doi:10.6041/j.issn.1000-1298.2018.11.004

# 基于卷积网络和哈希码的玉米田间杂草快速识别方法

姜红花[1]　王鹏飞[1]　张　昭[2]　毛文华[3]　赵　博[3]　齐　鹏[4]

(1. 山东农业大学信息科学与工程学院, 泰安 271018; 2. 宝鸡文理学院电子电气工程学院, 宝鸡 721016;
3. 中国农业机械化科学研究院, 北京 100083; 4. 山东永佳动力股份有限公司, 临沂 276000)

**摘要**: 为提高作物与杂草识别的准确性,结合深度卷积网络强大的特征提取能力和哈希码便于存储和快速检索的特点,提出了基于深度卷积网络和二进制哈希码的田间杂草快速识别方法。结合预训练的多层卷积网络,增加二进制哈希层构建杂草识别模型,并利用所采集的杂草数据集对模型进行 fine-tuning。所提出的二进制哈希层可有效地将高维杂草特征进行压缩,以便于实际田间杂草特征的存储和后续计算。在进行杂草识别时,利用训练好的模型提取输入图像的全连接层特征码和哈希特征码,与数据库中的全连接层特征码和哈希特征码进行对比,分别计算其汉明距离与欧氏距离,找出与其最相似的 $K$ 幅图像,统计这 $K$ 幅图像的标签,将其归入频率最高的一类,以达到分类识别的目的。通过对比不同卷积层数和不同二进制哈希码长度对杂草识别的影响,最终确定了包含 4 层卷积网络和 128 位哈希码长度的杂草识别模型。试验结果表明,本研究方法田间杂草识别准确率可达 98.6%,并且损失函数稳定性相较于普通模型有所提高;同时,在其他杂草数据集上也有良好的表现,准确率达到 95.8%,说明该方法具有通用性。实地测试表明,利用本文提出的模型进行杂草识别,对靶喷雾杂草施药率可达 92.7%,能够有效减少农药浪费,适用于精准喷雾。

**关键词**: 杂草识别; 卷积神经网络; 哈希码; 深度学习; 特征压缩

**中图分类号**: S451.0　　**文献标识码**: A　　**文章编号**: 1000-1298(2018)11-0030-09

# Fast Identification of Field Weeds Based on Deep Convolutional Network and Binary Hash Code

JIANG Honghua[1]　WANG Pengfei[1]　ZHANG Zhao[2]　MAO Wenhua[3]　ZHAO Bo[3]　QI Peng[4]

(1. *College of Information Science and Engineering*, *Shandong Agricultural University*, *Taian* 271018, *China*
2. *College of Electron and Electricity Engineering*, *Baoji University of Arts and Sciences*, *Baoji* 721016, *China*
3. *Chinese Academy of Agricultural Mechanization Sciences*, *Beijing* 100083, *China*
4. *Shandong Yongjia Power Co.*, *Ltd.*, *Linyi* 276000, *China*)

**Abstract**: Corn is one of the main grain crops in China and its production accounts for more than 20% of the World's corn production. Weed is one of the most important factors influencing maize yield. Effective recognition method of cron and weed can improve corn quality and production accounts. At present, pesticide spraying is the main way of removing weed in China. Excessive spraying of pesticides brings problems such as environmental pollution and food safety, and therefore precise spraying is the key of weeding to reduce the amount of pesticides and increase the utilization of pesticides. Precise application of pesticides is based on accurate identification of weeds, researchers at home and abroad have done a lot of research. Most existing weed identification methods rely on manually selected weed features, such as shape, texture, etc., which takes longer time to identify the image, and the accuracy of identification still needs further improvement. The deep learning method was used to achieve automatic extraction of weed image features without relying on artificial feature screening, and combined the binary Hash code to compress high-dimensional weed feature data to achieve rapid weed identification and provide information support for subsequent field drug spraying. In order to improve accuracy of crop and weed identification,

收稿日期: 2018-05-17　修回日期: 2018-06-13

**基金项目**: 山东省重点研发计划项目(2015GNC112004)、国家重点研发计划项目(2017YFD0700500)、山东省自然科学基金项目(ZR2018MC017)和山东农业大学智能化农业装备研发项目(24132)

**作者简介**: 姜红花(1971—),女,副教授,主要从事物联网与自动控制研究,E-mail: j_honghua@sdau.edu.cn

**通信作者**: 毛文华(1975—),女,研究员,主要从事农业电气化与自动化研究,E-mail: mwh-924@163.com

combining with the strong feature extraction capabilities of the deep convolutional network and the ease of storage and fast retrieval of the Hash code, a fast field weed identification method was proposed based on the deep convolutional network and binary Hash code. A pre-trained multilayer convolutional neural network was used to construct a weed identification model with a binary Hash layer, and the model was fine-tuned with the collected weed data set. The binary Hash layer proposed could effectively compress the high-dimensional weed image features to facilitate the storage and subsequent calculation of the high-dimensional weed image features. During tests of weed identification, the trained model was used to extract the full-connection layer feature codes and binary Hash codes of the input image, and then compared with the full-connection layer feature codes and binary Hash codes stored in the database to calculate the Hamming distance and the Euclidean distance. After that, the most similar *K* images could be found out according to last step's results. Finally, the labels' frequency of the *K* images was counted and the original image was classified into the highest frequency category of label to achieve the purpose of weed identification. The effects of different layers of convolutional networks and different length binary Hash code on weed identification were compared, and finally the weed identification model was determined, which included four layers convolutional neural network and 128-bit binary Hash code. The experimental results showed that the method proposed could achieve 98.6% accuracy in field weed identification, and the loss function stability was improved compared with the ordinary model. At the same time, it also performed well on other weeds datasets with an accuracy of 95.8%, which meant that the proposed method was universal. The research results could provide reference for precision weeding. The experiment carried out in corn field showed that the method could achieve 92.7% accuracy, and it could effectively reduce pesticide waste which was suitable for precision spray.

**Key words**: weed identification; convolution neural network; Hash code; deep learning; feature compression

## 0　引言

田间杂草是影响农作物产量的重要因素[1-2]。目前我国主要采用喷洒农药的方式进行除草作业，农药过量喷洒带来环境污染、食品安全等一系列问题[3]。因此，实施精准喷药[4]是解决农药过量喷洒、提高农药利用率的关键。

精准施药的前提是精准识别杂草，国内外研究人员对此进行了一系列研究。刘剑[5]在图像预处理基础上，设计出基于 ANN（Artifical neural network）的玉米田间杂草图像特征提取和识别算法，根据所提取的作物和杂草图像特征，在玉米田间区分出杂草。何东健等[6]在对田间植物图像处理的基础上，提取植物叶片形状、纹理及分形维数 3 类特征，分别以 3 类单特征的 SVM 分类结果构造基本概率指派，引入 DS 融合算法，根据融合结果及分类判决门限给出最终的识别结果。梁媛等[7]利用 D-S 证据理论将图像边缘邻域一致性、方向性和结构性 3 种测度进行融合，有效降低噪声的影响，提高了杂草边缘检测的准确性。TANG 等[8]利用 K-means 算法预处理杂草识别模型，以其权重初始化新的卷积神经网络模型权重，最终准确度达到 92.89%，优于普通卷积神经网络和无 fine-tuning 处理的神经网络。FERREIRA 等[9]利用 SLIC superpixel 算法生成超像素图像，并利用卷积神经网络进行识别处理，分类准确度达 98% 以上。LOTTES 等[10]利用四通道（RGB + NIR）相机采集图像，并利用近红外光谱图像实现植被与土壤背景分割，之后提取杂草特征并利用随机森林算法区分杂草与作物。目前现有的大多数杂草识别算法均依赖于人工选择的杂草特征（如形状、纹理等），识别准确度仍有待于进一步提高。

本文利用深度学习[11-13]的方法实现杂草图像特征的自动提取（不依赖于人工特征筛选），结合二进制哈希码压缩高维杂草特征数据，实现杂草的快速识别，为后续的田间农药喷洒提供信息支持。利用杂草数据在预训练的多层级卷积神经网络基础上进行 fine-tuning，生成杂草识别模型，提取杂草图像的普通特征码和哈希特征码，并存入数据库。利用训练好的模型提取输入图像哈希特征码和普通特征码，与数据库中的哈希特征码和普通特征码进行对比，分别计算其欧氏距离与汉明距离，找出与其最相似的 *K* 幅图像，统计这 *K* 幅图像的标签，将其归入频率最高的一类，以达到分类识别的目的。

## 1　材料与方法

### 1.1　试验材料与图像预处理

以玉米及其伴生杂草作为研究对象进行识别。试验采用 Canon PowerShot SX600 HS 型相机，主要参数为：背照式 CMOS 传感器，最高分辨率 4 608 像

素 ×3 456 像素,有效像素数 1 600 万。采集陕西省地区的玉米、刺儿菜、灰菜、莎草、早熟禾 5 类植物各 1 200 幅高清图像(4 608 像素 ×3 456 像素,180 dpi)。作物及杂草图像样本如图 1 所示。

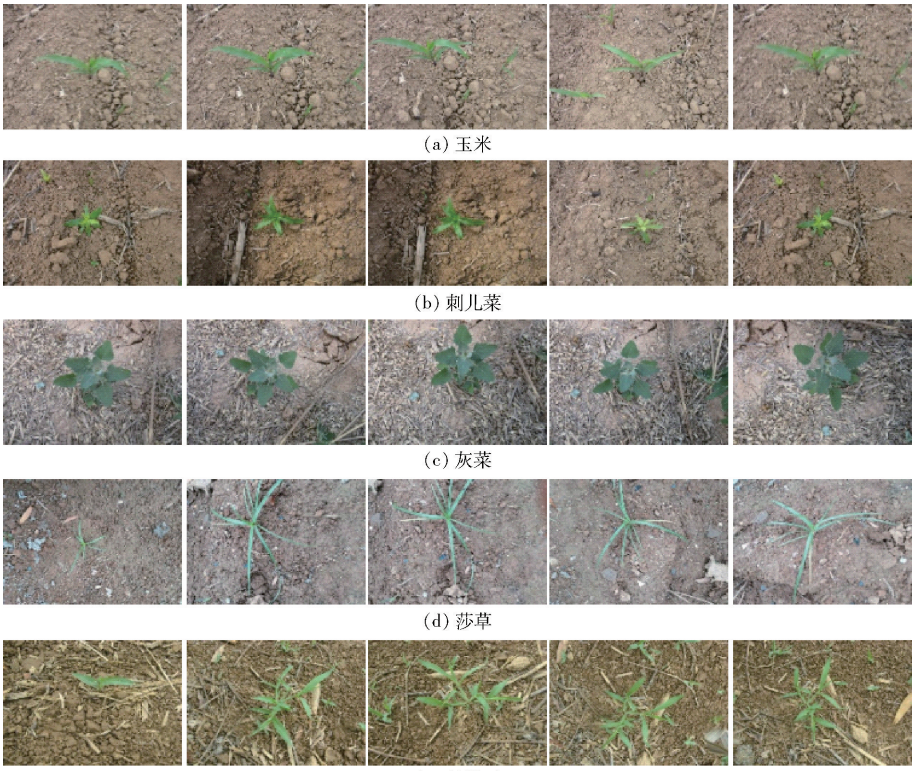

(a) 玉米

(b) 刺儿菜

(c) 灰菜

(d) 莎草

(e) 早熟禾

图 1 玉米及田间杂草图

Fig. 1 Pictures of corn and field weeds

对采集的图像进行人工分类和标记,构建数据库,并进行打标建立数据集,其中训练集各类植物 1 000 幅,测试集各类植物各 200 幅。刺儿菜、灰菜、莎草、玉米、早熟禾标签分别为 0、1、2、3、4。

由于相机获得的原始图像尺寸为 4 608 像素 ×3 456 像素,不适合进行识别模型的训练。为了加快模型的训练速度,提高模型精度,在将图像输入神经网络前将图像尺寸调整为 208 像素 ×208 像素。

### 1.2 杂草识别模型构建

卷积神经网络[14-18]由多层网络构成,每层网络包含数个二维平面,每个平面又由多个独立的神经元组成。其独特的结构能有效提取视觉层面的特征,适用于复杂环境下的田间杂草识别[19-21]。

在本文卷积神经网络中,杂草图像的一部分(局部感受区域)首先进入网络的最低层再依次向高层传递,各层网络通过卷积提取杂草图像的一个或多个特征(低层次的网络输出侧重于空间几何信息,高层次的网络输出侧重于语义等抽象信息)。卷积神经网络的特征提取过程可表示为

$$\boldsymbol{y}=F(\boldsymbol{M}|\boldsymbol{\theta})=f_l(\cdots f_2(f_1(\boldsymbol{M}|\theta_1)|\theta_2)\cdots|\theta_l) \quad (1)$$

式中 $\boldsymbol{M}$——输入的杂草图像矩阵

$\boldsymbol{\theta}$——待调整的参数

$f$——卷积函数 $\boldsymbol{y}$——杂草特征向量

$F$——杂草识别函数

杂草识别网络通过不断调整参数 $\boldsymbol{\theta}$ 使杂草识别函数 $F(\boldsymbol{M}|\boldsymbol{\theta})$ 的输出不断向 $\boldsymbol{y}$ 逼近。

结合杂草识别的实际需要,本试验采用 9 层卷积网络 $\{l\}_{i=1}^{9}$ 构建杂草识别模型。整个卷积神经网络的结构如下:

$l_1$:32 个(3,3)卷积核,激活函数采用 Relu 激活函数[22],其可表示为 $f(x)=\max(0,x)$,池化层为宽高方向步长均为 2,大小为(3,3)的最大池化层[23-24],池化层后连接应局部响应归一化函数[23](Local response normalization,LRN)。

$l_2$:64 个(3,3)卷积核,激活函数采用 Relu 激活函数,池化层为宽高方向步长均为 2,大小为(3,3)的最大池化层。

$l_3$:128 个(3,3)卷积核,激活函数采用 Relu 激活函数,池化层为宽高方向步长均为 2,大小为(3,3)的最大池化层。

$l_4$:256 个(3,3)卷积核,激活函数采用 Relu 激活函数,激活函数后先连接 LRN 函数再连接池化层,池化层为宽高方向步长均为 2,大小为(3,3)的最大池化层。

$l_5$:4 096 个神经元,权重 $\boldsymbol{w}$ 为(dim,4 096),dim 为 $l_4$ 展开成一维向量的长度,激活函数采用 Relu 激

活函数。

$l_6$:256 个神经元,权重 $\boldsymbol{w}$ 为(4 096,256),激活函数采用 Relu 激活函数。

$l_7$:Dropout 层,保留比例设为 0.9。

$l_8$:Hash 层,权重 $\boldsymbol{w}$ 为(256,128),激活函数采用 Sigmoid 函数。

$l_9$:输出层,权重 $\boldsymbol{w}$ 为(128,5),激活函数采用 Softmax 函数。

**1.2.1** 杂草识别网络卷积层

本试验所提出的杂草识别网络中,前 4 层即 $l_1$、$l_2$、$l_3$、$l_4$ 为卷积层,以其提取所需要分类特征,其过程可表示为

$$\boldsymbol{y}_l = f_l(\boldsymbol{M}_l \mid \boldsymbol{\theta}_l) = \mathrm{Relu}(\boldsymbol{w} \otimes \boldsymbol{M}_l + \boldsymbol{b}) \tag{2}$$

其中 $\boldsymbol{\theta}_l = [\boldsymbol{w} \quad \boldsymbol{b}]$

式中 $\boldsymbol{y}_l$——$l$ 层杂草图像输出矩阵,是由杂草特征图组成的三维向量

$\boldsymbol{M}_l$——$l$ 层杂草图像输入矩阵,是由杂草特征图组成的三维向量

$\boldsymbol{\theta}_l$——卷积核　　$\otimes$——卷积运算

$\boldsymbol{b}$——偏置

padding 方式设置为 SAME,stride 在宽高方向都设为 1,$\boldsymbol{M}_l$、$\boldsymbol{\theta}_l$、$\boldsymbol{y}_l$ 可分别表示为$(h_l, w_l, i_l)$、$(h_l, w_l, i_l, o_l)$、$(h_l, w_l, o_l)$,其中在第 1 层卷积层中 $h_l = w_l = 208$。在每层卷积层之后都连接一个最大池化层和局部响应归一化函数,池化层有利于减小特征图的尺寸从而加快模型训练速度,LRN 通过对局部神经元的活动建立竞争机制,进一步激活较为活跃的神经元并抑制不活跃的神经元,增强模型的泛化能力。

**1.2.2** 杂草识别网络全连接层

所提出的杂草识别网络 $l_5$、$l_6$ 为全连接层,在这 2 层中杂草模型特征图被展开成一维特征向量并被进一步压缩,提取其主要特征,其过程可表示为

$$\boldsymbol{y} = f(\boldsymbol{x} \mid \boldsymbol{\theta}) = \mathrm{Relu}(\boldsymbol{w}\boldsymbol{x} + \boldsymbol{b}) \tag{3}$$

其中 $\boldsymbol{\theta} = [\boldsymbol{w} \quad \boldsymbol{b}]$

式中 $\boldsymbol{x}$——杂草特征图展开后的长度为 $N$ 的一维向量

随后接入 Dropout 层,它的作用在于使部分神经元随机失活,防止过拟合。然后将随机失活后的一维特征向量输入 Hash 层提取特征哈希码,再将提取的特征哈希码输入一个全连接层映射成一个固定长度 $k$(本试验共有玉米、各类杂草共 5 个类别,此处固定长度 $k=5$)得到特征向量 $\boldsymbol{N}$,之后将特征向量 $\boldsymbol{N}$ 输入线性分类器进行分类预测。采用 Softmax 作为分类函数

$$P_i = \frac{\mathrm{e}^{l_i}}{\sum_{j=1}^{k} \mathrm{e}^{l_j}} \tag{4}$$

式中 $P_i$——类别 $i$ 的概率

$l_j$——特征向量 $\boldsymbol{N}$ 的第 $j$ 个元素

$l_i$——特征向量 $\boldsymbol{N}$ 的第 $i$ 个元素

$k$——特征向量 $\boldsymbol{N}$ 的长度,$1 \leqslant j \leqslant k$

经过分类函数得到预测标签后,利用交叉熵损失函数计算预测标签与实际标签的偏离程度

$$L = -\sum_{i=1}^{k} R_i \ln P_i \tag{5}$$

式中 $R_i$——实际的概率分布

最后通过反向传播算法来调整神经网络的权重等参数,实现对数据集特征的提取,完成杂草识别模型构建。

**1.2.3** 杂草网络 Hash 层结构

近来研究表明,由输入图像引入的全连接层的特征激活作为视觉特征[22-24],可以提高图像分类、检索精度。然而这些特征维度较高,难以应用于大规模图像的快速检索和识别。为了提高杂草识别效率,引入 Hash 层将杂草特征转换为二进制码,通过哈希或者汉明距离实现二进制码的快速比较以有效降低运算量。

本文试图提取特定区域的图像特征并将其转换为一系列的二进制哈希码(Hash-like)。假设最后一个全连接层的输出依赖一系列隐藏的有 on 和 off 状态的属性 $h$。即是说,图片诱导相似的二进制激活有同样的 label(标签)。为了实现该想法,在全连接层和输出层之间部署一个隐层 $H$,$H$ 也是一个全连接层,受后面编码语义特征和实现分类的输出层的调整。$H$ 层不仅提供对前面全连接层丰富特征的抽象,也是中层特征和高层语义的桥梁(承上启下)。$H$ 层的神经元通过 Sigmoid 函数激活近似到(0,1)之间。

为了实现领域适应,通过在目标数据集上反向传播 fine-tuning,CNN 的初始化权重为预训练模型的最终权重,$H$ 层和输出层的权重随机初始化。$H$ 层的初始化随机权重类似于 LSH(局部敏感度哈希)。在监督学习下,编码能够从 LSH 调整为更好匹配数据的形式。不用通过大规模的网络模型修改,该模型能够同时学习特定区域的视觉表示和二进制哈希函数以用于图像分类。

给定图像,提取隐层 $H$ 的输出,再二进制化得到二进制哈希码

$$H^j = \begin{cases} 1 & (\mathrm{Out}^j(H) \geqslant 0.5) \\ 0 & (\text{其他}) \end{cases} \quad (j \in (1,2,\cdots,h)) \tag{6}$$

式中 $\mathrm{Out}(H)$——隐层 $H$ 输出的图像标签

$h$——隐层节点的个数

### 1.3 预训练与 fine-tuning

首先在 ImageNet 数据集上利用卷积神经网络进行预训练获得卷积网络中参数和丰富的图像表示。然后在预训练的网络上添加 Hash 层，在杂草数据集上 fine-tuning 学习到二进制哈希码特征。最后利用所得到的杂草识别网络模型进行杂草特征提取。在杂草识别时，采用由粗到细的策略，利用学习到的二进制哈希码和全连接层特征码，实现杂草分类检索。预训练过程如图 2 所示。

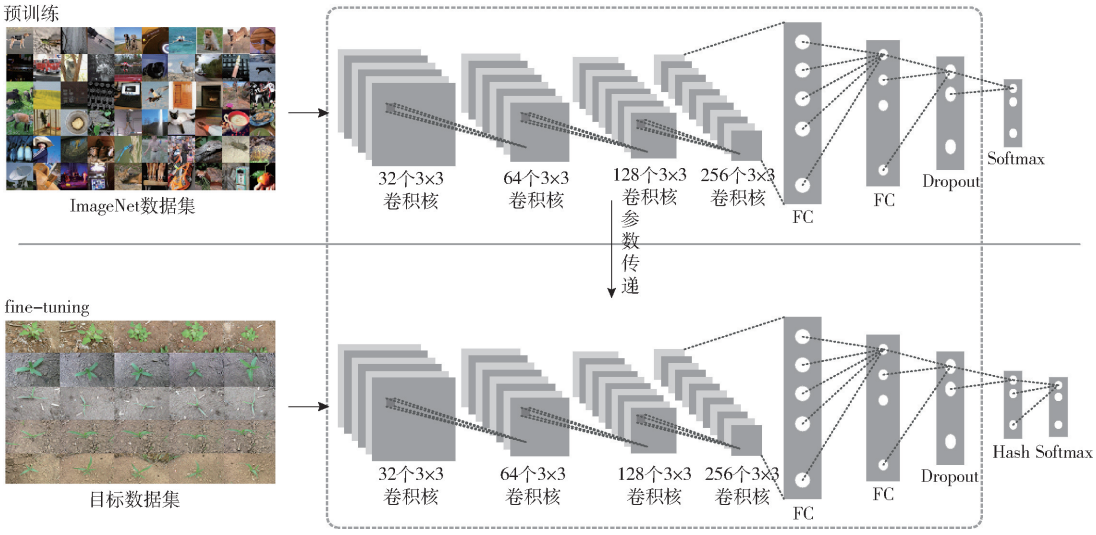


图 2 基于深度卷积网络和二进制哈希码的杂草识别模型

Fig. 2 Weeds recognition model based on convolutional network and binary Hash code

### 1.4 杂草识别策略

给定一个待检索杂草图像 $I$ 和候选集 $P$，通过模型提取其全连接层特征码和哈希码，先利用哈希码计算其与候选集 $P$ 中图像哈希码的汉明距离，得到距离最小的 $n(n \geqslant K)$ 幅图像 $Q$。汉明距离公式可表示为

$$d(\boldsymbol{X},\boldsymbol{Y}) = \sum_{i=1}^{n} x_i \oplus y_i \tag{7}$$

其中 $\boldsymbol{X} = (x_1, x_2, \cdots, x_n)$

$\boldsymbol{Y} = (y_1, y_2, \cdots, y_n)$

式中 $\oplus$——异或运算 $d(\boldsymbol{X},\boldsymbol{Y})$——汉明距离

然后计算 $I$ 与 $Q$ 中图像的全连接层特征码的欧氏距离得到前 $K$ 个距离最小的图像。欧氏距离计算公式为

$$S_i = \rho(\boldsymbol{A},\boldsymbol{B}) = \sqrt{\sum_{i=1}^{n} (a_i - b_i)^2} \tag{8}$$

其中 $\boldsymbol{A} = (a_1, a_2, \cdots, a_n)$ $\boldsymbol{B} = (b_1, b_2, \cdots, b_n)$

式中 $\rho(\boldsymbol{A},\boldsymbol{B})$——欧氏距离

最后统计这 $K$ 幅杂草图像的标签，出现频率最高的即确定为预测标签。当多种标签出现频率相同，先将 $S_i$ 按从小到大排序，然后从以下 2 种方案中选择其一：①因 $S_i$ 按从小到大排列即按输入图像与目标图像的欧氏距离从小到大排列，所以排名越靠前，其距离越近，因此可将输入图像标签确定为出现频率最高中排名最靠前的标签。②可将出现频率最高的几种标签的排名分别求和，将和最小的标签确定为输入图像的标签。分类流程如图 3 所示。

## 2 杂草识别试验

### 2.1 不同卷积网络层数对杂草识别的影响

一般来说，卷积层越多，模型越复杂，其精度就会越高，能提取到特征也就越复杂。例如在图像分类中，卷积网络的某一层提取到了边缘特征，其后的卷积层网络再用这些特征去提取形状特征，深层网络利用浅层网络提取的特征检测提取更为复杂的特征。针对杂草识别问题，为确定合理的卷积网络层数，进行了不同深度的卷积网络对比试验。

按模型结构设计不同深度的卷积网络进行对比试验，结果见表 1。由表 1 可知，训练 10 000 步时，不同深度的卷积网络训练所需时间相差最大为 128.04 s(3 层卷积层最少 3 160.65 s，8 层卷积层最多 3 288.69 s)，因此可以忽略时间的影响，只把准确率作为选择卷积网络层数的因素；准确率方面，卷积层数在 3 ~ 4 层时，准确率逐渐提升，在 5 ~ 7 层时，准确率逐渐降低，可能是发生了过拟合等现象，卷积层数为 4 层时准确率达到最高值 93.6%，因此，将卷积层数确定为 4 层。

### 2.2 不同哈希码长度对杂草识别的影响

在确定卷积层的层数之后，针对哈希编码长度的选择，对 0(没有哈希层)、48、64、128、256 位不同哈希码长度进行对比试验，结果见表 2。

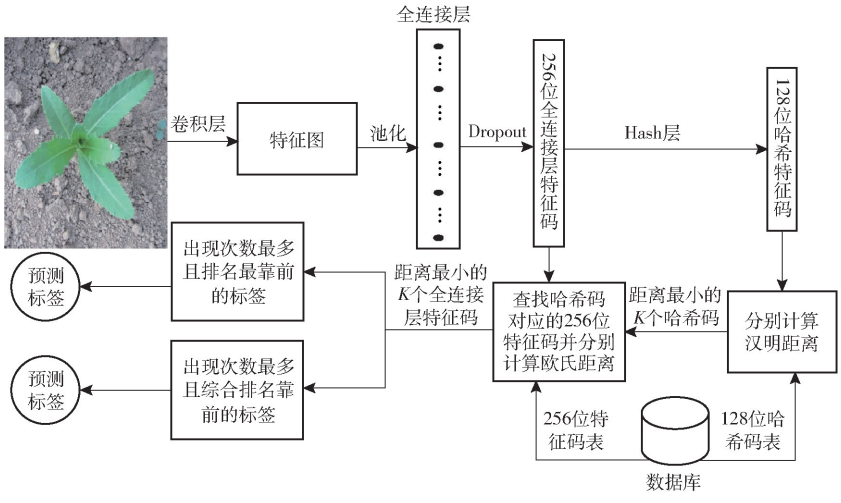


图 3　杂草识别流程图

Fig. 3　Process of weeds identification

**表 1　不同深度卷积网络对比**

**Tab. 1　Comparison of convolution networks with different layers**

| 卷积层数 | 步数 | 准确率/% | 时间/s |
|---|---|---|---|
| 3 | 10 000 | 91.5 | 3 160.65 |
| 4 | 10 000 | 93.6 | 3 219.98 |
| 5 | 10 000 | 92.9 | 3 278.61 |
| 6 | 10 000 | 90.0 | 3 246.98 |
| 7 | 10 000 | 90.6 | 3 262.34 |
| 8 | 10 000 | 92.7 | 3 288.69 |

**表 2　不同长度哈希码对比**

**Tab. 2　Comparison of different lengths Hash code**

| 哈希码长度/位 | 步数 | 准确率/% | 时间/s |
|---|---|---|---|
| 0 | 10 000 | 93.6 | 3 219.98 |
| 48 | 10 000 | 95.6 | 3 225.56 |
| 64 | 10 000 | 96.9 | 3 236.48 |
| 128 | 10 000 | 97.2 | 3 257.14 |
| 256 | 10 000 | 93.7 | 3 285.93 |

由表 2 可知，在加入 Hash 层后，准确率相较于无 Hash 层有所提高，最低提高 0.1 个百分点(256 位哈希码)，最高提高 3.6 个百分点(128 位哈希码)；哈希码长度在 48、64、128 位时逐渐提高，256 位时突然下降，原因可能是 128 位哈希码已经足以表达低层的特征，256 位哈希码导致特征过量表达，发生了过拟合。

## 3　试验结果分析

在确定好卷积层层数和哈希码长度之后，最终的杂草识别网络采用 4 层卷积网络和 128 维哈希编码的 Hash 层。利用此结构的网络，即可进行杂草识别。输入待检索图像，利用选定的模型提取其全连接层特征码和哈希特征码，先利用哈希码计算其与候选集中哈希码的汉明距离，得到距离最小的 $K$ 幅图像，然后计算待检索图像的全连接层特征码与这 $K$ 幅图像的全连接层特征码的欧氏距离，最后将 $K$ 个欧氏距离按升序排列并统计其对应的标签频率进行分类。选用准确率最高的模型(4 层卷积层，128 位哈希码)输入全部测试集的图像进行测试，准确率达到 98.6%。

将测试集中分类错误的结果进行统计，混淆矩阵如表 3 所示。部分错误识别结果，如图 4 所示。由表 3 和图 4 可知，错误的分类一般是将刺儿菜、灰菜与早熟禾混淆，将莎草与玉米混淆，主要原因在于刺儿菜、灰菜与早熟禾的外形较为相似，莎草与玉米的外形较为相似，所以导致少部分图像分类错误。针对这一现象，可以通过增加训练集数据以及训练步长等可进一步提高模型准确率，减少误分类情况。

**表 3　4 层卷积网络 128 位哈希码模型混淆矩阵**

**Tab. 3　4 confusion matrix of model with four layers and 128 bits Hash code**　%

| 实际标签 | 预测标签 | | | | |
|---|---|---|---|---|---|
| | 刺儿菜 | 灰菜 | 莎草 | 玉米 | 早熟禾 |
| 刺儿菜 | 99.50 | | | | 0.50 |
| 灰菜 | | 99.00 | | 0.50 | 0.50 |
| 莎草 | | | 98.00 | 2.00 | |
| 玉米 | 1.00 | 1.00 | 0.50 | 97.50 | |
| 早熟禾 | | 0.50 | 0.50 | | 99.00 |

卷积网络主要问题是计算量大，为满足田间杂草识别的实时性要求，采用 NVIDIA GTX 1080Ti GPU 代替 CPU 进行运算，识别一幅图像的耗时见表 4。同时也可以发现，4 层卷积层 + 128 位哈希码可以取得 98.6% 的杂草识别准确率，其表现优于 3 层卷积网络和较小哈希码长度的情况。

将 4 种不同模型的损失值绘制成折线图，通过观察发现加入 Hash 层后模型的稳定性均有所提高。




图 4 错误结果

Fig. 4 Error results

**表 4 利用 GPU 加速识别单幅图像耗时**

**Tab. 4 Time consumption per image with GPU**

| 模型 | 准确率/% | 耗时/s |
|---|---|---|
| 3 层卷积层 +0 位哈希码 | 92. 4 | 0. 18 |
| 4 层卷积层 +0 位哈希码 | 93. 7 | 0. 16 |
| 3 层卷积层 +64 位哈希码 | 95. 2 | 0. 28 |
| 4 层卷积层 +64 位哈希码 | 97. 4 | 0. 23 |
| 3 层卷积层 +128 位哈希码 | 95. 8 | 0. 52 |
| 4 层卷积层 +128 位哈希码 | 98. 6 | 0. 44 |

**表 5 不同模型准确率对比**

**Tab. 5 Accuracy comparison of different models**

| 卷积层数 | 哈希码长度/位 | 步数 | 准确率/% |
|---|---|---|---|
| 3 | 0 | 10 000 | 90. 6 |
| 3 | 128 | 10 000 | 91. 8 |
| 4 | 0 | 10 000 | 92. 2 |
| 4 | 128 | 10 000 | 95. 8 |
| 5 | 0 | 10 000 | 92. 6 |
| 5 | 128 | 10 000 | 95. 4 |

损失函数折线图如图 5 所示。

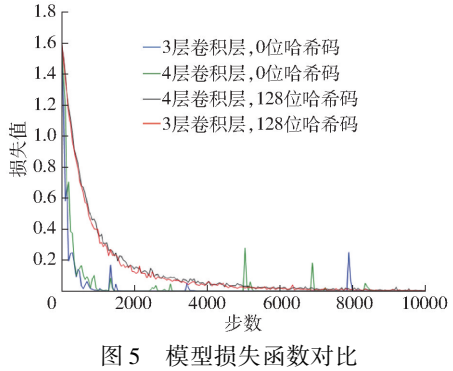


图 5 模型损失函数对比

Fig. 5 Comparison of loss function

## 4 其他数据集验证

### 4.1 数据集

为进一步验证模型的性能,采集于其他地区的玉米田间杂草,将被用来验证所提出杂草识别模型的通用性。在北京地区,采集玉米田间常见杂草马唐、牛筋草、稗草、狗尾草、猪殃殃 5 类杂草图像各 500 幅,对采集的图像进行人工分类和标记建立数据集,其中训练集各类杂草图像 400 幅,验证集各类杂草图像 100 幅。

### 4.2 验证测试

利用本文提出的模型,在新的数据集上进行训练生成新的模型,在测试集上进行验证测试,测试结果见表 5。

由表 5 可知,在测试集上准确率最低为 90. 6%,最高为 95. 8%,说明本文提出的研究方法具有通用性和实用性。

## 5 田间试验

于 2018 年 5 月 20 日,天气晴,在山东农业大学南校区农学试验站玉米田中进行除草剂喷施试验。玉米株距 50 cm,行距 40 cm。试验选用高地隙喷杆喷雾机,选择一侧喷杆的 2 个喷头,调整喷头位置,使之与玉米行间对齐,进行喷雾对比试验,如图 6 所示。2 个喷头的一侧安装 Canon PowerShot SX600 HS 型摄像头,相机帧率为 20 帧/s,调整相机,使相机距离地面 50 cm,视场角 22°,并在喷头前方安装电磁阀,如图 6c 所示。将采集到的图像上传到计算机,每 10 帧提取一幅图像,将该图像进行一定的预处理,输入到构建的杂草识别模型中,依据上文的杂草识别策略识别杂草及玉米,识别出杂草则电磁阀打开,控制喷头进行喷雾,实现精准喷雾。

选择合适杂草情况的玉米地,启动汽油机,打开喷杆的控制阀门,喷雾机以 0. 5 m/s 的速度,行进 10 m,关闭两侧喷杆的控制阀门及汽油机,将摄像头采集到的图像输入计算机,程序识别到杂草控制电磁阀打开喷头进行喷雾。观察统计杂草及玉米药液沉积情况,试验喷雾效果如图 6c 所示。

对靶喷雾统计结果为杂草施药率 92. 7%,玉米施药率 6. 5%,在无草无玉米时的喷施概率 1. 8%。




(a) 与计算机连线图　(b) 连续喷雾　(c) 图像识别对靶喷雾

图 6　田间验证识别率

Fig. 6　Verification in field

1. 摄像头　2. 电磁阀　3. 喷头

经观察分析知造成此现象的原因包括：有些杂草靠近玉米根部，玉米叶遮挡了药液的滴落，以及模型识别玉米及杂草存在一定误差，且电磁阀存在一定的响应时间，造成了喷雾延后，对玉米喷施药物的现象；系统的响应时间及喷杆的晃动等原因造成了无草无作物喷施的现象。

综上所述，所提出的杂草识别方法，可以有效提高杂草施药率，使其达到 92.7%，减少农药浪费，提高农药利用率，适用于田间玉米杂草处理。

## 6　结论

(1)利用深度学习中的卷积神经网络和哈希码构建杂草识别模型，并利用提取到的全连接层特征码和哈希特征码进行分类。本文方法在杂草数据集上的准确率和收敛速度相较于普通模型都有所提高，准确率可以达到 98.6%，满足实际应用需求。

(2)基于 NVIDIA GTX 1080Ti GPU 计算机平台，本文方法单幅图像识别耗时 0.44 s，模型识别速率较快，能够满足实时性要求，可实现农作物与杂草的快速识别分类。

(3)在杂草识别基础上进行对靶喷雾，杂草施药率可以达到 92.7%，减少了农药浪费。另外，模型在其他数据集上同样具有良好的表现，准确率可达 95.8%，说明本文方法具有通用性。

(4)提出的基于深度卷积网络和二进制哈希码的田间杂草快速识别方法能够达到较高准确性，具有通用性和实用性，为精准施药和精准机械除草提供田间杂草信息。

## 参　考　文　献


1　隋海霞. 杂草化感作用对粮食作物影响的研究进展[J]. 吉林农业，2014(23)：16.

2　汤雷雷，万开元，陈防. 养分管理与农田杂草生物多样性和遗传进化的关系研究进展[J]. 生态环境学报，2010，19(7)：1744－1749.
TANG Leilei，WAN Kaiyuan，CHEN Fang. Advances in studies on weeds biodiversity and genetic evolution in farmland in relation to nutrient [J]. Ecology and Environmental Sciences，2010，19(7)：1744－1749. (in Chinese)

3　创新机制，联手行动，共同应对农药对农业环境和生态的影响[J]. 中国植保导刊，2015，35(1)：79.

4　吴兰兰，徐恺，熊利荣. 基于视觉注意模型的苗期油菜田间杂草检测[J]. 华中农业大学学报，2018，37(2)：96－102.
WU Lanlan，XU Kai，XIONG Lirong. Detecting weed in seedling rapeseed oil field based on visual-attention model[J]. Journal of Huazhong Agricultural University，2018，37(2)：96－102. (in Chinese)

5　刘剑. 基于 Android 平台的玉米田间杂草的识别系统设计[D]. 太谷：山西农业大学，2016.

6　何东健，乔永亮，李攀，等. 基于 SVM－DS 多特征融合的杂草识别[J/OL]. 农业机械学报，2013，44(2)：182－187. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20130234&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2013.02.034.
HE Dongjian，QIAO Yongliang，LI Pan，et al. Weed recognition based on SVM－DS multi-feature fusion[J/OL]. Transactions of the Chinese Society for Agricultural Machinery，2013，44(2)：182－187. (in Chinese)

7　梁媛，杨帆. 基于 D－S 证据理论的杂草图像边缘检测的研究[J]. 数学的实践与认识，2012，42(9)：182－189.
LIANG Yuan，YANG Fan. Weed images for edge detection based on D－S evidence theory[J]. Mathematics in Practice and Theory，2012，42(9)：182－189. (in Chinese)

8　TANG Jinglei，WANG Dong，ZHANG Zhiguang，et al. Weed identification based on K-means feature learning combined with convolutional neural network[J]. Computers and Electronics in Agriculture，2017，135：63－70.

9　FERREIRA A D S，FREITAS D M，SILVA G G D，et al. Weed detection in soybean crops using ConvNets[J]. Computers & Electronics in Agriculture，2017，143：314－324.

10　LOTTES P，HÖRFERLIN M，SANDER S，et al. Effective vision based classification for separating sugar beets and weeds for precision farming[J]. Journal of Field Robotics，2017，6(34)：1035－1036.

11　侯宇青阳，全吉成，王宏伟. 深度学习发展综述[J]. 舰船电子工程，2017，37(4)：5－9.

HOU Yuqingyang, QUAN Jicheng, WANG Hongwei. Review of deep learning development[J]. Ship Electronic Engineering, 2017, 37(4):5 - 9. (in Chinese)

12 刘栋,李素,曹志冬. 深度学习及其在图像物体分类与检测中的应用综述[J]. 计算机科学,2016,43(12):13 - 23.
LIU Dong, LI Su, CAO Zhidong. State-of-the-art on deep learning and its application in image object classification and detection [J]. Computer Science, 2016, 43(12):13 - 23. (in Chinese)

13 侯一民,周慧琼,王政一. 深度学习在语音识别中的研究进展综述[J]. 计算机应用研究,2017,34(8):2241 - 2246.
HOU Yimin, ZHOU Huiqiong, WANG Zhengyi. Overview of speech recognition based on deep learning[J]. Application Research of Computers, 2017, 34(8):2241 - 2246. (in Chinese)

14 SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(4):640 - 651.

15 SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// ICLR, 2015.

16 WU X. Fully convolutional networks for semantic segmentation[C]// CVPR, 2015.

17 ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[J]. Computer Vision-ECCV, 2014, 8689:818 - 833.

18 SERMANET P, EIGEN D, ZHANG X, et al. Overfeat: integrated recognition, localization and detection using convolutional networks [C]// ICLR, 2014.

19 SHI W, CABALLERO J, HUSZAR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2016: 1874 - 1883.

20 MATURANA D, SCHERER S. VoxNet: a 3D convolutional neural network for real-time object recognition [C] // IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2015:922 - 928.

21 DAN C C, MEIER U, GAMBARDELLA L M, et al. Convolutional neural network committees for handwritten character classification [C]// International Conference on Document Analysis and Recognition. IEEE Computer Society, 2011:1135 - 1139.

22 GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C] // Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistic, PMLR 15, 2011:315 - 323.

23 KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // International Conference on Neural Information Processing Systems. Curran Associates Inc, 2012:1097 - 1105.

24 HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9):1904 - 1916.

25 BABENKO A, SLESAREV A, CHIGORIN A, et al. Neural codes for image retrieval [C] // European Conference on Computer Vision. Springer, Cham, 2014:584 - 599.

26 DONAHUE J, JIA Y, VINYALS O, et al. DeCAF: a deep convolutional activation feature for generic visual recognition [C] // International Conference on Machine Learning. JMLR. org, 2014:I - 647.

27 LIN K, YANG H F, HSIAO J H, et al. Deep learning of binary Hash codes for fast image retrieval [C] // Computer Vision and Pattern Recognition Workshops. IEEE, 2015:27 - 35.

28 LI J Y, LI J H. Fast image search with deep convolutional neural networks and efficient Hashing codes [C] // International Conference on Fuzzy Systems and Knowledge Discovery. IEEE, 2016:1285 - 1290.

29 SONG J, GAO L, ZOU F, et al. Deep and fast: deep learning Hashing with semi-supervised graph construction[J]. Image & Vision Computing, 2016, 55:101 - 108.

30 GAO L, SONG J, ZOU F, et al. Scalable multimedia retrieval by deep learning Hashing with relative similarity learning[C]// ACM International Conference on Multimedia. ACM, 2015:903 - 906.

31 LIN K, YANG H F, HSIAO J H, et al. Rapid clothing retrieval via deep learning of binary codes and hierarchical search [C] // ACM on International Conference on Multimedia Retrieval. ACM, 2015:499 - 502.

32 ZHANG R, LIN L, ZHANG R, et al. Bit-scalable deep Hashing with regularized similarity learning for image retrieval and person re-identification[J]. IEEE Transactions on Image Processing, 2015, 24(12):4766 - 4779.

33 WANG Q, SI L, ZHANG D. Learning to hash with partial tags: exploring correlation between tags and Hashing bits for large scale image retrieval[C]// European Conference on Computer Vision. Springer International Publishing, 2014:378 - 392.

34 KONG W, LI W J, GUO M. Manhattan Hashing for large-scale image retrieval[C]// SIGIR, 2012

35 LOWE D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2):91 - 110.