

基于多特征融合的田间杂草分类识别*

赵鹏 韦兴竹

(东北林业大学信息与计算机工程学院, 哈尔滨 150040)

摘要: 提出了一种基于模糊 BP 综合神经网络的田间杂草分类识别方法。对分类特征进行模糊化处理, 充分考虑了杂草的分类特征本身存在的不确定性。使用遗传算法对网络结构进行优化处理, 提高了该综合神经网络的收敛性和稳定性。并基于特征级数据融合方法进行杂草识别。对田间 7 种杂草进行识别的实验结果表明, 7 种杂草的混合识别率达到 94.2%; 另外, 对玉米及其伴生杂草进行分类测试, 混合识别率达到 96.7%, 具有较好的识别精度。

关键词: 杂草识别 机器视觉 数据融合 BP 神经网络 光谱分析

中图分类号: O657.3; S451 **文献标识码:** A **文章编号:** 1000-1298(2014)03-0275-07

引言

在利用形状特征进行杂草识别中, 主要是考虑不同植物叶片形状特征差异信息^[1-4]。

在利用纹理特征进行杂草识别中, 主要是考虑农作物与杂草的叶片具有不同的纹理分布特征^[5-6]。虽然杂草纹理特征识别具有较高正确识别率, 但由于纹理特征提取涉及矩阵计算, 其运算速度较慢不适用于大面积的实际野外田间环境中。在利用颜色特征进行杂草识别中, 主要是考虑某些杂草的茎呈红色, 但是该方法只适用于具有红色茎的杂草, 其正确识别率较低, 应用范围具有局限性^[7-8]。

考虑到利用植物的形状、纹理、颜色 3 种特征进行杂草识别各自的优缺点, 研究者又将这 3 种特征进行了特征级融合或者决策级融合^[9], 但这方法只是对 3 种特征的简单融合而没有对特征进行选择和优化的过程, 致使识别精度和处理时间的矛盾比较突出^[10]。

运用多光谱特征识别田间农作物与杂草是一种较新颖的方法, 主要是考虑不同植物对于不同波长入射光反射率/透射率的差异^[11-15]。

分析上述各种方法, 它们本质上是一些定量分析及模式识别过程, 使用的分类特征主要是某些绝对的数值量, 使用的分类器也主要是确定性分类器。但是, 杂草识别是一种定性分析的过程, 并且杂草的分类特征本身存在很大的模糊性和不确定性。例如, 杂草的叶片形状差别较大, 普遍存在着杂草叶片形状的种间差异和种内差异混合并存的情况。只有少数研究

者考虑到这类叶片形状特征的不确定性^[1,16-20]。

本文提出应用模糊理论将杂草的分类特征模糊化处理, 以基于 BP 神经网络的特征级数据融合方法进行杂草识别。

1 杂草分类特征提取

1.1 颜色特征

使用图像阈值分割法进行原始杂草图像的二值化处理, 去除背景后得到杂草目标。然后经大量测试和优化, 发现 4 个典型的颜色特征组合分类效果较好, 即 RGB 空间的 $(R-G)/G$ 、 $(R+4G+B)/6$ 和 HSI 空间的 H 、 S 。将这 4 个特征作为杂草识别颜色子网络的输入量, 分别用 T_1 、 T_2 、 T_3 、 T_4 表示。

1.2 纹理特征

先将原始图像的 RGB 空间转换到 HSI 空间, 得到 S 分量矩阵, 为减少计算量, 将其灰度级重新分为 6 级。为了避免叶面的方向对于纹理特征量的影响, 采用 0° 、 45° 、 90° 、 135° 方向上相距为 d 个像素的 4 个共生矩阵的和定义为杂草纹理共生矩阵, 本文中 $d=1$, 使用的 4 个主要纹理特征统计量为

$$\left\{ \begin{array}{l} T_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} iP(i,j) \\ T_6 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (1-i)^2 P(i,j) \\ T_7 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j)^2 \\ T_8 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) \lg P(i,j) \end{array} \right. \quad (1)$$

收稿日期: 2013-04-07 修回日期: 2013-07-29

* 中央高校基本科研业务费专项资金资助项目(DL12DB06)

作者简介: 赵鹏, 副教授, 博士, 主要从事光学检测、视觉测量、数据融合及图像分析研究, E-mail: bit_zhao@aliyun.com

另外 4 个次要纹理特征统计量为

$$\begin{cases} T_9 = \max(P(i, j)) \\ T_{10} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} P(i, j) \\ T_{11} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 P(i, j) \\ T_{12} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i + j - 2u)^4 P(i, j) \end{cases} \quad (2)$$

式中 N_g —— 灰度级的档数

u —— 像素平均灰度

$T_5、T_6、T_7、T_8$ —— 基本特征, 在杂草分类中起到主要作用

$T_9、T_{10}、T_{11}、T_{12}$ —— 在前几个特征基础上定义的次要特征, 在杂草分类中起到辅助作用

1.3 光谱特征

利用 FieldSpec ProFR 便携式多光谱辐射分析仪测量杂草叶片的光谱反射率, 测量波长范围为 340 ~ 1 070 nm, 光谱采样间隔 1.4 nm, 实际可以测量出 512 个中心波长的反射率, 它构成了 512 维的特征空间。再加上每幅杂草图像的颜色和纹理特征, 大量的冗余信息将降低分类器的处理速度, 因此需要进行光谱特征波长的选择。根据实验数据分析, 将光谱反射率特征选择在不同种类杂草区别较大的波长范围内比较合适。本文选 540 ~ 570 nm、760 ~ 790 nm、890 ~ 920 nm、950 ~ 980 nm 4 个波段反射率的和作为杂草光谱特征 $T_{13}、T_{14}、T_{15}、T_{16}$ 。

2 模糊 BP 神经网络设计

杂草自动识别 BP 神经网络的输入包括颜色、纹理和光谱总共 16 个特征分量, 这 16 个分量如果组合成一个特征向量并且直接作为神经网络的输入向量, 则将导致网络结构过于庞大和网络训练过于复杂。因此, 提出一种包括颜色特征子网络、主要纹理特征及次要纹理特征子网络和光谱特征子网络的新型综合网络分类识别系统。该综合网络不仅实现了杂草各种特征的特征级数据融合处理, 而且降低了网络的复杂程度和网络学习训练时间, 提高了 BP 网络的实用性和效率。

该模糊 BP 神经网络由 5 层组成, 具体的网络结构如图 1 所示。网络的第 1 层为输入层, 如果将 $T_1 \sim T_{16}$ 直接用一个特征向量表示并且作为网络的输入向量, 则会导致网络结构过分庞大复杂。此外, 由于颜色纹理及光谱的各类特征分量的取值范围差别较大, 将两类特征分量直接混合在一起必然引起网络权重的混乱, 从而造成网络分类识别能力的下

降。因此需要按照特征分量的类别将神经网络分解为 4 个特征子网络。

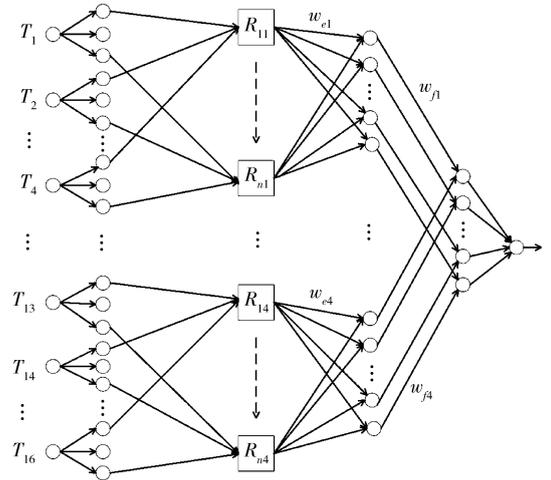


图 1 模糊 BP 综合神经网络结构图

Fig. 1 Structure graph of fuzzy BP neural network

网络的第 2 层实现输入特征分量的模糊化, 每个输入特征分量 $T_i (i = 1, \dots, 16)$ 模糊化为 3 个模糊子集, 分别用 $L、M、S$ 表示。 $U_L(T_i)、U_M(T_i)、U_S(T_i)$ 分别表示输入分量 T_i 隶属于 3 个模糊子集的隶属度, 其隶属函数取为梯形函数, 函数形式分别为

$$U_L(x) = \begin{cases} 1 & (x < a) \\ \frac{b-x}{b-a} & (a \leq x < b) \\ 0 & (x \geq b) \end{cases} \quad (3)$$

$$U_M(x) = \begin{cases} 0 & (x < a) \\ \frac{x-a}{b-a} & (a \leq x < b) \\ 1 & (b \leq x < c) \\ \frac{x-d}{c-d} & (c \leq x < d) \\ 0 & (x \geq d) \end{cases} \quad (4)$$

$$U_S(x) = \begin{cases} 0 & (x < c) \\ \frac{x-c}{d-c} & (c \leq x < d) \\ 1 & (x \geq d) \end{cases} \quad (5)$$

公式中 x 是各个特征分量值, $a = (x_{\max} - x_{\min})/5, b = 2a, c = 3a, d = 4a$, 隶属函数曲线如图 2 所示。

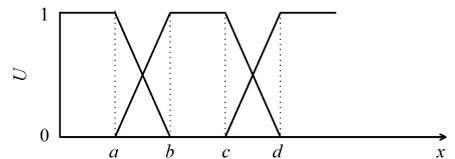


图 2 梯形隶属函数图

Fig. 2 Trapezoid membership function

网络的第 3 层实现模糊集运算, 其中 $R_{11}、\dots、R_{n1}$ 是第 1 个子网络的模糊规则, $R_{14}、\dots、R_{n4}$ 表示第 4 个子网络的模糊规则。理论上, 每个子网络模糊规

则应该遍历输入模糊集的每一种组合,这时每个子网络的模糊规则数目是 $3^4 = 81$ 。在实际设计中,为了降低网络的复杂程度和网络学习训练时间,使用遗传算法进行模糊规则的优化选取。经过优化选取,删除那些对分类没有作用或者作用力很小的规则。在遗传算法中,编码形式采用十进制编码方式;适应度函数定义为 $1/e_{MSR}$, e_{MSR} 定义为网络的期望输出与实际输出的均方差。在上述编码基础上,采用轮盘赌选择机制和两点交叉随机突变的遗传操作,对网络结构进行寻优。最后按照模糊规则的适应度大小,每个子网络优先保留适应度较大的 25 条模糊规则,这层的网络输出为各条模糊规则的适用度。

网络的第 4 层为 4 个子网络的归一化层,每个子网络共有 7 个节点,分别对应于每个子网络中判别分属于 7 种杂草的隶属度(实验中对常见的 7 种杂草作分类识别)。 $w_{e1} \sim w_{e4}$ 分别表示第 1 个子网络到第 4 个子网络的归一化系数。

网络的第 5 层为 4 个子网络的综合输出层,图 1 中的 $w_{f1} \sim w_{f4}$ 分别表示第 1 个子网络到第 4 个子网络的网络权重,该层的输出表示综合 4 个子网络后分属于 7 种杂草的隶属度。这里取 $w_f = (0.2, 0.4, 0.2, 0.2)^T$, 分别对应于颜色、主要纹理、次要纹理和光谱这 4 个子网络的网络权重。

网络的第 6 层实现解模糊,即把模糊量转化为确切的输出值。

在网络的训练过程中,第 1 组为田间杂草种类分类识别实验,模糊神经网络输出 $(0, 0, 0, 0, 0, 0, 1)^T$ 、 $(0, 0, 0, 0, 0, 1, 0)^T$ 、 $(0, 0, 0, 0, 1, 0, 0)^T$ 、 $(0, 0, 0, 1, 0, 0, 0)^T$ 、 $(0, 0, 1, 0, 0, 0, 0)^T$ 、 $(0, 1, 0, 0, 0, 0, 0)^T$ 、 $(1, 0, 0, 0, 0, 0, 0)^T$, 分别对应于藜草、稗草、狗尾草、莠麦菜、龙葵、苜蓿菜、反枝苋这 7 种杂草。第 2 组为玉米及其伴生杂草分类实验,网络输出 $(0, 1)^T$ 、 $(1, 0)^T$, 分别对应玉米幼苗和杂草。实际的网络训练很难达到理想值 0 和 1, 因此训练中分别用 0.02 和 0.98 作为目标值。

3 杂草种类识别实验

3.1 实验系统与材料

根据机器视觉杂草自动识别原理,建立了由摄像机、图像采集卡、多光谱辐射分析仪、计算机等构成的实验平台。系统采用日本 Sony 公司生产的 DCR-PC5E 型数码摄像机,分辨率为 40 万像素,内置 i.LINK(IEEE1394)数码输入输出端子,120 倍数码变焦。数码摄像机拍摄的图像,经过 1394 卡送入到计算机,再利用 Ulead Videostudio 6.0 软件完成图像采集工作。多光谱辐射分析仪用于测量杂草的光

谱反射率,采用美国 ASD 公司的 FieldSpec ProFR 便携式分光辐射光谱仪,该仪器工作波长范围 340 ~ 1 070 nm;采样频率 10 次/s,光谱采样间隔 1.4 nm。本系统的计算机 CPU 主频 1.6 GHz,内存 256 MB,使用了 Matlab 6.5 编程环境。

数据采集包括杂草图像采集和光谱反射信息的测量,连续 3 年在东北农业大学实验田、哈尔滨农科院实验田和长春市东北地理信息研究所实验田进行数据采集。选取早田中具有代表性的藜草、稗草、狗尾草、莠麦菜、龙葵、苜蓿菜、反枝苋这 7 种杂草总共 630 幅图像作为实验样本,其中 350 幅作为神经网络分类器训练样本,其余作为测试样本。

植物的光谱信息获取时,取实验田部分玉米幼苗和 7 种杂草的植物样本,野外采集在晴朗的天气进行。测量前从植株上采摘叶片,摆放在保鲜箱中,然后迅速返回到实验室直接用光谱仪进行测定。其他特征是在田间采集杂草或者玉米幼苗图像,通过图像处理方法计算得出。

3.2 网络收敛性对比实验

收敛性是网络系统的重要指标,它受学习速率和网络结构等因素的影响,其中学习速率影响最大。本节主要研究学习速率对于收敛性的影响。使用训练样本的 16 个特征分量作为输入量,分别送到网络结构为 4-3-25-7-7 的 4 个模糊 BP 神经网络和网络结构为 4-3-25-7-7 的 4 个 BP 神经网络所组成的 BP 综合网络中,进行网络性能对比性实验。2 个综合网络的学习速率都是 $r_{lrate}(N) = r_{lrate}(N-1) \times 0.999$, $r_{lrate}(0) = 0.4$ 。其中 N 是网络训练次数, r_{lrate} 为学习速率, $r_{lrate}(0)$ 是初始化的学习速率,对比结果如图 3 所示。

从图 3 可以看出模糊 BP 综合神经网络可以在较高的学习速率下进行学习,并且网络很快收敛,可见本文提出的模糊 BP 综合神经网络的收敛性能优于普通 BP 综合神经网络。

3.3 网络稳定性对比实验

学习速率也是影响网络系统稳定性的重要因素,本实验将学习速率的初始值由 0.4 增加到 0.5,实验对比结果如图 4 所示。可以看出,模糊 BP 综合神经网络在增加学习速率时,系统在训练 4 000 次后开始稳定。普通 BP 综合神经网络训练 5 700 次后稳定,在此之前网络振动幅度较大。可见模糊 BP 综合神经网络可以在较高的学习速率下稳定学习,它在系统稳定性方面也优于普通 BP 综合神经网络。因此,模糊 BP 综合神经网络的训练时间(指达到相同的均方根误差而停止训练,训练过程中所消耗的时间称作神经网络的训练时间)远远小于普通

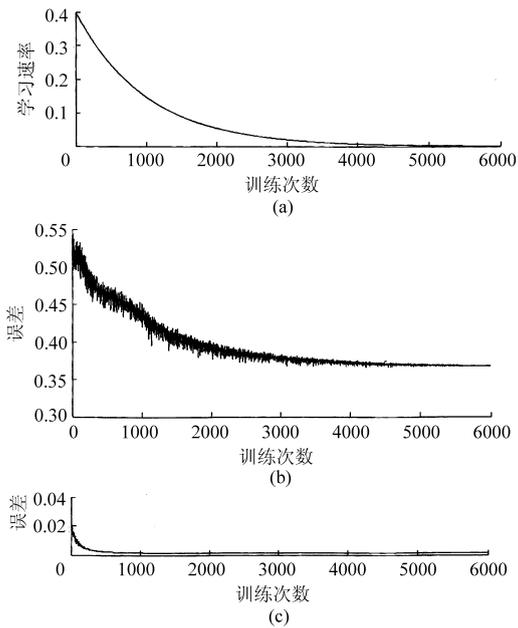


图3 学习速率对网络收敛性的影响

Fig. 3 Learning rate's influences on the network convergence

(a) 学习速率 (b) 普通 BP 综合网络的收敛误差
(c) 模糊 BP 综合网络的收敛误差

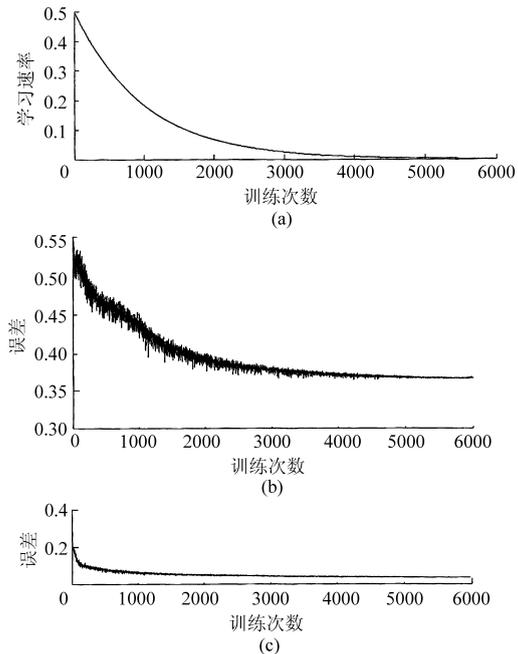


图4 学习速率对网络稳定性的影响

Fig. 4 Learning rate's influences on the network convergence

(a) 学习速率 (b) 普通 BP 综合网络的收敛误差
(c) 模糊 BP 综合网络的收敛误差

BP 综合神经网络的训练时间。

3.4 模式识别率对比实验

使用的测试样本选用训练样本以外的样本,选取 7 种杂草各 40 棵总共 280 棵进行分类识别实验。利用本文的模糊 BP 综合神经网络进行识别,单一杂草的识别率在 87.5% 以上,莠麦菜、龙葵的识别

率可达到 100%,7 种杂草混合识别率达到 94.2%。利用普通 BP 综合神经网络进行识别,单一杂草的识别率大约 75%,7 种杂草混合识别率达到 86.4%。其中,稗草和狗尾草的误识率较高,因为两种杂草只有在茎部有较明显的区别,稗草的茎扁平呈淡紫色;狗尾草茎部圆柱形呈绿色。图像采集是从上方拍摄的图像,茎部的信息大部分被遮盖,所以从颜色特征很难区分。从纹理特征看,这两种杂草都具有平行的叶脉,所以从纹理特征也较难区分。从光谱特征看,这两种杂草都属于单子叶杂草(它们属于同一个属类),光谱特征差别也不大,因此造成了这两种杂草一部分样本的错误分类。

3.5 模式识别速度对比实验

本实验测试 7 种杂草共计 280 棵,分别送入模糊 BP 综合神经网络和普通 BP 综合神经网络进行分类实验,学习速率初始值为 $r_{\text{lrater1}} = 0.4$, $r_{\text{lrater2}} = 0.5$,实验结果见表 1。可以看出,网络的学习速率越高,正确识别率就越低。另外,模糊 BP 综合神经网络的处理速度略低于普通 BP 综合神经网络,但是在分类识别率方面前者明显优于后者。

表 1 两种神经网络分类性能的比较

Tab. 1 Performance comparison between two class of neural network

性能指标	模糊 BP 神经网络		普通 BP 神经网络	
	r_{lrater1}	r_{lrater2}	r_{lrater1}	r_{lrater2}
单棵处理时间/s	0.045 2	0.028 9	0.042 9	0.027 3
混合识别率/%	91.5	87.2	82	79.5

4 农作物及其伴生杂草分类实验

4.1 图像的采集

通常春玉米的播种时间为 3 月下旬至 4 月上旬,而化学除草的进行时间为玉米出苗后 3~5 叶期,杂草 2~3 叶期,因此选取每年 4~6 月份采集实验田中玉米幼苗及其伴生杂草(狗尾草、稗草、藜)总共 240 幅图像作为实验样本。采集过程中要求标定相机的位置,拍摄时要保证相机沿着标定好的基准线进行平移运动,并准确地记录相机移动的距离,而相应移动的距离即为基线距 B ,在本实验中相机只需标定一次即可,可以重复地利用这一原理来进行杂草二维彩色图像对的采集。其采集原理图如图 5 所示。首先选取好图像拍摄的中心点,将相机置于中心点左侧位置 1 采集杂草的左图像,其次沿着水平线(即制作的轨道)水平移动,并记录移动的距离 B ,再将相机置于右侧位置 2 采集杂草的右图像。

4.2 双目立体视觉技术对图像三维重建

利用双目立体视觉可以恢复图像的三维坐标从

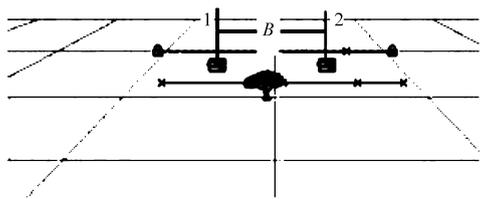


图 5 杂草图像采集原理图

Fig. 5 Schematic graph of gathering weed image

而提取其深度信息。双目立体视觉主要依据视差原理,运用三角形法则即将图像对和被测物体构成一个三角形来进行三维重建。 O_1 和 O_2 分别为左图像和右图像的中心点。 f 为相机的焦距。从图中可以看出深度 Z 和视差 $d(i, j)$ 可以运用几何学中三角形原理来进行计算得出。其原理图如图 6 所示。

$$Z(i, j) = f \frac{B}{d(i, j)} \quad (6)$$

若已知像素点 (i, j) 在某个投射面上的坐标,可以由 Z 值计算出 (X, Y) 点。

$$X = \frac{Z - f}{f} i \quad (7)$$

$$Y = \frac{Z - f}{f} j \quad (8)$$

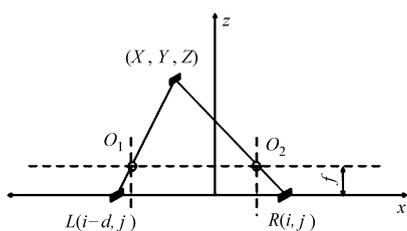


图 6 双目立体视觉三维重建原理图

Fig. 6 Schematic of 3-D reconstruction based on binocular stereoscopic vision

图 7 为当相机基线距 $B = 5 \text{ cm}$,焦距 $f = 8 \text{ mm}$ 时,重建的某株蒲公英样本三维图像。

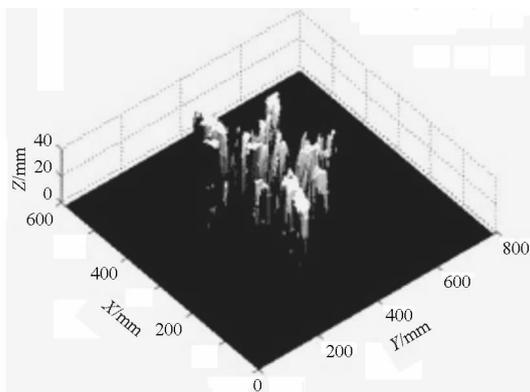


图 7 蒲公英的 3-D 重建图像

Fig. 7 3-D reconstruction picture of dandelion

4.3 基于 3-D 图像的植物高度特征提取

从重建后的 3-D 图像中提取其包含的三维信息,是双目立体视觉的一个重要应用。双目立体视

觉中提取出 3-D 图像中的深度信息为相机与植物叶片之间的距离。本实验中采集的玉米幼苗与杂草之间的高度差异较大,所以可以根据提取出来的深度 $\text{dept}(Z)$ 近似地计算出叶片的高度(相机与地面的距离减去深度 $\text{dept}(Z)$),在提取出叶片高度信息的同时统计对应高度上的像素点个数,画出高度直方图。图 8 为相机基线距 $B = 5 \text{ cm}$,焦距 $f = 8 \text{ mm}$ 时,实验测得某株蒲公英样本的高度直方图。

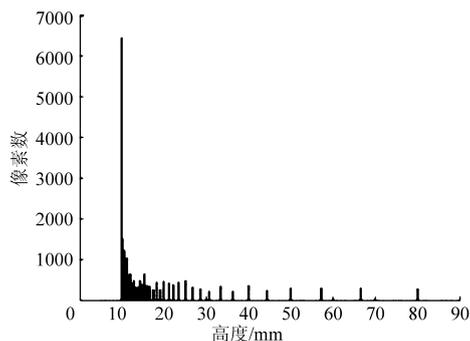


图 8 蒲公英高度直方图

Fig. 8 Height histogram of dandelion

4.4 模糊神经网络改进

通过建立并仔细观察杂草和玉米幼苗的高度直方图发现,狗尾草、稗草、藜草与玉米幼苗的高度区分度较为明显。为了提高分类识别的准确率,将原模糊神经网络输入层中次要纹理子网络替换为高度子网络。通过双目立体视觉技术,得到基于左视角图像与右视角图像的立体图像,然后统计出每种高度所对应的像素数,并选取植物高度的均值、中值、最大值、众值(mode value,即直方图中最大像素数目对应的高度),作为杂草识别高度子网络的输入量,分别用 $T_0 \sim T_{12}$ 表示,取 $w_f = (0.2, 0.2, 0.4, 0.2)^T$,分别对应于颜色、主要纹理、高度和光谱这 4 个子网络的网络权重。而网络的输出层中,将 $(0, 1)^T, (1, 0)^T$ 向量作为网络输出,分别对应玉米幼苗和杂草,具体的网络结构如图 9 所示。实验对玉米幼苗及杂草各 120 棵进行识别,其中采用模糊 BP 综合神经网络方法正确识别玉米幼苗 115 棵;采用普通 BP 综合神经网络方法正确识别玉米幼苗 110 棵;采用模糊 BP 综合神经网络方法正确识别杂草 117 棵;采用普通 BP 综合神经网络方法正确识别杂草 115 棵。实验表明,采用模糊神经网络对玉米幼苗及其伴生杂草分类,混合识别率高达 96.7%。

5 结束语

模糊 BP 综合神经网络分类器除了分类处理速度略低于普通 BP 综合神经网络以外,其他性能都优于普通 BP 综合神经网络分类器。这是因为模糊

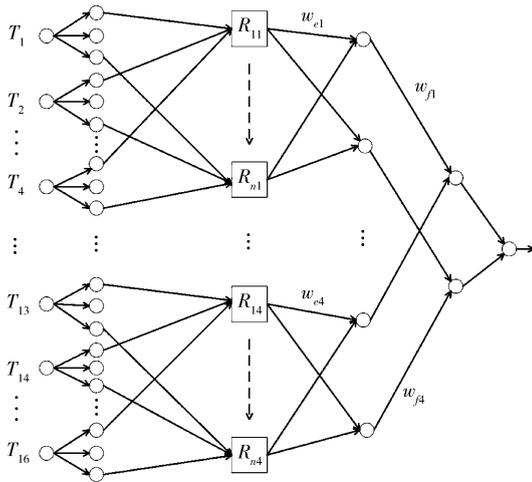


图9 改进模糊BP综合神经网络结构图

Fig.9 Structure block of improving fuzzy BP overall neural network

BP综合神经网络分类器充分考虑了杂草分类特征的不确定性/种间差异和种内差异并存的特点,它综合了4个分类特征BP神经网络、分类特征分量的模糊化和模糊规则的遗传优化选取这3方面的优点,从而使得它具有较高的分类识别率、较好的系统收敛性和稳定性。采用多特征融合的方法确实有比较好的正确识别率。一般情况下可以使用杂草叶片颜色、纹理和光谱特征进行数据融合和分类识别。如果不同植物的叶片高度差异较大,还可以使用颜色、纹理、高度和光谱这4个特征进行数据融合和分类识别。

但是,由于实时性较差,野外田间环境中存在着很多植物叶片的交叠遮挡现象等原因,将本文提出和设计的杂草自动识别软件系统应用到田间杂草分类识别处理仍然具有一定的局限性。

参 考 文 献

- 1 Sogaard H T, Heisel T. Weed classification by active shape models [J]. *Biosystems Engineering*, 2005, 91(3):271-281.
- 2 Schuster I, Nordmeyer H, Rath T. Comparison of vision-based and manual weed mapping in sugar beet [J]. *Biosystems Engineering*, 2007, 98(1):17-25.
- 3 Lamm R D, Slaughter D C, Giles D K. Precise weed control system for cotton [J]. *Transactions of the ASAE*, 2002, 45(1):231-238.
- 4 李志臣,姬长英.基于图像分析的杂草分形维数计算[J].*农业工程学报*,2006,22(11):175-178.
Li Zhichen, Ji Changying. Calculation of weed fractal dimension based on image analysis [J]. *Transactions of the CSAE*, 2006, 22(11):175-178. (in Chinese)
- 5 Burks T F, Shearers A, Heath J R, et al. Evaluation of neural-network classifiers for weed species discrimination [J]. *Biosystems Engineering*, 2005, 91(3):293-304.
- 6 曹晶晶,王一鸣,毛文华.基于纹理和位置特征的麦田杂草识别方法[J].*农业机械学报*,2007,38(4):107-110.
Cao Jingjing, Wang Yiming, Mao Wenhua. Weed detection method in wheat field based on texture and position features [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2007, 38(4):107-110. (in Chinese)
- 7 毛文华,王辉,赵博,等.基于株心颜色的玉米田间杂草识别方法[J].*农业工程学报*,2009,25(2):161-164.
Mao Wenhua, Wang Hui, Zhao Bo, et al. Weed detection method based on the centre color of seedling [J]. *Transactions of the CSAE*, 2009, 25(2):161-164. (in Chinese)
- 8 毛文华.基于机器视觉的田间杂草识别技术研究[D].北京:中国农业大学,2004.
Mao Wenhua. Research of weed identification technology using machine vision [D]. Beijing: China Agricultural University, 2004. (in Chinese)
- 9 Granittop M, Verdes P F, Ceccatto H A. Large-scale investigation of weed seed identification by machine vision [J]. *Computers and Electronics in Agriculture*, 2005, 47(1):15-24.
- 10 Tian L. Development of a sensor-based precision herbicide application system [J]. *Computers and Electronics in Agriculture*, 2002, 36(3):133-149.
- 11 陈树人,栗移新,毛罕平,等.基于光谱分析技术的作物中杂草识别研究[J].*光谱学与光谱分析*,2009,29(2):463-466.
Chen Shuren, Li Yixin, Mao Hanping, et al. Research on distinguishing weed from crop using spectrum analysis technology [J]. *Spectroscopy and Spectral Analysis*, 2009, 29(2):463-466. (in Chinese)
- 12 Feyaerts F, Gool L. Multi-spectral machine vision system for weed detection [J]. *Pattern Recognition Letters*, 2001, 22(6-7):667-674.
- 13 Javed I, Owens P R, Ali I. Application of remote sensing data to assess weed infestation in cotton [J]. *Agriculture Journal*, 2006, 1(4):186-191.
- 14 Vioix J B, Douzals J P, Truchetet F, et al. Spatial and spectral methods for weed detection and localization [J]. *EURASIP Journal on Advances in Signal Processing*, 2002, 7:679-685.
- 15 刘波,方俊永,刘学,等.基于成像光谱技术的作物杂草识别研究[J].*光谱学与光谱分析*,2010,30(7):1830-1833.
Liu Bo, Fang Junyong, Liu Xue, et al. Research on crop weed discrimination using a field imaging spectrometer [J]. *Spectroscopy and Spectral Analysis*, 2010, 30(7):1830-1833. (in Chinese)
- 16 Persson M, Astrand B. Classification of crops and weeds extracted by active shape models [J]. *Biosystems Engineering*, 2008,

- 100(6): 484 – 497.
- 17 Kishore S C, Michael N, Rasmus J N, et al. Weed identification using an automated active shape matching technique [J]. *Biosystems Engineering*, 2011, 110(4): 450 – 457.
- 18 毛文华, 张银桥, 王辉, 等. 杂草信息实时获取技术与设备研究进展 [J]. *农业机械学报*, 2013, 44(1): 190 – 195.
Mao Wenhua, Zhang Yinqiao, Wang Hui, et al. Advance techniques and equipments for real-time weed detection [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2013, 44(1): 190 – 195. (in Chinese)
- 19 何东健, 乔永亮, 李攀, 等. 基于 SVM – DS 多特征融合的杂草识别 [J]. *农业机械学报*, 2013, 44(1): 182 – 187.
He Dongjian, Qiao Yongliang, Li Pan, et al. Weed recognition based on SVM – DS multi-feature fusion [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2013, 44(1): 182 – 187. (in Chinese)
- 20 李先锋, 朱伟兴, 孔令东, 等. 基于 SVM 和 D – S 证据理论的多特征融合杂草识别方法 [J]. *农业机械学报*, 2013, 44(1): 164 – 168.
Li Xianfeng, Zhu Weixing, Kong Lingdong, et al. Method of multi-feature fusion based on SVM and D – S evidence theory in weed recognition [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2013, 44(1): 164 – 168. (in Chinese)

Weed Recognition in Agricultural Field Using Multiple Feature Fusions

Zhao Peng Wei Xingzhu

(*Information and Computer Engineering College, Northeast Forestry University, Harbin 150040, China*)

Abstract: A novel weed recognition scheme based on fuzzy BP overall neural network is proposed. First, the classification features are blurred to deal with the uncertainty of weed features. Second, the genetic algorithm is used to optimize the network structure so as to improve the network's convergence and stability. Finally, a feature-level data fusion scheme is used. In weed species identification experiments, neural network consists of the 4 BP sub-networks on color feature, main texture feature, secondary texture feature and spectral feature. The results indicate that the overall recognition rate reaches to a good recognition accuracy of 94.2% for 7 weed species. Besides, experiments were put into effect on the corn and its accompanying weeds. The neural network consists of the 4 BP sub-networks on color feature, main texture feature, height feature and spectral feature. The recognition rate reaches to 96.7% with a better recognition accuracy.

Key words: Weed recognition Machine vision Data fusion BP neural network Spectral analysis