



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2016
01
VOL.21

ISSN1006-8961
CN11-3758/TB



医学图像处理 P69

中国图象图形学报

刊名题字：宋健 | 月刊（1996年创刊）



第21卷第1期（总第237期）
2016年1月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 李小文
编辑出版《中国图象图形学报》编辑出版委员会
邮政信箱 北京9718信箱
邮 编 100101
电子信箱 jig@radi.ac.cn
电 话 010-64807995
网 址 www.cjig.cn

广告经营许可证 京朝工商广字第0361号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics


Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Institute of Remote Sensing and Digital Earth, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief LI Xiaowen
Editor, Publisher Editorial and Publishing Board of Journal of
Image and Graphics
P.O.Box 9718, Beijing, P.R.China
Zip code 100101
E-mail jig@radi.ac.cn
Telephone 010-64807995
Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ
国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



多尺度特征融合与极限学习机的玉米种子检测
(第0024页)



深度卷积神经网络的显著性检测(第0053页)



双树复小波域的MRI图像去噪(第0104页)

图像处理和编码

空时形状预测与高效编码

朱仲杰, 王玉儿, 蒋刚毅..... 1

第二小方向导数信息熵的兴趣点检测

卢健, 黄杰, 潘峰..... 8

采用面积采样的反走样字符旋转算法

郑凯文, 刘文波..... 17

图像分析和识别

多尺度特征融合与极限学习机的玉米种子检测

柯道, 杜明智..... 24

图像理解和计算机视觉

结合NSCT和压缩感知的红外与可见光图像融合

陈木生..... 39

Plücker直线描述的空间后方交会

盛庆红, 陈姝文, 肖晖, 张斌, 王青, 费利佳..... 45

深度卷积神经网络的显著性检测

李岳云, 许悦雷, 马时平, 史鹤欢..... 53

计算机图形学

以优先点为中心的Delaunay三角网生长算法

尤磊, 唐守正, 宋新宇..... 60

医学图像处理

快速数字影像重建的2维/3维医学图像配准

刘坤, 吕晓琪, 谷宇, 于荷峰, 任国印, 张明..... 69

小波-Lagrange方法进行医学图像层间插值

武士想, 尚鹏, 王立功..... 78

遥感图像处理

多主体框架下结合最大期望值和遗传算法的SAR图像分割

张金静, 李玉, 赵泉华..... 86

第十届图像图形技术与应用学术会议

视差互信息引导下的立体航空影像与LiDAR点云自动配准

吴军, 胡彦君, 饶云, 彭智勇..... 95

双树复小波域的MRI图像去噪

黄学优, 张长江..... 104

快速定位图像尺度和区域的3维跟踪算法


赵奇可, 孙延奎..... 114

局部不变特征点的精度指标

滕日, 周进, 蒋平, 崔雄文..... 122

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Detection of maize seeds based on multi-scale feature fusion and extreme learning machine(P0024)



Saliency detection based on deep convolutional neural network(P0053)



MRI denoising based on dual-tree complex wavelet transform(P0104)

Image Processing and Coding

- Spatio-temporal shape prediction and efficient coding
Zhu Zhongjie, Wang Yuer, Jiang Gangyi 1
- Interest point detection by using information entropy of the second small direction derivative
Lu Jian, Huang Jie, Pan Feng 8
- Anti-aliasing algorithm for character rotation based on area sampling
Zheng Kaiwen, Liu Wenbo 17

Image Analysis and Recognition

- Detection of maize seeds based on multi-scale feature fusion and extreme learning machine
Ke Xiao, Du Mingzhi 24

Image Understanding and Computer Vision

- Image fusion of visual and infrared image based on NSCT and compressed sensing
Chen Musheng 39
- Space resection method based on Plücker line
Sheng Qinghong, Chen Shuwen, Xiao Hui, Zhang Bin, Wang Qing, Fei Lijiao 45
- Saliency detection based on deep convolutional neural network
Li Yueyun, Xu Yuelei, Ma Shiping, Shi Hehuan 53

Computer Graphics

- Growth algorithm centered on priority point for constructing the Delaunay triangulation
You Lei, Tang Shouzheng, Song Xinyu 60

Medical Image Processing

- The 2D/3D medical image registration algorithm based on rapid digital image reconstruction
Liu Kun, Lyu Xiaoqi, Gu Yu, Yu Hefeng, Ren Guoyin, Zhang Ming 69
- Inter-slice interpolation for medical images by using the wavelet-lagrange method
Wu Shixiang, Shang Peng, Wang Ligong 78

Remote Sensing Image Processing

- Combining the expectation maximization and genetic algorithms for SAR image segmentation within a MAS framework
Zhang Jinjing, Li Yu, Zhao Quanhua 86

Column of IGIA' 2015

- Automatic registration of aerial stereo imagery to LiDAR data through iterative parallax mutual information computation
Wu Jun, Hu Yanjun, Rao Yun, Peng Zhiyong 95
- MRI denoising based on dual-tree complex wavelet transform
Huang Xueyou, Zhang Changjiang 104
- Three dimensional tracking with fast locating of image scale and area
Zhao Qike, Sun Yankui 114
- Extraction precision of local invariant feature points
Teng Ri, Zhou Jin, Jiang Ping, Cui Xiongwen 122

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2016)01-0024-15

论文引用格式: Ke X, Du M Z. Detection of maize seeds based on multi-scale feature fusion and extreme learning machine[J]. Journal of Image and Graphics, 2016, 21(1): 0024-0038. [柯道, 杜明智. 多尺度特征融合与极限学习机的玉米种子检测[J]. 中国图象图形学报, 2016, 21(1): 0024-0038.][DOI:10. 11834/jig. 20160104]

多尺度特征融合与极限学习机的玉米种子检测

柯道, 杜明智

1. 福州大学数学与计算机科学学院, 福州 350116; 2. 福州大学福建省网络计算与智能信息处理重点实验室, 福州 350116

摘要: **目的** 玉米种子等农作物检测是农业信息化领域中一个关键问题, 为了能够快速和准确地实现对其检测, 提出基于多尺度特征融合与极限学习机的玉米种子无损检测算法。**方法** 首先对种子特征的描述采用局部特征和全局特征相结合的特点, 局部特征采用多尺度方向梯度直方图特征, 而在全局特征上则提取 HSV 颜色模型特征。其次, 针对传统的 BP 神经网络以及 SVM 等存在训练时间长、检测速度慢的不足, 采用极限学习机作为其检测算法。此外, 为了避免样本在训练时带来的过多时间消耗, 该检测模型上采用了并行训练算法。再次, 针对原始图像分辨率过高问题所带来的检测时间以及内存消耗较大的问题, 采用一种基于局部均值的图像缩小算法。最后, 针对该文采用的滑动窗口扫描可能带来的同一对象多窗口重叠的问题, 提出了一种基于模糊聚类的局部窗口融合算法。**结果** 仿真结果表明, 提出的方法可实现对玉米种子的准确检测, 对检测样本的测试精度达到 97.66%, 同时误差控制在 0.1%。**结论** 相比传统的方法, 提出的方法在检测速度、检测准确率上均有所改善, 无需严格的硬件设备要求并且对玉米种子检测时不会产生任何损伤。

关键词: 极限学习机; 特征融合; 目标检测; 窗口融合; 模糊聚类

Detection of maize seeds based on multi-scale feature fusion and extreme learning machine

Ke Xiao^{1,2}, Du Mingzhi^{1,2}

1. College of Mathematics and Computer Science, Fuzhou University, Fuzhou 350116, China;

2. Fujian Provincial Key Laboratory of Networking Computing and Intelligent Information Processing, Fuzhou University, Fuzhou 350116, China

Abstract: **Objective** The detection of maize seeds and other crops is a key problem in the field of agricultural informatization. In this paper, to enhance detection and improve accuracy rate, we present a detection algorithm for maize seed on the basis of extreme learning machine (ELM) and multi-scale feature fusion. **Method** In the first part of this paper, the feature of maize seed is described as the combination of local features and global features. Local features can be described as a multi-scale histogram of oriented gradient, and global features can be described as the color feature of HSV. In the second part, ELM will be used as the detection algorithm against long training period and slow detection speed, which are the characteristics of traditional BP neural network and SVM. Furthermore, the detection model uses the parallel algorithm to significantly decrease the time used in the training of each classifier. Furthermore, the high resolution of the original image can cause long detection periods and consume a large amount of memory. To address this problem, we propose a local means of

收稿日期: 2015-06-11; 修回日期: 2015-09-23

基金项目: 国家自然科学基金项目(61502105); 福建省自然科学基金项目(2013J05088); 福建省中青年骨干教师教育科研项目(JA15075)

第一作者简介: 柯道(1983—), 男, 讲师、硕士生导师, 2011 年于厦门大学获理学博士学位, 研究方向为模式识别、图像处理、计算机视觉、机器学习以及自然语言处理等。E-mail: kex@fzu.edu.cn

Supported by: National Natural Science Foundation of China (61502105); Natural Science Foundation of Fujian Province, China (2013J05088)

an image compression algorithm. Finally, considering that the sliding windows of centralized scanning can produce a problem in creating multiple overlapping windows capturing the same object, we propose a local window fusion algorithm based on fuzzy clustering to address this problem. **Result** The simulation results show that the method proposed is able to accurately detect maize seeds. The accuracy of detection of maize seeds can reach 97.66% with an error of less than 0.1%.

Conclusion Compared with traditional methods, the no damage method proposed in this paper can improve the speed and accuracy of detection and has no strict hardware requirements.

Key words: extreme learning machine; feature fusion; object detection; windows fusion; fuzzy clustering

0 引言

种子是农业生产中最基本的生产资料,是一切农业生产的基础。种子的准确、快速检测对生产具有重要的指导意义,是农业信息化领域中的一个关键问题。国内外种子检测常用的方法主要有荧光扫描鉴定法^[1]、化学鉴定法^[2-3]和电泳鉴定法。这些方法需要较强的专业背景知识和较长的检测时间并且会对种子产生一定的损伤。因此,如何对农作物种子类别进行无损、快速检测是一个重要的研究方向。近年来,随着机器学习的快速发展,国内外已有许多学者将机器学习应用于农产品种子自动检测上^[4]。总的来说,基于机器视觉的种子检测具有如下优点:

1) 无损测量,对于测试的对象和观察者本身均不会产生任何损伤,从而提高了系统的安全性。

2) 客观性强,能够定量描述所需的测试指标,避免了因人为主观因素而产生的测量误差,提高了对象检测的准确率。

3) 计算机视觉信号易于处理,并且能够对海量的信息进行无间断处理,可以快速完成对种子的分析和检测任务。

从机器视觉的角度出发,在玉米种子的检测研究上,主要是先提取种子的颜色类^[5],形态类等外观特征,然后通过诸如贝叶斯网络、BP 神经网络、支持向量机等对玉米种子进行检测。

杨蜀秦等人^[6]将 BP 神经网络应用到玉米检测研究中,分析了玉米籽粒的形态特征,将提取的玉米籽粒形状、尺寸、颜色等相关的结构特征输入 BP 神经网络中进行检测,但是利用 BP 神经网络进行所需的训练时间较长,并且最终的检测准确率并不高。王宏勇等人^[7]将遗传算法和支持向量机相结合用于玉米种子的检测。利用遗传算法将玉米种子图像

的特征信息提取到支持向量机进行训练,最终实现对玉米种子的检测,该方法综合检测率较高,但是检测的时间和所消耗的空间也较高。黄敏等人^[8]利用高光谱反射图像处理技术,提取了玉米种子在 563.6 ~ 911.4 nm 共 55 个波段范围内的 12 个形状特征信息,对约 432 粒玉米种子,获得了测试集内 93.98% 的检测精度,但检测数目较少、并且需要专门的硬件设备。

针对传统种子检测方法存在检测速度慢、训练时间长、精度不高以及硬件设备要求严苛等问题,提出一种多尺度融合特征提取和基于极限学习机的种子检测方法。该方法可实现对玉米种子的准确检测,通过对深受广大农业主欢迎的奥玉 311,滑玉 986,鑫玉 35 等玉米种子进行测试。实验结果表明检测样本的测试精度达到 97.66%,同时误差控制在 0.1%。相比传统方法,本文方法在检测速度、训练速度、检测精度均有所改善,并且无需额外高要求的硬件设备。

1 基于多尺度特征融合与极限学习机的玉米种子检测框架

首先选取了在农业上深受广大农业主欢迎的奥玉 311,滑玉 986,鑫玉 35 等玉米种子图像数据集,然后对该数据集进行区域分割,采集数据集中关于玉米种子的信息。其次,对采集到的玉米种子在多尺度下进行基于局部的 HOG(histogram of oriented gradient)特征提取以及基于全局的 HSV 颜色特征提取,最后将提取的关于玉米种子的特征信息进行基于极限学习机的训练,从而得到最终的分类检测模型。

对待检测的玉米种子进行检测时,首先对该图像进行块状分割,分割成大小一致的窗口,对窗口内的图像信息进行特征提取。通过在多尺度下对窗口的不断滑动可以提取到该待检测图像上所有划分的

窗口特征信息。最后将该特征信息进行基于极限学习机的集成分类判断,通过投票表决的方式,得到最终的检测结果。针对玉米种子的大小各不相同,而且有可能差别较大,采用构造图像金字塔层的方法,对图像进行不同尺度的检测,以提高检测的可靠性、准确性。

采用滑动窗口机制对玉米种子图像进行检测。

多尺度条件下对图像进行滑动窗口扫描时会出现多区域混叠现象,这样便会导致一幅图像中存在着多个大小不一并且相互重叠的检测窗口映射到同一个种子对象上。因此,为了提高检测的精度,必须对这些同一对象上的多个重叠窗口进行局部融合。最后提出一种基于模糊聚类的局部窗口融合算法来进行优化。本文算法流程图如图 1 所示。




图 1 本文算法整体框架图

Fig. 1 Overall frame chart of the algorithm

2 多尺度特征融合

2.1 HOG 特征提取

HOG 特征是一种在图像处理以及计算机视觉中用来对检测的物体进行特征描述的一种算子^[9]。它表示的是边缘结构特征,可以很好地描述对象局部的形状信息。HOG 及其改进算法目前在行人检测和人脸检测领域已得到很好的应用^[10-11]。本文所检测的对象为玉米种子,边缘特征明显,具有很好的局部梯度描述特征。因为 HOG 算法的核心思想是基于图像的局部单元格,它对图像位置变化以及光照影响具有很强的鲁棒性。因此,HOG 能够很好

地作为玉米种子的描述特征之一。HOG 特征提取的流程如图 2 所示。

2.2 HSV 颜色特征提取

最常用的颜色特征表达方法是颜色直方图,因其不受图像的尺度变化、平移变化以及旋转等的影响得到广泛的应用。因为本文中的种子数量较大、形状不一、分布较为密集、背景颜色和玉米种子自身颜色相差较大,因此使用颜色直方图具有很好的描述效果,而且能剔除背景色彩所带来的影响,进一步弱化噪声点影响。与 RGB 颜色空间相比,HSV 颜色空间是一种面向视觉感知的颜色模型,能够以人的视觉系统来感知彩色图像来进行图像处理。相比 RGB 空间,使用的 HSV 颜色空间更加适合对玉米种




图 2 HOG 特征提取算法流程
Fig. 2 The feature extraction algorithm flow chart of HOG

子的特征描述。HSV 颜色空间由色调 (Hue)、饱和度 (Saturation)、亮度 (Value) 这 3 个元素构成。通过计算落在 HSV 空间中每个小区间内的像素数量, 可以得到玉米种子的颜色直方图。

2.3 多尺度特征融合与检测

方向梯度直方图虽然能够很好地把握图像的边缘信息以及局部特征,但是在一定程度上忽略了空间信息。多尺度特征是一种表达能力较强的形状特征描述,在能够很好地把握边缘信息的同时引入了空间信息,其主要思想是在不同尺度下对图像的边缘梯度方向直方图分布进行统计。如图 3 所示,通过逐级分割种子图像,把每一级分割成几块局部区域,按顺序将每一级各分块的梯度方向直方图串接组成一个多尺度的梯度方向直方图。随着种子图像分割的级数增加,多尺度的方

向梯度直方图对种子形状的刻画也越来越精细和局部化。




图 3 多尺度下玉米种子 HOG 特征提取
Fig. 3 Multi-scale feature extraction of HOG of maize seed

图 3 中, $L=0$ 表示的是第 1 级的轮廓分割图,代表整个种子的边缘轮廓图, $L=1$ 代表的是第 2 级,将整个种子图像进行均分,分为 4 个子区域。 $L=2$ 代表的是第 3 级,将第 2 级中的子区域再进行进一步划分成更小的 4 个区域。最终的多尺度特征就是将不同级别下的边缘梯度特征进行级联,最后

将级联后的特征数据进行归一化操作。该方法的优点在于融合了图像在空间上的信息以及图像的局部特征信息,具有较强的抗旋转能力和一定的抗噪性能。对于第 1 级,可以用直方图的 K 个部分来描述,即有 K 维特征向量,第 2 级有 $4K$ 维特征向量,第 3 级有 $16K$ 维的特征向量,对于整个图像来说总共就有 $21K$ 维的特征向量。采用 3 级尺度结构,并且 $K=9$,因此多尺度边缘梯度维数为 189 维。

因此最终玉米种子的特征可以描述为多尺度下的 HOG 特征和 HSV 颜色特征融合。考虑到系统的速度与实用性,本文的重点是构建一个种子检测框架,所以并没有再选用其他更多的特征。笔者也尝试过再增加种子的纹理特征以及大小特征来提高检测准确率,但是实验结果表明多尺度下的融合特征已经可以很好描述种子信息,加入纹理特征、大小特征后结果并没有显著提高,但是却要为此付出更多的时间和内存。本文的玉米种子检测过程采用的是滑动窗口机制,如图 4 所示。




图 4 滑动窗口多尺度检测过程

Fig. 4 The multi-scale detection of sliding window

检测时,对输入图片进行多尺度缩放,在每一层的图像上采用固定大小的窗口进行滑动,每个窗口都提取出多尺度 HOG 特征以及 HSV 颜色特征,输入到 ELM 分类器中进行集成投票表决,看该窗口中是否有目标。有则存下目标区域并且进行标记,无则继续滑动,直到达到图片金字塔的层数结束。

3 基于极限学习机的玉米种子集成分类模型

3.1 极限学习机(ELM)

极限学习机(ELM)是一种简单易用、有效的单隐层前馈神经网络学习算法^[12]。与传统的神经网络学习算法(如 BP 算法)相比,极限学习机不需要人为设置大量的网络训练参数,只需要设置网络隐层节点个数即可,并且在算法执行过程中无需调整隐元的偏置值以及网络的输入权重。此外,传统的神经网络学习算法很容易产生局部最优解或者陷入来回的迭代震荡,而极限学习机的网络的外权是通过计算最小化平方损失函数得到的最小二乘解(最终化归成求解一个矩阵的 Moore-Penrose 广义逆问题),是唯一的最优解。极限学习机可以极大降低因为网络参数的调节所消耗的时间,具有学习速度快以及泛化能力强的优点。玉米种子检测数目庞大、密度高,极限学习机用于种子检测可以很好地提高效率。ELM 算法的基本模型如图 5 所示。




图 5 极限学习机基本模型

Fig. 5 Basic model of extreme learning machine

ELM 算法工作原理如下:

针对训练数据样本 $(\mathbf{x}, \mathbf{t})$, 对于一个有 L 个隐层单元的单隐层前向神经网络可以表示为

$$f_L(\mathbf{x}) = \sum_{i=1}^L \beta_i G(\mathbf{a}_i, b_i, \mathbf{x}) \quad (1)$$

式中, $\mathbf{a}_i$ 为输入权重, b_i 为隐层单元偏置值, β_i 表示连接第 i 个隐层单元和网络之间的输出权重, $G(\mathbf{a}_i, b_i, \mathbf{x})$ 表示第 i 个隐层对应于样本 $\mathbf{x}$ 的隐层单元的输。以加法型的隐层节点为例, $G(\mathbf{a}_i, b_i, \mathbf{x})$ 的表达式为

$$G(\mathbf{a}_i, b_i, \mathbf{x}) = g(\mathbf{a}_i \cdot \mathbf{x} + b_i) \quad (2)$$

式中, g 为激活函数, $\mathbf{a}_i \cdot \mathbf{x}$ 代表输入权重 $\mathbf{a}_i$ 和样本 $\mathbf{x}$ 在 $\mathbf{R}_n$ 中的内积。假设存在 N 个互异的数据样本 $\{(\mathbf{x}_i, \mathbf{t}_i)\} \in \mathbf{R}_n \times \mathbf{R}_m$, 构建一个具有 L 个隐层单元的单隐层网络以趋近于零的误差来逼近这 N 个互异的数据样本, 即存在 $\mathbf{a}_i, \mathbf{b}_i$ 和 $\beta_i, i = 1, 2, \dots, L$, 使得

$$f_L(\mathbf{x}_j) = \sum_{i=1}^L \beta_i G(\mathbf{a}_i, \mathbf{b}_i, \mathbf{x}) = \mathbf{t}_j, j = 1, 2, \dots, N \quad (3)$$

式(3)可以简记为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (4)$$

式中, $\mathbf{H}$ 称为隐层单元输出矩阵。然而, 在多数情况下, 由于实际上的隐层单元个数远小于互异的训练样本个数 ($L \ll N$), 很难实现构建的具有 L 个隐层单元的单隐层网络能够以趋近于零的误差逼近这 N 个互异的数据样本, 因此, 训练样本的网络输出和实际输出之间具有一定的误差。在这种情况下, 式(4)可以改写为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} + \mathbf{E}, \quad \mathbf{E} = \begin{bmatrix} \mathbf{e}_1^T \\ \mathbf{e}_2^T \\ \vdots \\ \mathbf{e}_N^T \end{bmatrix}_{N \times m} \quad (5)$$

定义平方损失函数为

$$\mathbf{J} = \sum_{j=1}^N (\beta_i G(\mathbf{a}_i, \mathbf{b}_i, \mathbf{x}_j) - \mathbf{t}_j) \quad (6)$$

$$j = 1, 2, \dots, N$$

式(6)可以写成

$$\mathbf{J} = (\mathbf{H}\boldsymbol{\beta} - \mathbf{T})^T (\mathbf{H}\boldsymbol{\beta} - \mathbf{T}) \quad (7)$$

那么就可以通过对最小化平方损失函数的求解来实现 ELM 网络参数的训练问题。换句话说, 就是通过寻找最小二乘解 $\tilde{\boldsymbol{\beta}}$, 使得

$$\|\mathbf{H}\tilde{\boldsymbol{\beta}} - \mathbf{T}\| = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (8)$$

式中, $\|\cdot\|$ 表示 L_2 范数。在隐层输出为列满秩的情况下, 利用 Moore-penrose 广义逆可以得到

$$\tilde{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| = \mathbf{H}^+ \mathbf{T} \quad (9)$$

式中

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (10)$$

若隐层单元输出矩阵为非列满秩矩阵, 则可以通过奇异值分解算法得到最优输出权重 $\boldsymbol{\beta}$ 。

3.2 分类器的投票表决

为了提高分类精度以使得种子的检测准确率有所提高, 采用构造多个差异的分类器进行投票表决。

集成学习能够更好地提高分类准确性, 例如常用的 Bagging 算法和 Adaboost。Bagging 算法的主要思想是通过有放回地抽取训练集中的训练样本, 然后为每一个基分类器构造出一个跟训练集有着相同容量但内容具有一定差异的训练集, 进而训练出不同的基分类器。随机性是 Bagging 能否提高分类或者预测准确率的关键因素。Bagging 对随机型学习算法能提高预测的精度。本文的 ELM 是机器学习中的一个新模型, 因其具有一定的参数随机性, 因此利用 Bagging 集成学习, 可以提高其分类的精度。如图 6 所示, h_i 分别代表着不同的分类器, $\mathbf{a}_i$ 表示其相应的权值。




图 6 Bagging 集成分类学习

Fig. 6 Ensemble classification based on Bagging algorithm

3.3 检测过程中采用的多分类器并行算法

因为采用投票表决的方式, 并且各个分类器之间是独立进行的, 因此可以考虑到充分利用电脑的 CPU。采用多线程的并行计算, 各个分类器的训练并行独立进行。相比于串行训练, 显然可以加快训练时间, 提高训练的效率。此外在对图片进行多尺度检测种子的时候也采用并行算法。本文采用基于 Intel 的 TBB 多线程编程模型, 用于多核处理器的并行计算。TBB 的编程模式是使用模板作为并行迭代模型。这使得在玉米种子各个差别分类器训练过程中可以实现学习同步、负载均衡、缓存优化以及自动调度并程序, 使 CPU 的多核处于高速运转之中, 极大提高了分类器的学习效率。

3.4 基于局部均值的图像缩小算法

种子检测采用的是滑动窗口检测机制, 显然滑动窗口大小选择的合理性至关重要。若是选择太

小,则会出现对种子特征的描述不够详细和清晰,导致出现错误的检测。要是选择的窗口过大,则特征维数会相当的庞大,则计算机的大量资源会消耗在计算的时间以及存储内存上,不具有现实可行性。原图的分辨率大小为 $3\,696 \times 2\,448$ 像素。通过在原图上选取一些不同的窗口,可以得到如表 1 所示的实验信息。

表 1 滑动窗口大小为 30×30 的实验信息

Table 1 The experimental information of the sliding window is 30×30

测试图片名称	窗口大小	时间消耗/s	内存消耗/MB
奥玉 311(1 000 粒)	30×30	252	10 671
奥玉 311(1 500 粒)	30×30	307	10 678
滑玉 986(1 000 粒)	30×30	299	10 718
滑玉 986(1 500 粒)	30×30	338	10 778
鑫玉 35(1 000 粒)	30×30	304	10 778
鑫玉 35(1 500 粒)	30×30	366	10 786

如图 7 和图 8 所示,分别测试了 $30 \times 30, 35 \times 35, 40 \times 40, 45 \times 45, 50 \times 50$ 大小的窗口在检测时所需内存大小和时间长短的情况。其中块(Block)大小为 10×10 ,单元(Cell)大小为 5×5 ,滑动步长为 5×5 。从图 7 和图 8 中可以看出,随着滑动窗口的增长,计算机的时间消耗和内存消耗急剧扩大。而且从表 1 可以看出,即使在窗口 30×30 的情况下,检测一幅图像需要花费几分钟的时间,而且内存的消耗需要达到 10 GB 左右,这显然是不能接受的。针对上述情况,可以采用合理的无损压缩算法,减少花费在滑动窗口上检测的时间和内存空间。采用一种基于局部均值的采样压缩算法。该算法步骤如下:

设图 $F_{i,j}$, 大小为 $M \times N (i = 1, 2 \cdots, M; j = 1, 2, \cdots, N)$ 。缩小后的图像为 $G_{i,j}$, 大小为 $k_1 M \times k_2 N$ (当 $k_1 = k_2$ 时为按比例缩小,当 $k_1 \neq k_2$ 为不按比例缩小,且 $k_1 < 1, k_2 < 1$) ($i = 1, 2 \cdots, k_1 M; j = 1, 2, \cdots, k_2 N$), 则有

$$\Delta i = \frac{1}{k_1}, \quad \Delta j = \frac{1}{k_2} \quad (11)$$

$$g_{i,j} = f_{\Delta i \cdot i, \Delta j \cdot j} \quad (12)$$




图 7 滑动窗口大小与检测时间的关系

Fig. 7 The relationship between the size of the sliding window and the detection time




图 8 滑动窗口大小与内存空间的关系

Fig. 8 The relationship between the size of the sliding window and the memory

用式(11)计算采样间隔,得到 Δi 和 Δj , 求出相邻两个采样点之间所包含的原图像的子块,即为

$$F_{i,j} = \begin{bmatrix} f_{\Delta i \cdot (i-1) + 1, \Delta j \cdot (j-1) + 1} & \cdots & f_{\Delta i \cdot (i-1) + 1, \Delta j \cdot j} \\ \vdots & & \vdots \\ f_{\Delta i \cdot i, \Delta j \cdot (j-1) + 1} & \cdots & f_{\Delta i \cdot i, \Delta j \cdot j} \end{bmatrix} \quad (13)$$

设原图为

$$F = \begin{bmatrix} f_{11} & f_{12} & f_{13} & f_{14} & f_{15} & f_{16} \\ f_{21} & f_{22} & f_{23} & f_{24} & f_{25} & f_{26} \\ f_{31} & f_{32} & f_{33} & f_{34} & f_{35} & f_{36} \\ f_{41} & f_{42} & f_{43} & f_{44} & f_{45} & f_{46} \end{bmatrix} \quad (14)$$

图像矩阵大小为 4×6 , 将其进行缩小, 缩小的倍数 $k_1 = 0.7, k_2 = 0.6$ 。则缩小图像大小 3×4 , 由式(11)

和式(13)求出缩小的图像分块

$$\mathbf{F} = \begin{bmatrix} f_{11} & f_{12} & \vdots & f_{13} & \vdots & f_{14} & f_{15} & \vdots & f_{16} \\ \dots & \dots & \vdots & \dots & \vdots & \dots & \dots & \vdots & \dots \\ f_{21} & f_{22} & \vdots & f_{23} & \vdots & f_{24} & f_{25} & \vdots & f_{26} \\ f_{31} & f_{32} & \vdots & f_{33} & \vdots & f_{34} & f_{35} & \vdots & f_{36} \\ \dots & \dots & \vdots & \dots & \vdots & \dots & \dots & \vdots & \dots \\ f_{41} & f_{42} & \vdots & f_{43} & \vdots & f_{44} & f_{45} & \vdots & f_{46} \end{bmatrix} \quad (15)$$

再由 $g(i, j) = \mathbf{F}(i, j)$ 得均值, 得到缩小的图像为

$$\mathbf{G} = \begin{bmatrix} g_{11} & g_{12} & g_{13} & g_{14} \\ g_{21} & g_{22} & g_{23} & g_{24} \\ g_{31} & g_{32} & g_{33} & g_{34} \end{bmatrix} \quad (16)$$

式中, $g_{i,j}$ 为式(17)各子块的均值, 如

$$g_{21} = \frac{(f_{21} + f_{22} + f_{31} + f_{32})}{2} \quad (17)$$

本文中的基于局部均值采样压缩算法, 相比传统三次插值算法以及双立方插值算法, 该算法在保持边图像的特征信息同时又能极大减少计算量。

3.5 局部窗口融合算法

采用滑动窗口机制对玉米种子图像进行检测。多尺度条件下对图像进行滑动窗口扫描时会出现多区域混叠现象, 这样便会导导致一幅图像中存在多个大小不一并且相互重叠的检测窗口映射到同一个种子对象。因此, 为了提高检测的精度, 必须对这些同一对象上的多个重叠窗口进行局部融合。因此, 为了提高检测的精度, 必须对这些同一对象上的多个重叠窗口进行局部融合。提出一种基于模糊聚类的局部窗口融合算法。该算法的提出主要是基于以下两个假设:

1) 如果所构造出的集成分类器足够健壮的话, 它应该对所检测出的玉米种子区域作出一个强烈的反应。换句话说, 就是能够正确地把图像中的种子圈出来。当然, 因为采用的是滑动窗口的机制, 圈出来的种子区域允许稍稍偏离种子中心, 或者与最佳的检测区域有所出入。

2) 如果构造出的集成分类器是值得信赖的, 那么它应该对图像中的种子区域以及非种子区域能够做出一个强烈的对比, 两者不应该拥有相同的特征描述, 两者之间的区别应该足够明显。

模糊聚类是聚类和模糊集理论的综合, 非常适

合处理一些带有模糊边界的问题。在基于计算机视觉的图像处理上, 模糊聚类广泛应用于图像检索^[13-14]、图像分割^[15]、图像边界检测、图像增强、图像压缩等方面。尽管模糊聚类有着极其广泛的应用, 但目前来说, 并没有用到检测窗口融合的问题上。并且前人关于滑动窗口融合的研究也主要集中在人脸检测以及行人检测领域, 未使用到农业上种子分类检测问题。总的来说可以将前人的窗口融合算法分为基于核密度估计^[16]以及基于领域窗口^[17]。

基于领域窗口的方法其核心思想是通过对检测到的目标窗口和其附近领域内的窗口进行融合或者直接舍弃得到最终的目标。例如可以通过计算每个检测结果的指定高维领域内的其他检测结果数量, 如果这个数量大于某个给定的实验阈值, 那么该位置被归为一类, 舍弃附近领域窗口。该方法优点计算量相对较小, 并且所需设定的参数少, 融合时间较快。但是该方法相对来说比较粗糙, 当两个目标相邻很近时不能很好的处理, 例如在不同尺度下检测到的两个目标较近或者出现遮挡时, 经常会被错误分类为一个目标, 准确率较低。

针对基于领域窗口方法的不足, 后来又提出了基于核密度估计的窗口融合算法, 它把多个窗口重叠的融合问题看成是一个3维空间的核密度来看待, 将其作为一种非最大值抑制(NMS)的响应。主要思想是基于概率密度梯度函数估计, 通过基于梯度下降法来寻找概率密度函数的局部最大值来进行窗口融合估计。一般来说通过有限次的迭代, 可以找到密度分布最大的区域。该方法应用在图像多尺度缩放检测的时候取得较好的效果, 融合精度较高。但是该方法中核函数的选择以及和核窗口的确定对结果影响很大, 需要反复测试才能选取最合适的, 并且涉及高维计算, 效率较低, 运算量大。

针对基于窗口领域算法存在着检测准确率不高以及基于和核密度估计算法运算量较大以及参数选择较困难, 提出一种基于模糊数学理论的局部窗口融合算法。其基本思想是将窗口视为分布在2维空间上的不同离散点, 进而窗口局部融合便可以视为这些离散点的聚类。通过计算出聚类的中心, 则可以得出最佳的融合窗口位置。通过用模糊等价关系来实现离散点的聚类以达到最后的局部窗口融合。模糊等价关系具有自反性、对称性和传递性。在有限论域 $U = \{x_1, x_2, \dots, x_n\}$ 的场合, 用 n 阶矩阵

$R^* = (r_{ij})_{n \times n}$ 表示模糊等价关系对应的等价矩阵。

设模糊矩阵 $R^* = (r_{ij})_{n \times n}$ 是模糊等价矩阵, 则应该满足以下几个条件:

- 1) 自反性 $r_{ij} = 1$;
- 2) 对称性 $r_{ij} = r_{ji}$;
- 3) 传递性 $(R^*)^2 = R^* \circ R^* \subseteq R^*$ 。

求得模糊等价矩阵后, 可以通过设置不同的 λ 值得到其 λ 截矩阵 R_λ , 便能够按照 R_λ 进行分类。

λ 截矩阵的定义如下:

设 $R = (r_{ij})_{m \times n}$ 是模糊矩阵 (可以是具备模糊关系的矩阵, 亦可以是具备模糊等价关系的矩阵), $\lambda \in [0, 1]$ 。使得矩阵 $R_\lambda = (r_{ij}^\lambda)_{m \times n}$ 满足 $\forall i \leq m$,

$\forall j \leq n, r_{ij}^\lambda = \begin{cases} 1, & r_{ij} \geq \lambda \\ 0, & r_{ij} < \lambda \end{cases}$ 则称 R_λ 为 R 的 λ 截矩阵。不

同的 λ 对应于不同的 λ 截矩阵, x_i 和 x_j 被视为同一个 R_λ 等价类, 当且仅当 $r_{ij} \geq \lambda$ 。通过分析, 可知当 λ 越大时, 所得到的分类也就越精细, 反之则越粗。但是实际上大多数问题都是具有模糊相似关系而不具备模糊等价关系, 它们只有对称性和自反性, 并不具备传递性。因此, 直接根据模糊相似关系分类的话, 就会产生出不协调分类。为了能够得到协调的分类就必须将模糊关系改造为一个模糊等价关系, 根据模糊数学理论:

- 1) 设 $R^s = (r_{ij})_{n \times n}$ 是模糊相似矩阵, 则对任意自然数 k , R^s 的合成矩阵 $(R^s)^k$ 也是模糊相似矩阵。
- 2) 设 $R = (r_{ij})_{n \times n}$ 是模糊矩阵, 则称包含 R 的最小传递矩阵为 R 的传递闭包, 记为 $t(R)$ 。
- 3) 设 $R^s = (r_{ij})_{n \times n}$ 是模糊相似矩阵, 则存在自然数 $k \leq n$, 使得 $t(R^s) = (R^s)^k$, 且对于一切大于 k 的自然数 l , 有 $(R^s)^l = (R^s)^k$ 。

因此, 为了实现最终的模糊分类, 可以通过上述的方法构造出一个模糊等价矩阵。一般来说, 从相似矩阵 R^s 得到等价矩阵 R^* 可以采用平方自相合方法, 通过有限次运算, 可以得到 $k \leq n$ 使得 $(R^s)^{2k} < (R^s)^{2k+1}$, 从而 $R^* = t(R^s) = (R^s)^{2k} = (R^s)^{2k+1}$ 。

算法 1: 本文提出的窗口融合算法

输入: 候选玉米窗口位置坐标 $x_i = \{x_{iu}, y_{iu}, w_i, h_i\}_{i=1}^n$ 。

输出: $set[i]_{i=1}^k$ // 式中 k 表示窗口融合之后的非抑制集合个数。

初始化:

1) 将集成分类器中判断为玉米种子的候选窗口, 按照坐标位置从小到大排列。

2) 确定惩罚因子 p :

for $i = 0 : n - 1$

for $j = 0 : 1$

compute $R_{n \times 2}$; // 根据最大归一化法计算模糊矩阵 R

end for

end for

for $i, j = 0 : n - 1$;

if $i = j$ then $r_{ij} = 1$;

else $r_{ij} = 1 - \frac{p}{e^{\frac{overlap(x_i, x_j)}{\sqrt{(x_{ix} - x_{jx})^2 + (x_{iy} - x_{jy})^2}}}}$; // 计算模糊相似矩阵

end for

for $i = 1 : max$; // max 为设定的一个大整数

if $(R^s)^i \circ (R^s)^i = (R^s)^i$ continue;

else $i = i + 1$ compute $(R^s)^i \circ (R^s)^i$;

end for

output R^* ; // 根据平方自合成方法求出模糊等价矩阵 R^* 。

按照 R^* 矩阵得分从大到小排列, 随机选取合适的 λ , 根据 λ 划分 $setunion[i]_{i=1}^k$ 。

对 $setunion[i]_{i=1}^k$ 每一类的窗口进行加权平均, output $set[i]_{i=1}^k$ 。

本文提出的窗口融合算法具体描述如下:

1) 设 $U = \{x_1, x_2 \cdots x_n\}$ 为待分类检测窗口的集合式中 $x_i = \{x_{iu}, y_{iu}, w_i, h_i\}$ 。 $\{x_{iu}, y_{iu}\}$ 代表滑动窗口的左上角坐标, w_i 代表滑动窗口的宽, h_i 代表滑动窗口的高) 集合中的每个元素 x_i 有 2 个特征 x_{ix}, x_{iy} (窗口质心坐标描述)。 $x_{ix} = x_{iu} + w_i, x_{iy} = y_{iu} + h_i$, 将模糊矩阵进行归一化压缩到 $[0, 1]$ 区间上。采用最大法归一化

$$x_{ij}' = \frac{x_{ij}}{M_j}, M_j = \max(x_{1j}, x_{2j}, \cdots, x_{nj}) \quad (18)$$

2) 确定 U 中的模糊相似矩阵 $R^s = (r_{ij})_{n \times n}$, 即计算出模糊相似矩阵中的元素 r_{ij} , 其含义表示的是 x_i 和 x_j 这两个检测到的窗口相似度。针对玉米种子的检测, 提出一种新的相似度系数计算方法, 相似度为

$$r_{ij} = \begin{cases} 1 & i = j \\ 1 - \frac{p}{e^{\frac{overlap(x_i, x_j)}{\sqrt{(x_{ix} - x_{jx})^2 + (x_{iy} - x_{jy})^2}}}} & i \neq j \end{cases} \quad (19)$$

式中, p 为惩罚因子, 为一个常数, 用于调节候选窗口之间质心距离以及重叠域。 $overlap(x_i, x_j) =$

$area(\mathbf{x}_i \cap \mathbf{x}_j)$ 表示重叠域, 有

$$area(\mathbf{x}_i \cap \mathbf{x}_j) = dw \times dh \quad (20)$$

$$dw = \max((\min(x_{ix}, x_{jx}) - \max(x_{it}, x_{jt})), 0) \quad (21)$$

$$dh = \max((\min(x_{iy}, x_{jy}) - \max(y_{it}, y_{jt})), 0) \quad (22)$$

本文定义的相似度函数综合考虑到领域窗口之间的重叠域以及质心距离, 这两个因素是导致邻域窗口是否可以进行局部融合的关键。

$\frac{overlap(\mathbf{x}_i, \mathbf{x}_j)}{\sqrt{(x_{ix} - x_{jx})^2 + (x_{iy} - x_{jy})^2}}$ 称为窗口重叠密度, 即领域窗口重叠区域与质心距离的比值, 当窗口之间的重叠域较大并且质心距离较小时, 则相似度越高, 便越有可能聚合为同一类。

3) 根据上述求解的模糊相似矩阵, 求解模糊矩阵传递闭包。通过有限次的平方自相合运算方法, 便可以得到检测窗口的模糊等价矩阵 $\mathbf{R}^*$ 。

4) 通过设定最优的 λ 值, 求出 $\mathbf{U}$ 关于 λ 截等价矩阵 $\mathbf{R}_\lambda^*$ 的商集 $\mathbf{U}/\mathbf{R}_\lambda^*$, 这样就可以得到图像中所有候选窗口的聚类结果。在融合时候只需要给出一个 λ 值进行融合就可以得到分类结果, λ 值的确定可以通过多次实验来筛选。

5) 通过上述算法可以得到每一个聚类结果中的窗口集合。对于隶属于同一个类别集合中的多个窗口, 先计算出该集合的质心位置, 然后根据加权平均求出该窗口的宽度和高度, 采用高斯密度分布方法, 即距离质心越近的窗口权重越大, 得出最后融合的窗口位置。

4 实验

4.1 实验设置

PC 机一台, 系统为 Windows7 (64 位) 系统, 运行内存 12 GB, CPU 核心数为双核。

4.2 实验数据集

实验的样本有深受广大农业主欢迎的奥玉 311, 滑玉 986, 鑫玉 35 共 300 000 颗左右的玉米种子。检测图像的原始大小为 $3\,696 \times 2\,448$ 像素。每幅图像上的玉米种子数目在 1 000 ~ 1 500 个不等。

4.3 实验参数

4.3.1 分类器个数

采用 Bagging 分类集成学习, 目的在于通过投票表决方式来提高分类的精度和学习系统的泛化能力。采用 Bagging 算法时, 根据统计学原理可知每

个基分类器约存在 63.2% 重复训练样本。因此当分类器超过一定个数的时候会带来冗余的投票表决结果, 准确率的增加不明显, 但是却要不断消耗随着分类器的增加带来的时间消耗。

从图 9 可以看出, 随着分类器个数的增加, 种子的检测准确率能够进一步提高, 当分类器的个数在 4 个或者 5 个时, 玉米种子的检测准确率可以达到一个满意的结果, 并且可以进一步发现分类器个数为 4 个和 5 个时, 两者之间的检测准确率差别不大, 但是当分类器个数为 5 个时, 要消耗更多的时间计算和内存消耗。因此本文中的分类器个数最终选定为 4 个差异性 ELM 分类器。




图9 分类器个数和检测准确率关系

Fig. 9 The relationship between the number of classifiers and accuracy of detection

4.3.2 滑动窗口大小

通过多次实验对比, 本文采用局部均值算法将原图压缩到 $2\,000 \times 1\,324$ 像素大小。并且采用 4 个差异的 ELM 分类器, 在窗口大小为 $15 \times 15, 20 \times 20, 25 \times 25, 30 \times 30, 35 \times 35$ 对测试图像分别进行空间和时间大小进行统计。

由图 10、图 11 可知, 随着窗口的不断增大, 检测过程中所消耗的计算时间和内存空间也急剧增大, 因为随着窗口增大时, 种子的特征描述维数会越来越庞大。因此一个合适的窗口对检测的性能十分的重要。同时对比图 7、图 8 之后, 首先可以看到进行压缩算法之后的图像在时间和内存上的消耗和原图相比有大幅度降低, 其次是在种子密度一定的情况下, 检测所消耗的内存相对稳定, 因此该压缩算法是合理, 有效的。当窗口在 30×30 之内的效果较好, 时间计算少并且内存消耗也较少。窗口大小在 30×30 以上时所耗费的计算机

资源难以接受。




图 10 采用压缩算法后窗口大小与时间的关系

Fig. 10 The relationship between the window size and time after the compression algorithm




图 11 采用压缩算法后窗口大小与内存的关系

Fig. 11 The relationship between the window size and memory after the compression algorithm




图 12 窗口的选择和检测准确率关系

Fig. 12 The relationship between the choice of window and detection accuracy

因为测试图像中的种子大小不是固定的,不同的窗口对种子特征的描述相差较大,因此就存在着一个合理的窗口大小能对种子特征进行较为准确的

描述。通过实验分析可以看出,当窗口大小低于 25×25 时以及大于 25×25 时检测的准确率相对较低,窗口在 25×25 时的准确率达到一个峰值,因此最后选择 25×25 的窗口作为检测窗口。

4.4 实验结果评估标准

实验结果采用五折交叉验证的方法 (5-fold Cross Validation) 计算召回率 (R)、准确率 (P) 以及综合指标 (F) 来进行评价。即

$$R = \frac{C}{S} \quad (23)$$

$$P = \frac{C}{C + E} \quad (24)$$

$$F = \frac{2 \times P \times R}{P + R} \quad (25)$$

式中, C 表示正确检测的种子个数, S 表示总的种子个数, E 表示的是误判的种子个数。

实验测试的样本分别为来自农业公司的奥玉 311, 滑玉 986, 鑫玉 35 等玉米种子。其中正样本的数据集个数为 2 600, 负样本的数据集个数为 3 000。如图 13 所示。




图 13 正样本和负样本

Fig. 13 Samples in the experiment ((a) positive sample; (b) negative sample)

4.5 使用 TBB 算法并行加速

因为采用投票表决的方式,并且各个分类器直接是独立进行的,因此可以考虑到充分利用电脑的 CPU,采用多线程的并行算法,各个分类器的训练并行独立进行。本文的并行算法将任务自动映射到多线程,减少消息传递和数据移动带来的额外开销。相比于串行训练,显然可以加快训练时间,提高训练

的效率。图 14 显示使用并行算法时 CPU 的利用率。图 15 可以看出,TBB 并行算法相比串行算法在训练时间上显示出很大的优势,可以充分利用计算机资源,提高效率。



图 14 使用并行算法检测时 CPU 的利用率
Fig. 14 The utilization of CPU in the parallel detection algorithm




图 15 TBB 并行算法和串行算法对比(窗口大小为 25 × 25)
Fig. 15 The comparison of TBB parallel algorithm and serial algorithm when the window size is 25 × 25

4.6 局部窗口融合算法对比

将本文所提出的局部窗口融合算法分别同基于领域窗口重叠的方法以及非最大值抑制(NMS)方法(基于核密度估计)进行对比,结果如图 16、图 17 所示。




图 16 不同窗口融合算法时间比较
Fig. 16 The time consumption of different window fusion algorithms




图 17 不同窗口融合算法准确率比较
Fig. 17 The accuracy of different window fusion algorithms

从图 16 可以看出,本文融合算法所需要的融合时间最少,总体上来说,融合时间只有基于领域窗口算法的一半,并且远小于 NMS 算法。此外,随着种子密度的增大,并没有明显增加融合时间。

从图 17 可以看出,本文融合算法的准确率和 NMS 准确率接近,但均高于基于领域窗口的融合准确率。并且随着种子密度不断增大(即候选窗口数目不断增加)并没有表现出明显的震荡性。从而也说明本文的算法在不牺牲融合性能的情况下能够提高融合效率。

图 18 中显示的两幅图分别为滑玉 986 玉米种子融合前和融合后的,图 19 显示的两幅图分别为鑫玉 35 玉米种子融合前后的对比图。可以清晰地看到在融合前,首先非目标区域并没有出现矩形框,本文的集成分类器具有一定的健壮性,其次单个检测到的目标产生了两个甚至是多个的重叠矩形框,这说明检测结果中出现了不必要或者偏移的值,而融合后可以看出结果变得更加清晰和明确。这也表明了本文基于模糊聚类的局部窗口融合算法对检测结果具有良好的优化性能。




图 18 滑玉 986 种子融合算法前后的对比
Fig. 18 The comparison of the fusion algorithm of the seed of huayu986 before and after((a) before fusion; (b) after fusion)




图 19 鑫玉 35 种子融合算法前后的对比
Fig. 19 The comparison of the fusion algorithm of the seed of xinyu 35 before and after((a) before fusion; (b) after fusion)

4.7 实验结果

为了验证算法的有效性,从农业公司所提供的玉米种子图像数据集中,随机抽取了 200 幅玉米种子图像,分别是深受广大农业主欢迎的奥玉 311,滑玉 986,鑫玉 35 玉米种子,每幅图像上种子数量在 1 000 颗或者 1 500 颗,共 300 000 颗玉米种子进行测试。

从图 20 可以看出,本文通过采用极限学习机作为检测分类器并且采用多线程的集成学习方法,在检测时间上取得显著效果。与传统的基于 BP 神经网络以及 SVM 分类检测相比,平均检测时间在 46 s 左右,检测速度上大约是基于 SVM 算法的 3 倍,是基于 BP 算法的 5 倍。在检测速度上显现出了很大的优势。

从图 21 可以看出,本文通过多尺度下的融合特征提取作为玉米种子特征的依据,能够准确描述种子信息,在检测的准确率平均可以达到 97.8%,较传统基于 BP 神经网络以及 SVM 分类检测相比有明显改善。

表 2 数据说明,本文提出的玉米种子检测算法对光照,种子倒映背景,种子尺度,种子形状特征等




图 20 本文算法和基于 BP 以及 SVM 算法检测时间对比
Fig. 20 The comparison of the detection time based on BP、SVM and the algorithm in this paper




图 21 本文算法和基于 BP 以及 SVM 算法检测准确率对比
Fig. 21 The comparison of accuracy based on BP、SVM and the algorithm in this paper

方向的影响具有很好的鲁棒性,并且具有较高的检测准确率。相对传统的基于 BP 神经网络以及 SVM 等具有训练时间快、检测精度高、泛化能力强等特点。此外在图像数据集中当种子密度加大时,仍然可以表现出令人满意的效果。实验结果如图 22—图 24 所示。

表 2 实验结果数据
Table 2 The final data of experiments

测试图像	时间消耗/s	内存消耗/MB	准确率 p /%	召回率 R /%	综合指标 F /%
奥玉 311(1 000 粒)	43	3 360	98. 83	97. 24	98. 02
奥玉 311(1 500 粒)	45	3 365	97. 62	96. 19	96. 89
滑玉 986(1 000 粒)	42	3 369	96. 77	97. 88	97. 32
滑玉 986(1 500 粒)	47	3 366	96. 74	97. 22	96. 48
鑫玉 35(1 000 粒)	42	3 366	98. 88	97. 92	98. 09
鑫玉 35(1 500 粒)	48	3 367	96. 23	95. 90	96. 06




图 22 鑫玉 35 玉米种子原图
Fig. 22 The image of maize seed of xinyu35




图 23 鑫玉 35 玉米种子检测结果
Fig. 23 The identification results of maize seed of xinyu35




图 24 滑玉 986 玉米种子检测结果
Fig. 24 The identification results of maize seed of huayu986

5 结 论

提出了一种基于极限学习机的多尺度特征融合玉米种子检测算法,并且在此基础上提出了进一步改善检测准确率的局部窗口融合算法,丰富了机器学习在种子检测领域的研究。实验结果表明本文方法具有一定的现实意义和理论研究价值。在机器的时间消耗以及内存消耗还有种子的检测准确率上都在一个良好的控制范围内。

同时也应看到,本文算法还有尚待改进之处。

检测效果仍存在不足,存在漏数、重复数的情况,这也是目前机器学习在检测检测上普遍存在的问题。如何在合理的计算机资源内进一步提高种子检测的准确率以及优化在时间和内存上的消耗是进一步研究的方向。

参考文献 (References)

[1] Wang L, Liu D, Pu H, et al. Use of hyperspectral imaging to discriminate the variety and quality of rice[J]. Food Analytical Methods, 2015, 8 (2): 515-523. [DOI: 10.1007/s12161-014-9916-5]

- [2] Zhang X L, Liu F, He Y, et al. Application of hyperspectral imaging and chemometric calibrations for variety discrimination of maize seeds[J]. *Sensors*, 2012, 12(12): 17234-17246. [DOI: 10.3390/s121217234]
- [3] Jia S Q, An D, Liu Z, et al. Variety identification method of coated maize seeds based on near-infrared spectroscopy and chemometrics[J]. *Journal of Cereal Science*, 2015 (63): 21-26. [DOI: 10.1016/j.jcs.2014.07.003]
- [4] Sun K Q, Chen Z, Jiang S F. Local morphology fitting active contour for automatic vascular segmentation[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59 (2): 464-473. [DOI: 10.1109/TBME.2011.2174362]
- [5] Yan X M, Liu S X, Zhang C Q, et al. Purity identification of maize seed based on color characteristics [J]. *Transactions of the CASE*, 2010, 26(S1): 46-50. [闫小梅, 刘双喜, 张春庆, 等. 基于颜色特征的玉米种子纯度识别[J]. *农业工程学报*, 2010, 26 (S1): 46-50] [DOI: 10.3969/j.issn.1002-6819.2010.z1.011]
- [6] Yang S Q, Ning J F, He D J. Identification of corn breeds by BP neural network [J]. *Journal of Northwest Sci-Tech University of Agriculture and Forestry: Natural Science Edition*, 2004, 32: 162-164. [杨蜀秦, 宁纪锋, 何东健. BP 神经网络识别玉米品种的研究[J]. *西北农林科技大学学报: 自然科学版*, 2004, 32: 162-164.]
- [7] Wang H Y, Hou H F, Liu S H. Maize seed recognition based on genetic algorithm and multi-class SVM[J]. *Computer Engineering and Applications*, 2008, 44(18): 221-223. [王宏勇, 侯惠芳, 刘素华. 基于遗传算法和支持向量机的玉米品种识别[J]. *计算机工程与应用*, 2008, 44(18): 221-223.] [DOI: 10.3778/j.issn.1002-8331.2008.18.069]
- [8] Huang M, Zhu X, Zhu Q B, et al. Morphological characteristics of maize seed extraction and identification based on the hyperspectral image [J]. *Acta Photonica Sinica*, 2012, 41(7): 868-873. [黄敏, 朱晓, 朱启兵, 等. 基于高光谱图像的玉米种子特征提取与识别[J]. *光子学报*, 2012, 41(7): 868-873.] [DOI: 10.3788/gzxb20124107.0868]
- [9] Dalal N, Triggs B. Histograms of oriented gradient for human detection[C] // *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Washington DC: IEEE, 2005, 1: 886-893.
- [10] Chen P Y, Huang C C, Lien C Y, et al. An efficient hardware implementation of HOG feature extraction for human detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(2): 656-662. [DOI: 10.1109/TITS.2013.2284666]
- [11] Wang H F. HOG-NPE: a novel local description operator for face image recognition [J]. *Journal of Fiber Bioengineering and Informatics*, 2014, 7(3): 419-427. [DOI: 10.3993/jfbi09201411]
- [12] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine theory and applications[J]. *Neurocomputing*, 2006, 70(1/3): 489-501. [DOI: 10.1016/j.neucom.2005.12.126]
- [13] Li L, Liu Y, Ma Z, et al. Image retrieval method on image features of fuzzy clustering [J]. *Journal of Tsinghua University: Science and Technology*, 2014, 54(7): 929-934. [李兰, 刘洋, 马振, 等. 利用图像特性的模糊聚类图像检索算法[J]. *清华大学学报: 自然科学版*, 2014, 54(7): 929-934.]
- [14] Haridas K, Thanamani A S. An efficient image clustering and content based image retrieval using fuzzy K Means clustering algorithm[J]. *International Review on Computers and Software*, 2014, 9(1): 147-153.
- [15] Liu X N, Lu Y N, Lei L, et al. A multi-objective image segmentation method based on FCM and discrete regularization [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2015, 27(1): 142-146. [刘晓妮, 卢奕南, 雷玲, 等. 基于 FCM 和离散正则化的多目标图像分割[J]. *计算机辅助设计与图形学学报*, 2015, 27 (1): 142-146.] [DOI: 10.3969/j.issn.1003-9775.2015.01.018]
- [16] Dalal N. Finding people in images and videos [D]. Grenoble, France: The French National Institute for Research in Computer Science and Control, 2006.
- [17] Schneiderman H and Kanade T. Object detection using the statistics of parts [J]. *International Journal of Computer Vision*, 2004, 57(2): 137-154. [DOI: 10.1023/B:VISI.0000011202.85607.00]