

刘祖鹏. 基于优化 PCNN 模型的黄瓜叶片病斑提取方法[J]. 江苏农业科学, 2018, 46(18): 216–221.

doi:10.15889/j.issn.1002-1302.2018.18.055

基于优化 PCNN 模型的黄瓜叶片病斑提取方法

刘祖鹏

(河南工学院电子通信工程系, 河南新乡 453000)

摘要: 黄瓜叶部病斑的精确提取是计算机视觉技术在黄瓜病害识别系统中应用的关键。由于黄瓜叶部病斑形态小、光照不均匀、背景复杂等特性, 导致现有的病斑提取方法精度较差。针对这一问题, 提出一种基于优化脉冲耦合神经网络(pulse coupled neural network, 简称 PCNN)模型的黄瓜叶片病斑精确提取方法。首先, 对采集的病斑叶片进行 Lab 颜色空间变换, 通过对颜色分量的平均值和高斯滤波结果进行差值计算, 获取病斑叶片的频率调谐视觉显著性图; 接着, 对病斑图像进行 HSI 颜色空间变换, 提取色调(hue, 简称 H)分量, 进行色调的均衡优化, 并通过融合优化后的 H 参量来增强病斑叶片的频率调谐视觉显著性图; 最后, 对传统 PCNN 模型进行简化, 构建网络参量的自适应更新规则, 并将融合后的显著性图作为模型的输入参量进行病斑的分割和形态学处理, 获取病斑的提取结果。结果显示, 本研究方法能够实现在光照度改变、背景干扰等不同复杂环境下对黄瓜常见病斑图像进行精确提取, 试验结果为后续病害精确识别奠定了较好的基础。

关键词: 智能化农业; 计算机视觉; 黄瓜病斑叶片; 病斑提取; 脉冲耦合神经网络模型

中图分类号: TP391 **文献标志码:** A **文章编号:** 1002-1302(2018)18-0216-05

黄瓜叶片病斑的精确提取是计算机视觉技术在黄瓜病害识别系统中应用的关键技术之一, 是农业智能化的重要组成部分^[1-2]。近年来, 随着计算机视觉技术在农业智能化系统中的应用, 基于机器视觉的农作物产品图像分割与识别受到了广泛的关注^[3-6]。研究人员先后对葡萄、草莓、苹果的果实成熟问题进行了深入的分析和研究。通过利用图像分割技术、图像识别技术, 并联合具体应用对象的特征进行优化和改进, 取得了一定的成果。先后提出了 Ostu 分割方法^[7]、K-mean 聚类方法^[8]、反向传播神经网络方法^[9]、径向基神经网络方法^[10]、LBP 滤波算法^[11]等, 实现了成熟果实的智能化提取和识别。基于同样的原理, 研究人员将相关方法分别引入到农作物病害特征的提取和识别领域。田杰等采用主成分分析和高斯混合模型联合的方法对小麦病害进行提取和识别, 但须要根据小麦病害的先验知识进行高斯混合模型的构建^[12]; 杨国等采用卷积神经网络的深度学习模型来进行茶叶害虫的定位和识别, 取得了较高的定位和识别精度^[13], 但该方法须要丰富的样本进行离线训练, 当训练样本不足时, 容易产生样本数据的统计失配问题, 且算法的实时性较差; Ostu 将 Ostu 分割方法引入到黄瓜靶斑病的提取当中, 通过采用双颜色空间取得了较好的分割效果, 但是对于较小的病斑斑点无法进行有效分割^[14]; 张芳等将超像素和 K-mean 聚类方法结合进行黄瓜病害叶片的分割, 有效提升了小块情况下的分割精度, 但是对于光照度变化的叶片分割精度较差^[15]; 韩青松将超像素同视觉显著性特点联合进行黄瓜病斑的分割, 实现了常见黄瓜病斑的有效提取^[16], 但该方法在光照度较弱情

况下的分割效果较差, 错分率较大。

针对黄瓜叶片病斑提取背景的复杂性, 本研究提出一种多特征融合表征与优化脉冲耦合神经网络(pulse coupled neural network, 简称 PCNN)模型联合的提取方法。该方法首先对采集的黄瓜病斑叶片进行 Lab 颜色空间变换, 通过颜色分量的平均值和高斯滤波后的值进行差值计算, 获取病斑叶片的频率调谐视觉显著性图; 接着, 对采集的病斑图像进行 HIS 颜色空间转换, 并提取色调(hue, 简称 H)分量, 对其进行均衡处理, 并同视觉显著性图联合实现病斑特征的联合表达; 最后, 为便于对病斑进行建模分析, 对传统的 PCNN 模型进行简化处理。同时, 为了适应不同的复杂环境, 提出模型参量自适应优化方法, 并将融合后的特征作为模型的输入参量, 对模型的输出结果进行形态学处理, 获取最终的病斑提取结果。基于采集的 100 幅黄瓜常见病斑叶片图像进行详细的试验分析, 并对本研究方法的提取精度和计算复杂度进行详细的分析。

1 叶片病斑图像的特征表达

1.1 视觉显著性特征提取

频率调谐视觉显著性特征是 Achanta 在 2009 年提出的一种图像频域分析的特征, 通过将图像映射到 Lab 空间, 获取图像整体的颜色平均值, 并同高斯滤波后的图像进行差值计算, 获取相应的频率调谐视觉显著性特征^[17], 计算公式为

$$S(x, y) = \|I_{\mu} - I_{\omega_{\mu}}(x, y)\| = \sqrt{(L_{\mu} - L_{\omega_{\mu}})^2 + (a_{\mu} - a_{\omega_{\mu}})^2 + (b_{\mu} - b_{\omega_{\mu}})^2} \quad (1)$$

其中,

$$I_{\mu} = \begin{bmatrix} L_{\mu} \\ a_{\mu} \\ b_{\mu} \end{bmatrix}, I_{\omega_{\mu}}(x, y) = \begin{bmatrix} L_{\omega_{\mu}} \\ a_{\omega_{\mu}} \\ b_{\omega_{\mu}} \end{bmatrix}。$$

收稿日期: 2018-01-06

基金项目: 河南省高等学校重点科研项目(编号: 14A510025)。

作者简介: 刘祖鹏(1980—), 男, 河南新乡人, 硕士, 讲师, 研究方向为图像处理。E-mail: chenxuefeng2046@163.com。

式中: $S(x, y)$ 表示像素点 (x, y) 的频率调谐视觉显著性值; μ 为图像 Lab 空间的色度平均值; ω_{hc} 表征经过高斯滤波以后图像的特征分量; $I_{\omega_{hc}}(x, y)$ 为经过相应高斯滤波处理以后特征分量的矩阵; I_{μ} 为特征分量的平均值; $\|g\|$ 表征欧式距离的计算。根据文献[18], 可以将频率调谐视觉显著性的高斯滤波表示为高斯差分的累加和, 即

$$F_N = \sum_{n=0}^{N-1} DOG(x, y) = \sum_{n=0}^{N-1} [G(x, y, \rho^{n+1} \sigma) - G(x, y, \rho^n \sigma)]。 \quad (2)$$

式中: F_N 、 N 分别表示差分等价的带通滤波器、高斯差分次数; $DOG(x, y)$ 为高斯差分计算; $G(x, y, \rho^n \sigma)$ 表示像素点 (x, y) 处的高斯滤波算子, σ 、 ρ^n 分别为算子的标准差、调节因子。根据文献[18], 设置 ρ^{n+1} : $\rho^n = 1.0 : 1.6$ 。

图 1 分别为黄瓜褐斑病、霜霉病的频率调谐视觉显著性特征提取结果, 可以看出, 视觉显著性图可以明显增强图像边缘特征和大块病斑的提取效果, 但对较小的病斑分割效果较差。




图 1 黄瓜病害频率调谐视觉显著性特征提取结果

1.2 色调均衡补偿的特征增强


视觉显著性特征提取方法对小块病斑提取精度较差, 主要是由于光照度变化会改变图像的灰度值, 影响较小病斑的提取精确性。为进一步降低小病斑对光照度的敏感性, 引入 HSI 颜色空间的 H 分量对病斑图像进行增强, 主要是因为 H 不受光照度影响。本研究在进行 H 分量的提取过程中, 参照文献[19]的方法, 首先对图像进行均衡化调整, 以增强图像局部颜色改变处的对比度信息, 从而增强捕获病斑与周围颜色细节的差异。均衡化以后可以将 H 分量和频率调谐视觉显著性图融合后的特征表示为

$$I_{\text{fusion}}(x, y) = \sqrt{H(x, y)S(x, y)}。 \quad (3)$$

式中: $I_{\text{fusion}}(x, y)$ 为像素点 (x, y) 的融合特征; $H(x, y)$ 、 $S(x, y)$ 分别表示该像素点处的均衡化 H 值、频率调谐视觉显著性值。通过 H 分量的引入, 可以有效增强病斑图像的轮廓信息, 有效提升较小病斑的区分能力。图 2 为图 1 提取结果经过均衡化 H 分量增强以后的结果, 可以看出, 通过色调均衡补偿后的显著性图得到了明显增强, 特别是较小的病斑也得到了较好的分割效果。

2 改进的 PCNN 模型

PCNN 模型作为一种神经网络模型的分支, 具有不需要



a. 黄瓜褐斑病

b. 黄瓜霜霉病

图 2 黄瓜病害色调均衡补偿后的显著性特征提取结果

训练, 可以同步实现性质相同神经元捕捉的良好特性, 目前被广泛应用在图像分割领域^[20-21]。但传统的 PCNN 模型过于复杂, 不适合病斑的提取, 另外, 传统的 PCNN 模型中采用固定参量建模的方法, 对不同复杂背景条件下的适应性较差, 针对这一问题, 本研究对 PCNN 模型从以下 2 点进行改进: (1) 针对病斑提取的独特性, 简化模型结构、降低运算的复杂性; (2) 构建模型参量的自适应更新方法, 提升模型的抗噪能力和对不同环境的适应性。

2.1 基于 PCNN 模型的病斑提取原理

传统的 PCNN 模型单个神经元的离散迭代计算过程^[22]如下:

$$F_{ij}(n) = \exp(-\alpha_F) F_{ij}(n-1) + V_F \sum_{kl} M_{ij,kl} Y_{kl}(n-1) + S_{ij}; \quad (4)$$

$$L_{ij}(n) = \exp(-\alpha_L) L_{ij}(n-1) + V_L \sum_{kl} W_{ij,kl} Y_{kl}(n-1); \quad (5)$$

$$U_{ij}(n) = F_{ij}(n) [1 + \beta L_{ij}(n)]; \quad (6)$$

$$Y_{ij}(n) = \text{step}[U_{ij}(n) - E_{ij}(n-1)] = \begin{cases} 1, & U_{ij}(n) > E_{ij}(n-1) \\ 0, & U_{ij}(n) \leq E_{ij}(n-1) \end{cases}; \quad (7)$$

$$E_{ij}(n) = \exp(-\alpha_E) E_{ij}(n-1) + V_E Y_{ij}(n)。 \quad (8)$$

PCNN 主要是基于像素进行计算, 公式(4)和公式(5)为 PCNN 模型的基本构成单元。其中, $F_{ij}(n)$ 、 $L_{ij}(n)$ 分别表示输入场的反馈值、连接值; $M_{ij,kl}$ 、 $W_{ij,kl}$ 分别表示针对反馈值与连接值的 1 次迭代输出 $Y_{kl}(n-1)$ 的权值矩阵; S_{ij} 为提取的色调均衡优化的视觉显著性图; V_F 、 α_F 分别为反馈输入场中的放大系数、衰减时间常数; V_L 、 α_L 分别为连接输入场中的放大系数、衰减时间常数。公式(6)中的 $U_{ij}(n)$ 表示内部调制场参量; β 为联通强度。公式(7)为 1 次点火实现, $\text{step}(g)$ 表示阶跃函数, 其功能是基于动态阈值 $E_{ij}(n-1)$ 来度量 $U_{ij}(n)$, 当 $U_{ij}(n) > E_{ij}(n-1)$ 时, 产生脉冲点火输出 $Y_{ij}(n) = 1$, 目的是在每一次迭代中都能有效提取性质相同的像素点; n 为迭代次数。公式(8)表征了动态阈值 $E_{ij}(n)$ 的组成, V_E 、 α_E 分别表示放大系数、衰减时间常数。

2.2 对 PCNN 模型的改进

传统 PCNN 模型参量复杂, 且无法自适应更新, 提取精度严重依赖经验值的设定^[23]。本研究改进后的 PCNN 单个神经元结构如图 3 所示, 其具体的工作原理可以表示为

$$F_{ij}(n) = \sum_{k,l} M_{ij,kl} S_{kl}; \quad (9)$$

$$L_{ij}(n) = \sum_{k,l} W_{ij,kl} Y_{kl}(n-1); \quad (10)$$

$$U_{ij}(n) = F_{ij}(n) [1 + \beta L_{ij}(n)]; \quad (11)$$

$$E_{ij}(n) = V_E \bar{m}(n)。 \quad (12)$$

其中, $\bar{m}(n)$ 为病斑像素平均值, 从公式(9)~公式(12)可以看出, 改进后的模型在输入场中简化了功能单元, 删除了

指数衰减项,并重新定义了反馈输入域 $F_{ij}(n)$,单一采用以像素 (i,j) 为中心的 8 个邻域内输入图像的显著性图矩阵 S_{kl} ,联合权重矩阵 $M_{ij,kl}$ 耦合形成。连接输入场 $L_{ij}(n)$ 同样定义为由 8 邻域内神经元的迭代输出与 $W_{ij,kl}$ 构成。公式 (11) 中的连接强度 β 通过表征图像局部细节特征的修正拉普拉斯绝对和 (sum of modified laplacian, 简称 SML) 计算,实现自适应优化。公式 (12) 中的 $E_{ij}(n)$ 同样删减了不适合小病斑提取的指数衰减参量,利用每次点火输出区域的显著性图计算该值,确保了 PCNN 模型的振荡,具体的点火机制同公式 (7)。

3 参量的自适应优化分析

从“2.2”节的分析中可以看出,该简化模型很好地适应了小病斑的检测。由图 3 可知,本研究改进方法主要包括输入场、调制场、脉冲产生器等 3 个部分。且改进模型的关键参量分别是输入场的反馈权重矩阵 $M_{ij,kl}$ 和连接权重矩阵 $W_{ij,kl}$ 、调制场的连接强度 β 以及脉冲产生器的动态阈值 $E_{ij}(n)$ 。

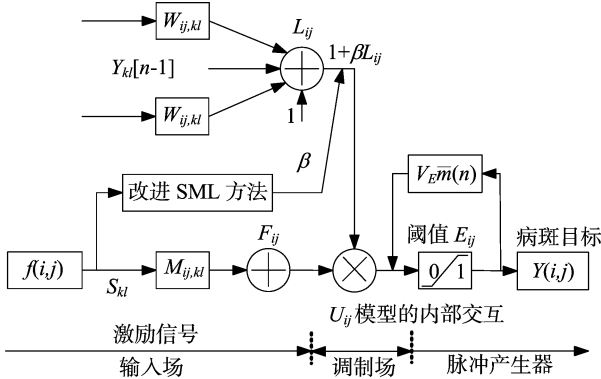


图3 改进 PCNN 模型的单个神经元结构

3.1 输入场的权值矩阵优化

在反馈输入场中利用权值矩阵 $M_{ij,kl}$ 对图像的输入特征进行预处理,实现对图像空间噪声的抑制,保护边缘细节特征,并有效调节与距离相关的神经元单元。传统基于高斯滤波的差值计算方法容易导致图像边缘模糊、丢失细节特征,为增强图像的细节特征,本研究采用各项异性特征对高斯滤波器进行改进^[15],改进后的矩阵 $M_{ij,kl}$ 可表示为

$$M_{ij,kl} = \begin{cases} C_0 g \frac{1}{\| (i,j) - (k,l) \|} \\ Y_{ij}(n-1) \times \text{or} Y_{kl}(n-1) = 1 \\ C_1 g \frac{1}{2\pi\sigma_i\sigma_j} \exp \left[-\frac{1}{2} \left(\frac{\|i-k\|^2}{\sigma_i^2} + \frac{\|j-l\|^2}{\sigma_j^2} \right) \right], \text{otherwise} \end{cases} \quad (13)$$

式中: $Y_{ij}(n-1) \times \text{or} Y_{kl}(n-1) = 1$ 主要实现图像椒盐噪声的定位。获取定位信息以后,可以通过 8 个邻域的神经元与中心神经元的欧式距离倒数 ($\frac{1}{\| (i,j) - (k,l) \|}$) 计算权值矩阵; C_0 、 C_1 均为归一化系数; $\|i-k\|^2$ 为水平神经元之间距离的平方; $\|j-l\|^2$ 为垂直神经元之间距离的平方; σ_i 、 σ_j 均为高斯尺度因子,在本研究中分别取值为 1、3。

同时,可以计算连接输入场的权值矩阵 $W_{ij,kl}$,具体公式为

$$W_{ij,kl} = \frac{1}{\| (i,j) - (k,l) \|} \quad (14)$$

3.2 调制场的连接强度优化

在本研究黄瓜病斑的分割中,旨在更多地保留图像的边缘细节,使最终病斑分割结果轮廓清晰,以便于后续的病态识别。因此,在具有相似边缘特征的像素点处提升其连接强度 β 的大小,使之更容易被 PCNN 模型捕获而点火输出。考虑到 SML 利用二阶拉普拉斯梯度来表达局域范围内灰度的跳变程度具有很好的图像纹理和方向信息描述能力,可以将像素 (i,j) 的拉普拉斯分量绝对和^[21]定义为

$$\nabla_{ML}^2 f(i,j) = |2f(i,j) - f(i-s,j) - f(i+s,j) + 12f(i,j) - f(i,j-s) - f(i,j+s)| \quad (15)$$

式中: s 为计算中的空域间隔,由于传统的 SML 方法中忽略了倾斜方向的梯度信息,因此在 $s=1$ 的情况下,可以将公式 (15) 进一步改进为

$$\nabla_{\text{Imp-ML}}^2 f(i,j) = |2f(i,j) - f(i-1,j) - f(i+1,j) + 12f(i,j) - f(i,j-1) - f(i,j+1) + 12f(i,j) - f(i-1,j-1) - f(i+1,j-1) + 12f(i,j) - f(i-1,j+1) - f(i+1,j+1)| \quad (16)$$

当图像特征出现边缘跳变时,公式 (16) 能够获取较大的 SML 值,提取较小的病斑区域。因此,同构对图像进行改进后的 SML 计算,可以通过自适应修正连接强度 β 进行病斑边缘的点火输出,其中连接强度的优化计算表达式为

$$\beta(i,j) = G_n [S_{ML}(i,j)] = G_n \left[\sum_{i=x-N}^{x+N} \sum_{j=y-N}^{y+N} \nabla_{\text{Imp-ML}}^2 f(i,j) \right] \quad (17)$$

式中: $G_n[g]$ 为实现归一化的函数运算; N 表示选择的邻域窗口的大小,本研究中 $N=3$; $S_{ML}(i,j)$ 表示计算的 SML 值。

3.3 脉冲产生器的动态阈值优化

对于病斑叶片而言,正常的颜色为绿色,病斑颜色为非绿色,本研究采用超绿特征 $E \times G$ 进行特征提取^[24],其灰度值计算公式为

$$E_{(x,y)} = \begin{cases} 255, 2G - R - B > 255 \\ 2G - R - B, \text{else} \\ 0, 2G - R - B < 0 \end{cases} \quad (18)$$

式中: $E_{(x,y)}$ 为像素点 (x,y) 处的灰度值; R 、 G 、 B 分别表示该像素点在红、绿、蓝颜色空间的取值。获取灰度图后,此时病斑区域的灰度值相对较高,设置动态阈值时系统通过迭代递进的方法,令灰度值相对较高的区域为最终稳定地点火输出。采用公式 (9) 表达的动态阈值设置方法,取其为 PCNN 每一次迭代分割出的区域在原图像上的平均灰度值 $\bar{m}(n)$ 与放大系数 V_E 的乘积,其中, $\bar{m}(n)$ 可以计算为

$$\bar{m}(n) = \frac{\sum_{(u,v) \in \Omega} f(u,v)}{N} \quad (19)$$

$$\Omega = \{ (i,j) | i,j | Y_{ij}(n) = 1 \}$$

式中: Ω 为第 n 次迭代 PCNN 点火输出的区域矩阵; $f(u,v)$ 为点火输出区域内原输入融合特征矩阵的每一个元素值; N 为点火区域内总的元素个数。 $\bar{m}(n)$ 的初始迭代值设置为 0。动态阈值 $E_{ij}(n)$ 随着 PCNN 迭代的进行不断增大,导致每次迭代 PCNN 分割出的区域不断缩小;同时,区域的平均灰度值将不断增加,直到最终输出不再变化时,输出区域的平均值已经逼近了病斑区域的平均值,停止迭代,输出分割结果。通过这样的机制使改进的 PCNN 分割模型可以实现自适应的迭代

停止控制。放大系数 V_E 为控制平均值增长速度的系数,在本研究中 $V_E = 1$ 。

4 验证试验与结果分析

4.1 试验设置说明

为验证本研究方法的有效性,对采集的黄瓜叶片常见病斑进行检测分析。试验中共采集 6 种常见的黄瓜叶斑病(白粉病、黑斑病、霜霉病、慢枯病、角斑病、红粉病)的 100 幅相关病斑叶片图像。为便于运算,将图像全部归一化到像素。采用 Intel® Core™ i7 - 3520M 4.0 GHz CPU, 8 GB RAM 笔记本电脑,安装 Window 7 操作系统,图像分析程序在 Visual C++ 2010 平台编程实现,采用 C++ 语言编写,便于不同平台之间的移植使用。试验的检测流程如图 4 所示,首先,针对采集到的病斑叶片图像进行相关参量的初始化处理;接着进行 Lab 颜色空间 3 个分量和 HIS 颜色空间的 H 分量提取,并进行特征显著性和 H 分量均衡化处理,实现特征的融合表征;最后,将融合后的特征图像作为改进 PCNN 模型的输入图像,并对模型输出图像进行一定的形态学处理,获取最终的病斑识别结果。

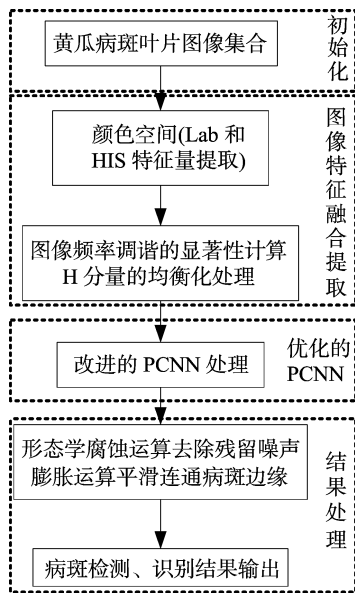


图4 本研究方法的检测流程

4.2 病斑提取精度的定性分析

首先,针对采集的病斑叶片进行不同背景条件下病斑提取结果的定性分析。为便于定性对比,试验中分别采用 Otsu 方法、K-means 聚类方法、传统 PCNN 方法、本研究方法进行病斑的提取分析。由图 5 可知,在强光照度且背景相对简单的情况下,几种方法都取得了较好的分割结果,但由于光照度变化的影响,导致 Otsu 方法、K-means 聚类方法、传统 PCNN 方法在叶片的边缘和叶片与枝干连接的地方提取效果较差,主要原因是这些方法没有考虑到光照度变化对病斑图像特征的影响。由于本研究方法采用了多特征融合的方法,可以看出,本研究方法较好地适应光照度的变化。由图 6 可知,由于光线较暗且背景干扰比较复杂,导致 Otsu 方法、K-means 聚类方法分割结果较差,而传统 PCNN 方法分割精度有所提升。但由于传统 PCNN 方法的分割阈值平均值仍为固定设置,导

致在光照度较弱的情况下,病斑与背景信息的颜色可分性降低,将部分背景信息分割为病斑。而本研究方法采用了自适应参量的实时更新方法,可以看出,分割结果十分接近真实的病斑分布。




图5 强光照度、简单背景下黄瓜白粉病病斑提取结果




图6 弱光照度、复杂背景下黄瓜霜霉病病斑提取结果

4.3 病斑提取精度的定量分析

为定量对比分析本研究方法的分割精度,采用错分率 (E_R) 对提取结果进行比较。其中,错分率的具体计算公式可

以表示为

$$E_R = \frac{N_c}{N_a} \times 100\%。$$
 (20)

式中： N_a 、 N_c 分别表示叶片图像的总像素数量、病斑错误提取的像素数量。

试验中针对采集的 100 幅病斑叶片图像进行统计分析，并计算平均错分率。从“4.2”节的定性分析中可以明显看出，Otsu 方法采用了阈值分割的方法，其效果较差，因此，在该部分定量比较中，为了方便计算，不对其进行定量计算，直接针对后 3 种提取精度相对较高的方法（K-means 聚类方法、传统 PCNN 方法、本研究方法）进行定量计算分析。由表 1 可知，对 6 种常见的黄瓜病害，本研究方法的错分率较低，最小错分率为 1.9%，最大错分率为 4.5%，提取精度明显优于传统 PCNN 方法和 K-means 聚类方法，对提取精度而言，本研究方法是一种优秀的方法。

表 1 3 种方法的平均错分率

| 黄瓜病害 | 不同方法的错分率(%) | | |
|------|--------------|------------|-------|
| | K-means 聚类方法 | 传统 PCNN 方法 | 本研究方法 |
| 白粉病 | 19.9 | 16.4 | 4.5 |
| 黑斑病 | 43.9 | 15.4 | 3.2 |
| 霜霉病 | 49.2 | 20.3 | 2.2 |
| 角斑病 | 37.6 | 21.8 | 2.4 |
| 慢枯病 | 21.1 | 17.2 | 2.2 |
| 红粉病 | 37.2 | 11.7 | 1.9 |

4.4 算法复杂性分析

病斑提取速度的快慢是进行后续机器视觉识别应用的关键。为度量本研究方法的计算复杂性，对采集的 100 幅病斑图像进行病斑提取速度分析。由表 2 可知，由于 K-means 聚类方法主要是针对像素级别进行聚类，时间消耗较大；传统的 PCNN 方法由于采用邻域块的操作，即使引入了一些约束和迭代思想，但最终的运行时间仍小于 K-means 聚类方法，具有较为合理的时间效率；而本研究方法虽然增加了颜色空间的变换和特征融合处理，但在 PCNN 模型参量的计算过程中有针对性进行了简化处理，因此，一定程度上降低了本研究方法的计算复杂性，整体比传统 PCNN 方法的效率有了一定的提升。

表 2 3 种方法的运行时间

| 黄瓜病害 | 运行时间(s) | | |
|------|--------------|------------|-------|
| | K-means 聚类方法 | 传统 PCNN 方法 | 本研究方法 |
| 白粉病 | 18.87 | 8.56 | 8.03 |
| 黑斑病 | 18.98 | 9.83 | 9.14 |
| 霜霉病 | 11.02 | 7.14 | 7.23 |
| 角斑病 | 16.03 | 10.45 | 9.96 |
| 慢枯病 | 12.37 | 7.87 | 7.03 |
| 红粉病 | 11.52 | 10.44 | 8.91 |

5 结论与讨论

本研究针对不同复杂背景下黄瓜病害叶片的病斑精确提取和识别问题进行了分析，提出了一种联合多特征融合表征和脉冲耦合神经网络模型的病斑精确提取方法，对黄瓜叶片病斑进行有效识别。从黄瓜常见病斑叶片的检测分析结果可

以看出，本研究方法具有较高的精度。与现有的分割和识别方法相比，本研究方法具有以下几点创新：（1）对采集的黄瓜病斑原始图像进行了 Lab 和 HIS 颜色空间的变换处理，有效提升了特征的鲁棒性。特别是在光照度改变的情况下，本研究提取的特征具有更加有效的表征性。本研究方法的最小错分率为 1.9%，最大错分率为 4.5%，与 K-means 聚类算法和传统 PCNN 方法相比，均有较大改善。（2）本研究方法采用 PCNN 模型进行迭代分割，与传统的神经网络模型相比，不须要进行大量图像的离线运算，因此可以达到较好的实时性效果。（3）本研究对 PCNN 模型输入场、调制场、脉冲形成等 3 个阶段的关键参量进行了优化，针对具体的应用场景实现了自适应处理，增强了模型对不同复杂背景下的实用性。

在下一步的研究中，将进一步优化该方法在实际应用平台中的应用，通过农作物智能物联系统构建完善的黄瓜生长智能分析和识别系统。

参考文献：

[1] 吴海华, 方宪法, 杨炳南. 国内外农业装备技术发展趋势及进展[J]. 农业工程, 2013, 3(6): 20-23.

[2] 李文勇, 李明, 陈梅香, 等. 基于机器视觉的作物多姿态害虫特征提取与分类方法[J]. 农业工程学报, 2014, 30(14): 154-162.

[3] 陈梅香, 杨信延, 石宝才, 等. 害虫自动识别与计数技术研究进展与展望[J]. 环境昆虫学报, 2015, 37(1): 176-183.

[4] Belongie S, Malik J, Puzicha J. Shape matching and object recognition using shape contexts[J]. Pattern Analysis and Machine Intelligence, 2002, 24(4): 509-522.

[5] 史庆才, 李向阳, 陈志伟, 等. 茶园假眼小绿叶蝉的防控技术研究进展[J]. 农学学报, 2015, 5(1): 20-24.

[6] 张红涛, 毛罕平, 邱道尹. 储粮害虫图像识别中的特征提取[J]. 农业工程学报, 2009, 25(2): 126-130.

[7] Camargo A, Smith J S. An image-processing based algorithm to automatically identify plant disease visual symptoms[J]. Biosystems Engineering, 2009, 102(1): 9-21.

[8] 温长吉, 王生生, 于合龙, 等. 基于改进蜂群算法优化神经网络的玉米病害图像分割[J]. 农业工程学报, 2013, 29(13): 142-149.

[9] 关海鸥, 许少华, 谭峰. 基于 T-S 模型的模糊神经网络在植物病害图像分割中的应用[J]. 中国农业大学学报, 2011, 16(3): 145-149.

[10] Oberti R, Marchi M, Tirelli P, et al. Automatic detection of powdery mildew on grapevine leaves by image analysis: optimal view angle range to increase the sensitivity[J]. Computers and Electronics in Agriculture, 2014, 104: 1-8.

[11] 朱林, 赵健, 冯全, 等. 基于 LBP 滤波和 ACWE 的葡萄病害图像分割方法[J]. 中国农机化学报, 2014, 35(6): 99-104.

[12] 田杰, 韩冬, 胡秋霞, 等. 基于 PCA 和高斯混合模型的小麦病害彩色图像分割[J]. 农业机械学报, 2014, 45(7): 267-271.

[13] 杨国国, 鲍一丹, 刘子毅. 基于图像显著性分析与卷积神经网络的茶园害虫定位与识别[J]. 农业工程学报, 2017, 33(6): 156-162.

[14] Otsu N. A threshold selection method from gray-level histogram[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.

[15] 张芳, 王璐, 付立思, 等. 复杂背景下黄瓜病害叶片的分割方法研究[J]. 浙江农业学报, 2014, 26(5): 1346-1355.

孙毅. 基于 BP 神经网络的土壤侵蚀预测模型对比[J]. 江苏农业科学, 2018, 46(18): 221–224.
doi:10.15889/j.issn.1002-1302.2018.18.056

基于 BP 神经网络的土壤侵蚀预测模型对比

孙毅

(太原理工大学水利科学与工程学院, 山西太原 030024)

摘要:根据《中国水土保持公报》数据资料, 基于反向传播(back propagation, 简称 BP)神经网络模型、万有引力搜索算法(gravitational search algorithm, 简称 GSA)和人群搜索算法(seeker optimization algorithm, 简称 SOA)优化的 BP 神经网络模型, 研究以土壤类型、地形、坡度、植被措施、降水为输入, 以土壤侵蚀模数为输出的 BP、GSA-BP 和 SOA-BP 模型对土壤侵蚀量的预测, 并采用典型监测点的实测数据对模型进行验证。结果表明, 3 种模型均具有较高精度, 可用于土壤侵蚀量的定量预测, 其中 SOA-BP 模型的预测效果最优。本研究成果将为水土流失监测工作提供有效支持。

关键词:万有引力搜索算法; 人群搜索算法; BP 神经网络; 土壤侵蚀模数

中图分类号: S157 **文献标志码:** A **文章编号:** 1002-1302(2018)18-0221-04

1 研究背景

土地是维系人类繁衍生息的基本资源。水土流失现象危害极严重, 首先会直接导致可耕作土地资源的减少^[1], 其次流失的土壤会引起河道的淤积问题^[2], 此外水土流失也是土壤养分流失的重要诱因^[3]。因此, 开展水土流失机制、防治和预报等方面的工作, 对环境保护、农业增产和促进经济社会的可持续性发展具有极其重要的作用和意义。

目前, 诸多学者从水土流失机制和预测 2 个方面开展了较多的科学研究, 并取得了一定的成果。在水土流失机制方面, 主要开展了降水^[4-5]、坡度和坡型^[6-7]、植被类型和植被覆盖度^[8-9]、土壤类型^[10-11]、耕作措施^[12-13]对土壤侵蚀量的影响研究, 结果表明, 这几项因素对侵蚀量的影响均较为显著。在土壤侵蚀预测方面, 主要构建了一系列的经验模型^[14-16]和物理模型^[17-18], 随着人工智能算法的发展, 反向传播(back propagation, 简称 BP)神经网络在土壤侵蚀预测方面得到了广泛的应用^[19-23]。但前人建立的模型输入项常常忽

略了一些重要因素, 主要包括植被覆盖程度^[20]、土质因素^[21-22]、降水^[23]等。此外, 前人所建立的模型还存在适用范围小、所采用的传统算法存在搜索空间大, 易陷入局部极值点等问题, 这几点限制了前人建立的模型在实际预测中的广泛应用。因此, 对全国较大范围内土壤侵蚀量预测的研究有待进一步深入, 模型优化算法的改进也是十分必要的。

万有引力搜索算法(gravitational search algorithm, 简称 GSA)和人群搜索算法(seeker optimization algorithm, 简称 SOA)具有较好的收敛速度和寻优精度。目前, 基于万有引力算法和人群搜索算法优化后的 BP 神经网络模型在水土流失方面的预测还未见相关报道, 同时哪种模型更适合土壤侵蚀预测研究同样也有待进一步深入。因此, 本研究旨在构建基于万有引力算法和人群搜索算法优化的 BP 神经网络模型, 实现土壤侵蚀的准确预报, 以期水土流失预测工作提供支持。

2 BP 神经网络模型原理

BP 神经网络是目前应用最广泛的神经网络模型之一。图 1 为 BP 神经网络的工作原理和基本网络结构, 它主要由输入层、隐含层和输出层 3 部分构成, m 、 q 、 n 分别为这 3 层神经元的节点数, 三者的职责各不相同, 输入层负责接收外界输入信息、隐含层负责内部信息的变换处理、输出层负责向外界传输处理结果。完成 1 次完整的正向传播处理后, 若输出信息与期望不吻合, 便进入误差反向传播机制, 通过不断调整

收稿日期: 2017-01-12

基金项目: 山西省国际科技合作项目(编号: 2013081034); 山西省水利厅水利技术与推广项目; 2015 年山西省研究生教育创新项目(编号: 2015SY18)。

作者简介: 孙毅(1990—), 男, 山西吕梁人, 硕士研究生, 研究方向为水文及水资源。E-mail: 462427080@qq.com。

[16] 韩青松. 基于 Otsu 算法的遥感图像阈值分割[D]. 乌鲁木齐: 新疆大学, 2011.

[17] 张善文, 张云龙, 尚怡君. 一种基于 Otsu 算法的植物病害叶片图像分割方法[J]. 江苏农业科学, 2014, 42(4): 337–339.

[18] 彭红星, 邹湘军, 陈丽娟, 等. 基于双次 Otsu 算法的野外荔枝多类色彩目标快速识别[J]. 农业机械学报, 2014, 45(4): 61–68.

[19] 龚立维. 基于 Com VI 和双阈值 OTSU 算法的农作物图像识别[J]. 排灌机械工程学报, 2014, 32(4): 363–368.

[20] Bai X D, Cao Z G, Wang Y, et al. Crop segmentation from images by morphology modeling in the CIE L*a*b color space[J].

Computers and Electronics in Agriculture, 2013, 99(7): 21–34.

[21] 杨立军, 封生霞, 张雪霞. 黄瓜靶斑病的发生规律及综合防治措施[J]. 现代农业科技, 2012(22): 136.

[22] 韩小爽, 高 苇, 傅俊范, 等. 黄瓜棒孢叶斑病的诊断与防治[J]. 中国蔬菜, 2011(9): 20–21.

[23] 吴 娜, 李 淼, 陈 晟, 等. 基于融合多特征图切割的作物病害图像自动分割[J]. 农业工程学报, 2014, 30(17): 212–219.

[24] Cheng M M, Mitra N J, Huang X, et al. Global contrast based salient region detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 569–582.