置与图像一一对应,即对应数据库中的样本集生成标签集,数据样本集与检测样本集分开放置。

## 2.2 网络训练算法

训练卷积神经网络本质上就是让网络变得有效,在第1次训练时卷积核中的权重取值是随机的,范围在-1到1之间,训练的目的是为了优化并找到最优的权重。求解最优权重的过程就是在获得真实值与预测值的残差后,对每一个权重计算其梯度(求偏导),当梯度逐渐减小时,残差就逐渐趋近最小值。当残差局部达到最小后,可以视为实现了较为高效的神经网络模型。

神经网络的反向传播大致可以分为4个部分,分别为前向传导、损失函数、反向传导以及权重更新。在前向传导阶段,假设第 $l$ 层是卷积层, $l+1$ 层是池化层,则前向传导过程为

$$\mathbf{x}^l = f(\mathbf{u}^l) \quad (2)$$

$$\text{其中 } \mathbf{u}^l = \mathbf{W}^l \mathbf{x}^{l-1} + \mathbf{b}^l \quad (3)$$

式中  $\mathbf{x}^l$ ——第 $l$ 层的输出

$f$ ——选择的激活函数

$\mathbf{W}^l$ ——当前权重

$\mathbf{b}^l$ ——当前偏重

$\mathbf{u}^l$ ——第 $l$ 层输入

则第 $l$ 层的第 $j$ 个卷积核提取的特征图为

$$\mathbf{X}_j^l = f\left(\sum_{i \in M_j} \mathbf{X}_i^{l-1} K_{ij}^l + \mathbf{b}_j^l\right) \quad (4)$$

式中  $M_j$ —— $l$ 层卷积中的卷积核

$K_{ij}^l$ ——当前层中第 $j$ 个卷积核对应的第 $i$ 个卷积窗口

$\mathbf{b}_j^l$ ——第 $j$ 个卷积核的偏置项

定义损失函数的形式为平方差函数

$$E^n = \frac{1}{2} \sum_{k=1}^c (t_k^n - y_k^n)^2 = \frac{1}{2} \|\mathbf{t}^n - \mathbf{y}^n\|_2^2 \quad (5)$$

式中  $E^n$ —— $n$ 个图片样本进行训练的误差

$c$ ——全连接层输出的个数,也是需要分类的类别数目

$t$ ——样本的标签值,也就是样本的实际值

$y$ ——大量样本训练所输出的结果值

权重的调整方向可表示为

$$\nabla \mathbf{W}^l = -\eta \frac{\partial E}{\partial \mathbf{W}^l} \quad (6)$$

$$\text{其中 } \frac{\partial E}{\partial \mathbf{W}^l} = \mathbf{x}^{l-1} (\boldsymbol{\delta}^l)^T \quad (7)$$

$$\boldsymbol{\delta} = \frac{\partial E}{\partial \mathbf{b}} = \frac{\partial E}{\partial \mathbf{u}} \frac{\partial \mathbf{u}}{\partial \mathbf{b}} = \frac{\partial E}{\partial \mathbf{u}} \quad (8)$$

式中  $\eta$ ——学习率  $\boldsymbol{\delta}$ ——残差

在这里需要注意的是,学习率是由操作者所输入的经验参数。数值较大的学习率表示权重更新的幅度更大,这样可能在训练时会花费更少的时间去收敛得到最优权重。但学习速率过高往往会导致权重更新的幅度过大,很容易跳过而无法寻找到最优值。

卷积神经网络中第 $l$ 层的残差为

$$\boldsymbol{\delta}^l = (\mathbf{W}^{l+1})^T \circ f'(\mathbf{u}^l) \quad (9)$$

式中, $\circ$ 表示每个元素相乘。

对应的,全连接层 $L$ 的残差为

$$\boldsymbol{\delta}^L = f'(\mathbf{u}^L) \circ (\mathbf{y}^n - \mathbf{t}^n) \quad (10)$$

卷积神经网络中包含了不同类型的层级,所以式(9)可写为

$$\boldsymbol{\delta}^l = (\mathbf{W}^{l+1})^T \boldsymbol{\delta}^{l+1} \circ f'(\mathbf{u}^l) \quad (11)$$

假设池化层为第 $l$ 层,那么上一层为卷积层,下一层 $l+1$ 也为卷积层,则当前层的与第 $j$ 个卷积核对应的残差公式为

$$\boldsymbol{\delta}_j^l = \boldsymbol{\beta}_j^{l+1} (f'(\mathbf{u}_j^l) \circ \text{up}(\boldsymbol{\delta}_j^{l+1})) \quad (12)$$

式中  $\boldsymbol{\beta}$ ——权值 $\mathbf{W}$ 的取值

$\text{up}(\cdot)$ ——克罗内克积

同样,如果当前层是卷积层,此时的卷积层会对前一层的池化层做一个卷积运算,所以反向传导求残差时应当将维度扩展回去,即

$$\boldsymbol{\delta}_j^l = f'(\mathbf{u}_j^l) \circ \text{conv2}(\boldsymbol{\delta}_j^{l+1}, g(K_j^{l+1})) \quad (13)$$

以上简单地描述了本文卷积神经网络训练的过程。卷积网络训练的目的是为了不断地计算误差累积损失值,以便获得最小化的损失函数。实际上,大部分神经网络在训练时无法获得全局最小值,这是由于在求得局部最小值后,梯度已经抑制到最低,很难再进行下一步梯度下降算法,但往往局部最小值已经能实现较好的检测效果。

### 2.3 选定训练参数

除此之外,在训练卷积神经网络时,还有3个重要的参数需要不断地调整以达到较好的训练结果:

(1)学习率  $\eta$ 。求解神经网络的最优权重时,主要依靠梯度下降搜索算法,这些算法会初始化一个解,然后在这个解的基础上确定一个方向,以设定的步长依次搜索,逐渐下降找到最优的解。

(2)批训练的样本数量。每次训练完一批样本后就会更新一次权重值,需要注意的是,每批次的样本数量不能太少,不然很容易造成过拟合。本研究批训练样本数量  $B = 40$ 。

(3)迭代次数。迭代次数为神经网络训练一个完整样本集的次数,每迭代一次就进行一次优化,一次迭代相当于训练了一次样本,那么完整的训练次数为迭代次数与样本数和批训练样本比的乘积。

## 3 试验结果与分析

合成的数据库中,正样本共1400幅,负样本1000幅,测试集400幅,试验环境为Matlab 2014b,在确定卷积核大小、卷积核个数、池化窗口尺寸后,改变学习率与迭代次数进行最优化试验。学习率控制梯度下降的步长,一般来说,学习率会依据迭代次数的增加适当调小,在训练中,若学习率过大,则有可能因步长过大而找不到最优解;若学习率过小,可能会造成损失函数迟迟无法收敛的问题。在对样本库进行学习时,首先设置一个较大的迭代次数,本研究中迭代次数为500,在相同的迭代次数下对不同学习率的模型进行试验,试验结果如图4所示。

对样本库中的训练集进行分析,负样本占据了全部样本的41.7%,因此,当神经网络模型没有实现正确的训练时,错误率达到41.7%。当学习率过大时,出现了超调现象,权值在极值点两端不断发散或剧烈振荡,随着迭代次数的增加,识别的错误率并不会减少,模型也得不到训练;当学习率为0.0001和0.00001时,由于步长过小产生了梯度消失的问题,寻找不到梯度下降的方向,随着迭代次数的增加损失也基本不变;当学习率为0.001时,显然迭代全部完成后模型还没有实现收敛,但学习率为0.01时

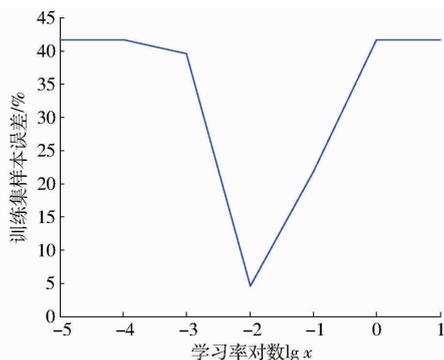


图4 训练集中学习率与错误率关系

Fig. 4 Relationship between learning rate and error rate of training set

就已经有了较好的收敛效果,因此,在500次迭代以内选取0.01的学习率较为合适。

在确定学习率后,使用测试集对训练结果进行分析,以寻找较优的迭代次数。图5为不同迭代次数的检测准确率情况。

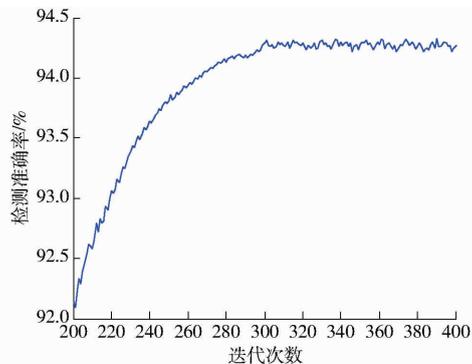


图5 不同迭代次数下的检测准确率

Fig. 5 Recognition accuracy with different iteration numbers

由图5知,在进行了300次左右迭代检测准确率就已经不发生大的改变,而在一定的范围内波动。如果再进行多次迭代,会导致过拟合,此时卷积神经网络在训练集中的检测效果较好,但是在测试集中准确率就没有那么高。一般在模型每次迭代后,向后的 $N$ 次迭代(一般 $N$ 为10)的准确率差值小于一定的阈值,即可视为模型收敛,已经获得了较优的识别效果。因此,本研究的迭代次数设置为320次,测试集的检测准确率为94.2%。

为对比卷积神经网络的障碍物检测精准度,使用同样的样本对方向梯度直方图(Histogram of oriented gradient, HOG)和支持向量机(Support vector machine, SVM)进行训练。HOG + SVM分类器相结合的方法,广泛应用于行人<sup>[16]</sup>、车辆<sup>[17]</sup>、交通标识<sup>[18]</sup>等各种对象的检测与识别,具有较高的正确率和鲁棒性以及较大的计算量和较慢的检测速度<sup>[19-20]</sup>。图6为HOG + SVM检测结果,表明其样本测试集的检测准确率为89.6%,明显小于卷积神

经网络的检测准确率。

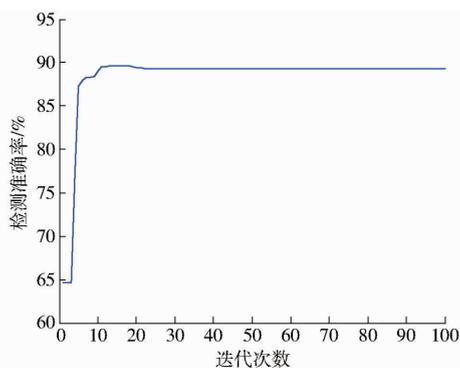


图6 HOG + SVM 检测准确率

Fig.6 Recognition accuracy of HOG + SVM

## 4 结论

(1) 为了实现农田多类动态障碍物的分类识别,设计了一种模型。试验表明卷积神经网络模型结构设计及参数设定合理,训练后的模型对农业车辆和行人这2种障碍物的检测准确率可达到94.2%,实现了较好的识别效果。

(2) 由于行人和农业车辆各自特征相对明显,一定程度上降低了算法识别难度。因此需要对田间各种类型障碍物图像进行收集,建立障碍物样本库,构建更深层次的神经网络模型,实现多类障碍物的快速检测与识别。

## 参 考 文 献

- 何勇, 蒋浩, 方慧, 等. 车辆智能障碍物检测方法及其农业应用研究进展[J]. 农业工程学报, 2018, 34(9): 21-32.  
HE Yong, JIANG Hao, FANG Hui, et al. Research progress of intelligent obstacle detection methods of vehicles and their application on agriculture[J]. Transactions of the CSAE, 2018, 34(9): 21-32. (in Chinese)
- 袁文涛, 刘卉, 胡书鹏. 面向自动驾驶拖拉机的农田障碍物识别研究[J]. 农机化研究, 2018, 40(10): 247-251.  
YUAN Wentao, LIU Hui, HU Shupeng. Farmland obstacle identification for automatic navigation tractor[J]. Journal of Agricultural Mechanization Research, 2018, 40(10): 247-251. (in Chinese)
- JAMES G B, KANNA R. Robotics in remote and hostile environments[J]. Science, 2007, 318(5853): 1098-1102.
- 韩永华, 汪亚明, 康锋, 等. 基于小波多分辨率分解的农田障碍物检测[J/OL]. 农业机械学报, 2013, 44(6): 215-221.  
[http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20130637&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20130637&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2013.06.037.  
HAN Yonghua, WANG Yaming, KANG Feng, et al. Detection of obstacles in farmland based on wavelet multi-resolution transform[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(6): 215-221. (in Chinese)
- 姬长英, 沈子尧, 顾宝兴, 等. 基于点云图的农业导航中障碍物检测方法[J]. 农业工程学报, 2015, 31(7): 173-179.  
JI Changying, SHEN Ziyao, GU Baoxing, et al. Obstacle detection based on point clouds in application of agricultural navigation[J]. Transactions of the CSAE, 2015, 31(7): 173-179. (in Chinese)
- CAMPOS Y, SOSSA H, PAJARES G. Spatio-temporal analysis for obstacle detection in agricultural videos[J]. Applied Soft Computing, 2016, 45: 86-97.
- HERNANDEZ-ACEITUNO J, ARNAY R, TOLEDO J, et al. Using kinect on an autonomous vehicle for outdoors obstacle detection[J]. IEEE Sensors Journal, 2016, 16(10): 3603-3610.
- 黄如林, 梁华为, 陈佳佳, 等. 基于激光雷达的无人驾驶汽车动态障碍物检测、跟踪与识别方法[J]. 机器人, 2016, 38(4): 437-443.  
HUANG Rulin, LIANG Huawei, CHEN Jiajia, et al. Lidar based dynamic obstacle detection, tracking and recognition method for driverless cars[J]. Robot, 2016, 38(4): 437-443. (in Chinese)
- 赵凯旋, 何东健. 基于卷积神经网络的奶牛个体身份识别方法[J]. 农业工程学报, 2015, 31(5): 181-187.  
ZHAO Kaixuan, HE Dongjian. Recognition of individual dairy cattle based on convolutional neural networks[J]. Transactions of the CSAE, 2015, 31(5): 181-187. (in Chinese)
- 何春燕. 基于卷积神经网络的车行环境多类障碍物检测与识别[D]. 重庆: 重庆邮电大学, 2017.  
HE Chunyan. Study on multi-obstacles detection and recognition under the car driving environment based on convolutional neural network[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2017. (in Chinese)
- 王科俊, 赵彦东, 邢向磊. 深度学习在无人驾驶汽车领域应用的研究进展[J]. 智能系统学报, 2018, 13(1): 55-69.  
WANG Kejun, ZHAO Yandong, XING Xianglei. Deep learning in driverless vehicles[J]. CAAI Transactions on Intelligent Systems, 2018, 13(1): 55-69. (in Chinese)
- JIAO Libin, WU Hao, BIE Rongfang, et al. Multi-sensor golf swing classification using deep CNN[J]. Procedia Computer Science, 2018, 129: 59-65.
- 高震宇, 王安, 刘勇, 等. 基于卷积神经网络的鲜茶叶智能分选系统研究[J/OL]. 农业机械学报, 2017, 48(7): 53-58.  
[http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170707&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170707&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2017.07.007.  
GAO Zhenyu, WANG An, LIU Yong, et al. Intelligent fresh-tea-leaves sorting system research based on convolution neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(7): 53-58. (in Chinese)
- 刘德营, 王家亮, 林相泽, 等. 基于卷积神经网络的白背飞虱识别方法[J/OL]. 农业机械学报, 2018, 49(5): 51-56.

- [http://www.jcsam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20180506&journal\\_id=jcsam](http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180506&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2018.05.006.
- LIU Deying, WANG Jialiang, LIN Xiangze, et al. Automatic identification method for *Sogatella furcifera* based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(5):51-56. (in Chinese)
- 15 卢伟, 胡海阳, 王家鹏, 等. 基于卷积神经网络面部图像识别的拖拉机驾驶员疲劳检测[J]. 农业工程学报, 2018, 34(7):192-199.
- LU Wei, HU Haiyang, WANG Jiapeng, et al. Tractor driver fatigue detection based on convolution neural network and facial image recognition[J]. Transactions of the CSAE, 2018, 34(7):192-199. (in Chinese)
- 16 GAVRIILIDIS A, VELTEN J, TILGNER S, et al. Machine learning for people detection in guidance functionality of enabling health applications by means of cascaded SVM classifiers[J]. Journal of the Franklin Institute, 2018,355(4):2009-2021.
- 17 马蓓蓓. 基于 HOG 特征的车辆检测技术研究[D]. 广州: 华南理工大学, 2015.
- MA Beibei. The technology research of vehicle detection based on HOG features[D]. Guangzhou: South China University of Technology, 2015. (in Chinese)
- 18 GREENHALGH J, MIRMEHDI M. Real-time detection and recognition of road traffic signs[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(4):1498-1506.
- 19 徐渊, 许晓亮, 李才年, 等. 结合 SVM 分类器与 HOG 特征提取的行人检测[J]. 计算机工程, 2016, 42(1):56-60,65.
- XU Yuan, XU Xiaoliang, LI Cainian, et al. Pedestrian detection combining with SVM classifier and HOG feature extraction[J]. Computer Engineering, 2016, 42(1): 56-60, 65. (in Chinese)
- 20 吴迪, 蔡晓东, 华娜, 等. 基于 HOG 和 SVM 的级别自适应车型识别算法[J]. 桂林电子科技大学学报, 2016, 36(1): 23-28.
- WU Di, CAI Xiaodong, HUA Na, et al. A level-adaptive algorithm for vehicle types recognition algorithm based on HOG and SVM[J]. Journal of Guilin University of Electronic Technology, 2016, 36(1):23-28. (in Chinese)

(上接第 7 页)

- 10 贾楠, 杜松怀, 李蔚, 等. 我国自动化奶牛饲喂技术及装备研究进展[J]. 中国畜牧杂志, 2015, 51(22):51-55.
- JIA Nan, DU Songhuai, LI Wei, et al. Progress in automatic feeding equipment for dairy cattle[J]. Chinese Journal of Animal Science, 2015, 51(22):51-55. (in Chinese)
- 11 焦盼德, 贺成柱, 杨军平. 奶牛智能推料机器人的研制[J]. 中国农机化学报, 2018,39(1):74-77.
- JIAO Pande, HE Chengzhu, YANG Junping. Development and manufacture of intelligent push feed robot for cows[J]. Journal of Chinese Agricultural Mechanization, 2018,39(1):74-77. (in Chinese)
- 12 杨亮, 潘晓花, 郑姗姗, 等. 奶牛饲喂自动机电控制系统的设计与试验[C]//中国畜牧兽医学会信息技术分会学术研讨会, 2017.
- 13 高振江, 郭跃虎, 蒙贺伟, 等. 自走式奶牛精确饲喂机控制系统[J/OL]. 农业机械学报, 2012, 43(11):226-230. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?file\\_no=20121142&flag=1](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20121142&flag=1). DOI: 10.6041/j.issn.1000-1298.2012.11.042.
- GAO Zhenjiang, GUO Yuehu, MENG Hewei, et al. Design of self-propelled precise feeding machine control system for single dairy cow[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(11):226-230. (in Chinese)
- 14 蒙贺伟, 郭跃虎, 高振江, 等. 双模自走式奶牛精确饲喂装备设计与试验[J/OL]. 农业机械学报, 2013, 44(2):52-56. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?file\\_no=20130211&flag=1](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20130211&flag=1). DOI:10.6041/j.issn.1000-1298.2013.02.011.
- MENG Hewei, GUO Yuehu, GAO Zhenjiang, et al. Design and experiment on dual-mode self-propelled precise feeding equipment for dairy cow[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(2):52-56. (in Chinese)
- 15 吴刚, 王晨, 李世雄, 等. 一种饲草推送装置: 201510606968.3 [P]. 2018-02-09.
- 16 谭彧, 李景行, 李宝胜, 等. 一种基于摩擦随动回转的饲草推送装置: 201710067992.3 [P]. 2017-06-13.
- 17 吴刚, 王晨, 李世雄, 等. 一种饲草推送器的自动安全充电系统: 201510671051.1 [P]. 2018-03-13.
- 18 仇成群, 刘成林, 沈法华, 等. 基于 Matlab 和模糊 PID 的汽车巡航控制系统设计[J]. 农业工程学报, 2012, 28(6): 197-202.
- QIU Chengqun, LIU Chenglin, SHEN Fahua, et al. Design of automobile cruise control system based on Matlab and fuzzy PID [J]. Transactions of the CSAE, 2012, 28(6): 197-202. (in Chinese)
- 19 刘浩蓬, 龙长江, 万鹏, 等. 植保四轴飞行器的模糊 PID 控制[J]. 农业工程学报, 2015,31(1): 71-77.
- LIU Haopeng, LONG Changjiang, WAN Peng, et al. Fuzzy self-adjusting proportion integration differentiation for eppo quadcopter[J]. Transactions of the CSAE, 2015,31(1): 71-77. (in Chinese)
- 20 苏中滨, 章宗鑫, 马晨茗, 等. 模糊 PID 控制无人自旋旋翼机飞行姿态仿真[J]. 东北农业大学学报, 2018, 49(2):64-72.
- SU Zhongbin, ZHANG Zongxin, MA Chenming, et al. Simulation of fuzzy PID control on flight attitude of unmanned autogyro [J]. Journal of Northeast Agricultural University, 2018, 49(2): 64-72. (in Chinese)