

王怀宇,李景丽. 基于纹理特征的玉米苗期田间杂草识别[J]. 江苏农业科学,2014,42(7):143-145.

基于纹理特征的玉米苗期田间杂草识别

王怀宇,李景丽

(保定学院信息技术系,河北保定 071000)

摘要:对玉米常见杂草进行灰度化、图像滤波等图像预处理,对多个图像纹理特征进行筛选。以支持向量机进行分类识别,分别进行基于灰度矩阵、统计矩的识别以及二者结合的识别。结果表明,综合了灰度矩阵与统计矩的纹理特征识别精度最高,可满足田间杂草识别要求。

关键词:玉米;杂草;识别;纹理特征;灰度矩阵;统计矩

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1002-1302(2014)07-0143-03

玉米苗期常见杂草包括刺儿菜、藜、马唐、田旋花等。传统除草方法是喷洒除草剂,但田间杂草生长分布呈不均匀、无规律的随机分布,因此大规模药物喷洒不仅造成浪费,也对环境带来不容忽视的污染。随着精准农业的发展和图像处理技术应用的深入,在机器视觉的协助下实现农田中除草剂的变量喷洒成为当今研究热点。如何识别杂草图像是其中最为关键的步骤。当前已经开发出不少识别杂草的有效方法,这些方法往往结合杂草各类特征对其进行识别,包括颜色特征^[1-4]、形状特征^[5-6]、光谱特征^[7-9]等,也有研究结合以上组合特征进行识别,取得了较高的效率与精度。但单独针对杂草纹理特征进行智能识别的研究尚不多见。

纹理特征能够体现出图像灰度或颜色分布的可描述规律,尤其是在被识别目标的形状、颜色等属性均与周边环境相似时,能够以兼顾宏观性质与细部结构的方式取得较好的识别效果^[10]。不同作物种类或同种作物的健康植株与病害植株间在图像纹理特征上有较为明显的区别,因此纹理特征在农作物病虫害识别研究中能取得较好的识别效果^[10]。对于杂草识别来讲,怎样快速提取纹理特征以及如何实现准确的识别率是最关键的问题。本研究以玉米常见杂草图像识别为例,在图像预处理后,对样品的多个纹理特征进行筛选,以支持向量机进行分类,分别进行基于灰度矩阵、统计矩的识别以及结合二者的识别,以期对杂草的快速检测及定向施药提供基础。

1 材料与方法

1.1 图像采集

北方地区玉米苗期杂草非常常见,一般在播种后便可观察到杂草。据统计,华北地区玉米播种后的 8~10 d 是杂草出土最集中的时期,12~15 d 杂草出土占总量的 80%,25 d 后达到 95%。杂草的出土、生长时间规律与北方地区夏玉米苗期生长节律基本吻合。因此,只有及时除去杂草才能保证

玉米产量。研究证实,当玉米生长至 3~5 叶、田间杂草生长至 2~3 叶时,是去除杂草的关键时期。本研究在玉米生长至 3~5 叶时采集田间各类杂草图像,包括刺儿菜、藜、马唐、田旋花。在目标物正上方以 640×480 像素进行拍摄,杂草图像实例见图 1。




图1 杂草图像实例

1.2 图像预处理

1.2.1 图像增强 为了突出图像特征,削弱某些不重要甚至干扰的信息,首先对原始图像进行增强处理,以提升图像中有价值区域的对比度。图像增强方法分为频率增强法和空间增强法两大类。考虑到图像识别对于实时性的要求,本研究选取效率更高的空间增强法^[11],该方法对每个像素的灰度值进行变换,最终实现整体对比度的提升,达到图像增强的目的。采用的算法如下:

$$g(i,j) = \frac{g_b - g_a}{f_b - f_a} \times [f(i,j) - f_a] + g_a \quad (1)$$

式中: f_a 、 f_b 分别是指图像样本中线性变换区域的输入灰度最大值与最小值; g_b 、 g_a 分别是指输出灰度最大值与最小值; $f(i,j)$ 、 $g(i,j)$ 分别表示输入、输出图像的灰度值。

1.2.2 灰度化处理 图像纹理特征分析只需要其亮度信息,不需要颜色信息,而由于颜色信息数据量比较大,影响了图像处理速度,为便于纹理分析,还应把基于 RGB 的图像进行灰度化处理。考虑到玉米与杂草及周围其他元素相比,其主色调为绿色,表明 RGB 的 G 元素与周围环境区分最为明显,因此引入 Woelbecke 的超滤特征法进行灰度化处理^[1],算法

收稿日期:2013-11-03

基金项目:河北省保定市科技基金(编号:13ZN021);保定学院科研基金(编号:2013Z04)。

作者简介:王怀宇(1975—),男,河北保定人,硕士,讲师,从事图像处理、数据挖掘研究。E-mail:why_bdxxy@163.com。

如下:

$$E_c(x, y) = 2G(x, y) - R(x, y) - B(x, y). \quad (2)$$

式中: $E_c(x, y)$ 表示目标图像的超绿值; $G(x, y)$ 、 $R(x, y)$ 、 $B(x, y)$ 分别代表颜色空间中 3 个分量的矩阵。

1.2.3 滤波处理 在上述处理的基础上, 进一步通过滤波来优化图像质量。滤波法一般包括邻域滤波和中值滤波 2 类。叶片边缘轮廓信息量很大, 同样考虑到处理的效率和实时性, 本研究选取运算量相对较低的中值滤波^[12]。

中值滤波的主要原理是, 将图像分为不同的窗口, 将窗口里所有像素按大小进行排列, 将中位灰度值作为该窗口的灰度值, 可表示如下:

$$g(x, y) = \text{median}\{f(x-i, y-i)\}, i, j \in S. \quad (3)$$

式中: $g(x, y)$ $f(x-i, y-i)$ 表示窗口里像素的灰度值; S 表示中值滤波所使用的图像窗口; median 为取中位值函数。

处理后的杂草图像实例如图 2 所示。




图2 处理后的杂草图像实例

1.3 提取纹理特征

1.3.1 灰度共生矩阵 灰度共生矩阵的含义是从图像中某个灰度值为 i 的像素离开固定位置 $d(D_x, D_y)$, 并达到灰度值为 j 的可能性^[13], 表示如下:

$$P_d(i, j) \quad (i, j = 0, 1, 2, \dots, L-1). \quad (4)$$

式中: L 是指目标图像的灰度级数; 每个像素灰度以 (i, j) 表示。不同位置的空间关系以 d 表示, 一般通常选取 $0, \pi/4, \pi/2, 3\pi/4$ 方向。Labay 等研究发现, 灰度共生矩阵中 4 个互不相关的特征最能体现图像的纹理特点^[14], 本研究引入这 4 个特征。

1.3.1.1 能量 能量是指灰度共生矩阵中所有元素值平方和, 表示如下:

$$f_1 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_d^2(i, j). \quad (5)$$

该特征可以体现出目标图像在灰度方面的纹理粗细与均匀度。若灰度分布均匀, 则能量值较大, 反之能量值较小; 若纹理较粗糙, 则能量值较大, 反之较小。

1.3.1.2 对比度 对比度体现出目标图像的清晰度以及纹理沟槽的深浅程度, 表示如下:

$$f_2 = \sum_{n=0}^{L-1} n^2 \left\{ \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_d^2(i, j) \right\}. \quad (6)$$

式中: n 表示图像的灰度级, 取值范围为 $[0, L]$ 。目标图像的沟纹越深、灰度差越大, 则对比度值越大, 反之越小。

1.3.1.3 相关度 相关度体现出目标图像的灰度矩阵所有元素在图像的行、列方向的相似度, 表示如下:

$$f_3 = \frac{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_d^2(i, j) - \mu_1 \mu_2}{\delta_1^2 \delta_2^2}, \quad (7)$$

$$\mu_1 = \sum_{i=0}^{L-1} i \sum_{j=0}^{L-1} P_d(i, j), \quad (8)$$

$$\mu_2 = \sum_{j=0}^{L-1} j \sum_{i=0}^{L-1} P_d(i, j), \quad (9)$$

$$\delta_1^2 = \sum_{i=0}^{L-1} (i - \mu_1)^2 \sum_{j=0}^{L-1} P_d(i, j), \quad (10)$$

$$\delta_2^2 = \sum_{j=0}^{L-1} (j - \mu_2)^2 \sum_{i=0}^{L-1} P_d(i, j). \quad (11)$$

当目标图像的灰度共生矩阵值均匀相等时, 相关度取较大值; 当灰度共生矩阵值相差很大时, 则相关度取较小值。如果目标图像的水平纹理居多, 则该方向的相关度取值会明显大于其余方向。

1.3.1.4 同质性 同质性体现出目标图像的局部平滑, 表示如下:

$$f_4 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_d(i, j) / (1 + |i - j|). \quad (12)$$

1.3.2 统计矩 目标图像的灰度直方图统计矩也是其纹理特征的重要描述方式。已知图像的灰度级为 L , 以 SVM 的径向基核函数 $K(x, x) = \exp(-g \|x_r - x\|^2)$ 描述目标图像的直方图, 其中 g 为核函数的修正参数, x_r 为第 r 个支持向量, x 为标准支持向量, 从而可以得到如下 5 个纹理特征。

1.3.2.1 均值 均值(m)体现出目标图像的平均灰度, 表示如下:

$$m = \sum_{i=0}^{L-1} z_i p(z_i). \quad (13)$$

1.3.2.2 标准差 标准差(δ)体现出目标图像在纹理灰度方面的变化, 表示如下:

$$\delta = \sqrt{\sum_{i=0}^{L-1} (z_i - m)^2 p(z_i)}. \quad (14)$$

该特征便于对目标图像的粗糙纹理进行识别与分类。

1.3.2.3 平滑度 平滑度(R_s)体现出目标图像所拥有的灰度级对比度大小, 表示如下:

$$R_s = 1 - 1 / (1 + \delta^2). \quad (15)$$

如果目标图像存在等强度区, 则该区的 R_s 值为 0。

1.3.2.4 三阶矩 三阶矩(μ_3)体现出目标图像直方图的偏斜程度, 表示如下:

$$\mu_3 = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i). \quad (16)$$

如果目标图像直方图主要呈现出左倾斜, 则三阶矩小于 0, 否则大于 0。

1.3.2.5 熵 熵(H)体现出目标图像的信息量, 表示如下:

$$H = \sum_{i=0}^{L-1} P(z_i) \lg P(z_i). \quad (17)$$

图像具备的纹理信息带有随机性, 当灰度共生矩阵的全部元素呈现分散性分布时, 纹理信息随机性较大, 熵也较大。

对目标图像提取基于灰度共生矩阵与统计矩的玉米苗期田间杂草纹理特征共 9 种(表 1)。

1.4 支持向量机识别

支持向量机专门针对“二类模式”识别问题^[15]。考虑到作物和杂草的纹理参数多, 计算量较大, 为增强实时性, 选取基于 RBF 核函数的 SVM 识别方法, 实现最佳性能^[16]。

令 $U \in R^n, V \in R^n, g \in R^+$, 则 RBF 核函数表示如下:

$$K(U, V) = \exp(-g \|U - V\|^2). \quad (18)$$

表 1 基于灰度共生矩阵与统计矩的纹理特征

杂草	纹理特征								
	f_1	f_2	f_3	f_4	m	δ	R_3	μ_3	H
刺儿菜	5.137 2	1.562 0	1.596 1	1.607 8	2.691 0	14.390 2	0.622 6	0.910 6	1.565 1
藜	12.980 7	1.427 9	1.543 8	1.599 1	4.531 1	17.920 4	0.624 3	1.026 7	1.447 5
马唐	6.428 7	1.467 7	1.561 1	1.595 7	3.223 2	11.600 7	0.621 6	0.721 0	1.475 9
田旋花	38.165 6	1.016 9	1.366 7	1.612 0	34.675 8	49.843 3	0.655 6	2.378 3	1.027 0

式中: R 表示向量空间; g 为核函数的参数。

2 结果与分析

以 150 幅图像为样本,利用 MATLAB 软件获取所有图像的纹理特征。分别选择基于灰度共生矩阵的方法与基于统计矩特征的方法,以随机抽取的方式选取 50% 的图像(75 幅)作为构建 SVM 的测试集,其他 50% 的图像(75 幅)作为测试集。支持向量机的输入为前文所确定的 9 个特征。进行 3 种特征识别:一是基于灰度共生矩阵所获取的特征,包括能量、对比度、相关度、同质性,将其作为 SVM 输入进行识别;二是基于统计矩所获取的特征,包括均值、标准差、平滑度、三阶矩、熵,将其作为 SVM 输入进行识别;三是将以上 9 个参数作为 SVM 输入进行识别。识别结果见表 2。

表 2 识别结果		
参数类型	训练识别率 (%)	测试识别率 (%)
共生矩阵参数	90.67	88.00
统计矩参数	93.33	89.33
两者混合	96.00	97.33

由表 2 可知,识别精度较高。其中,共生矩阵参数的测试识别率最低,为 88.00%;两者混合的测试识别率最高,为 97.33%。两者混合识别方式下的训练识别率、测试识别率均处在最高值。在混合参数识别情况下,测试识别率为 97.33%,出现 2 个错误,经查证,将马唐误识别为玉米,原因可能是两者纹理特征相近,在图像清晰度不足的情况下容易导致系统误判。为了进一步提升识别准确率,可以将纹理特征识别结果与其他特征相互组合,使识别准确率更高。

3 结论

针对玉米田间杂草的识别问题,提出了根据纹理特征进行智能识别的方法,具有创新性。以灰度共生矩阵和统计矩来描述识别目标的纹理特征,通过支持向量机进行分类识别。结果表明,综合了灰度矩阵与统计矩的纹理特征识别精度超过 90%,能满足识别要求。本研究成果有利于减少除草剂喷洒量,有助于实现除草系统的自动化和智能化。

参考文献:

[1] Woebecke D M, Meyer G E, Von Bargaen K, et al. Color indices for weed identification under various soil, residual, and lighting conditions

[J]. Transactions of the ASAE, 1995, 38(1): 259 - 269.
[2] El - Faki M S, Zhang N, Peterson D E. Factors affecting color - based weed detection[J]. Transactions of the ASAE, 2000, 43(4): 1001 - 1009.
[3] Tang L, Tian L, Steward B L. Color image segmentation with genetic algorithm for in - field weed sensing[J]. Transactions of the ASAE, 2000, 43(4): 1019 - 1027.
[4] El - Faki M S. Zhang N, Peterson D E. Weed detection using color machine vision[J]. Transactions of the ASAE, 2000, 43(6): 1969 - 1978.
[5] Guyer D E, Miles G E, Schreiber M M, et al. Machine vision and image processing for plant identification[J]. Transactions of the ASAE, 1986, 29(6): 1500 - 1507.
[6] Franz E, Gebhardt M R, Unklesbay K B. Shape description of completely visible and partially occluded leaves for identifying plants in digital images[J]. Transactions of the ASAE, 1991, 34(2): 673 - 681.
[7] Franz E, Gebhardt M R, Unklesbay K B. The use of local spectral properties of leaves as an aid for identifying weed seedlings in digital images[J]. Transactions of the ASAE, 1991, 34(2): 682 - 687.
[8] Lu R, Peng Y K. Hyperspectral scattering for assessing peach fruit firmness[J]. Biosystems Engineering, 2006, 93(2): 161 - 171.
[9] Goel P K, Prasher S O, Patel R M, et al. Use of airborne multispectral imagery for weed detection in field crops[J]. Transactions of the ASAE, 2002, 45(2): 443 - 449.
[10] 周平, 汪亚明, 赵匀. 基于颜色分量运算与色域压缩的杂草实时检测方法[J]. 农业机械学报, 2007, 38(1): 116 - 119.
[11] 何东健. 数字图像处理[M]. 西安: 西安电子科技大学出版社, 2004.
[12] 刘立宏, 胡可刚, 刘立欣. 目标检测中的快速中值滤波法[J]. 吉林大学学报: 信息科学版, 2004, 22(3): 232 - 235.
[13] Haralick R M, Shanmugam K. Texture features for image classification[J]. IEEE Systems Man and Cybernetics, 1973, 3(6): 610 - 621.
[14] Ulaby F T, Kouyate F, Brisco B, et al. Textural information in SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 1986, GE - 24(2): 235 - 245.
[15] 邓乃扬, 田英杰. 数据挖掘中的新方法: 支持向量机[M]. 北京: 科学出版社, 2004.
[16] Valentini G, Dietterich T G. Bias - variance analysis of support vector machines for the development of SVM - based ensemble methods[J]. Journal of Machine Learning Research, 2004, 5(7): 725 - 775.