

基于K-SVD和正交匹配追踪稀疏表示的稻飞虱图像分类方法

林相泽, 张俊媛, 朱赛华, 刘德营

(南京农业大学工学院, 南京 210031)

摘要:针对当前稻飞虱图像分类研究中存在图像识别速度慢、分类精度低的不足, 该文提出一种基于K-SVD和正交匹配追踪 (orthogonal matching pursuit, OMP) 稀疏表示的稻飞虱图像分类方法。首先, 根据稻飞虱的趋光性特点, 使用团队自主研发的野外昆虫图像采集装置自动获取稻田害虫图像; 然后, 利用K-SVD算法对稻飞虱图像特征的过完备字典进行更新构造, 结合OMP算法对原始输入图像的特征信号进行稀疏表示; 最后, 通过求解输入图像的重构误差对昆虫图像进行分类。在相同的试验条件下, 与传统的图像分类算法(SVM、BP神经网络)进行比较。实验结果表明, 该文提出的基于K-SVD和OMP算法的稻飞虱图像稀疏表示分类方法可对稻飞虱与非稻飞虱进行快速准确的分类, 分类速度达到6.0帧/s, 平均分类精度达到93.7%。与SVM和BP神经网络相比, 分类速度分别提高了5和5.5帧/s; 分类精度分别提高了15.7和28.2个百分点, 为稻飞虱的防治预警工作提供了信息与技术支持。

关键词: 图像处理; 分类; 稻飞虱; 稀疏表示; K-SVD; 正交匹配追踪

doi: 10.11975/j.issn.1002-6819.2019.19.026

中图分类号: S24; TP2

文献标识码: A

文章编号: 1002-6819(2019)-19-0216-07

林相泽, 张俊媛, 朱赛华, 刘德营. 基于K-SVD和正交匹配追踪稀疏表示的稻飞虱图像分类方法[J]. 农业工程学报, 2019, 35(19): 216—222. doi:10.11975/j.issn.1002-6819.2019.19.026 http://www.tcsae.org

Lin Xiangze, Zhang Junyuan, Zhu Saihua, Liu Deying. Sparse representation classification method of rice planthopper image based on K-SVD and orthogonal matching pursuit algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(19): 216—222. (in Chinese with English abstract) doi:10.11975/j.issn.1002-6819.2019.19.026 http://www.tcsae.org

0 引言

水稻是世界三大粮食作物之一, 也是中国重要的谷类粮食作物, 其种植面积占全国粮食种植面积的30%以上, 超过65%的中国人将水稻作为主要口粮^[1]。因此, 稻田害虫防治是农业生产发展的重要部分。稻田害虫少, 水稻产量高、品质好; 稻田害虫猖獗, 稻米产量少、品质差, 对国家粮食安全和农业经济的稳定发展造成严重威胁。

水稻在生长的不同阶段都会受到不同程度、不同种类害虫的侵害, 危害中国水稻生长的害虫主要有稻飞虱、水稻螟虫、稻苞虫、稻纵卷叶螟等, 其中稻飞虱对水稻的影响尤为严重, 可使水稻产量最高下降35%^[2]。稻飞虱通常以群集方式在稻丛基部刺吸水稻汁液, 危害水稻生长, 严重的还会造成冒穿、黄塘、毁秆、倒伏甚至无产^[3]。因此, 准确获取稻飞虱虫情信息并及时制定合理防治措

施是控制稻飞虱爆发、降低虫害的有效途径。

为了实现稻飞虱虫情测报的自动化与高效化, 稻飞虱图像分类成为近几年的研究热点。Sarin等^[4]提出了一种基于颜色和灰度共生矩阵(gray-level co-occurrence matrix, GLCM)图像特征训练的支持向量机分类算法, 可以自动检测收集图像中稻飞虱的位置和对稻飞虱的生长阶段进行分类, 分类精度可达87%; 林相泽等^[5]提出了一种基于迁移学习和Mask-CNN相结合的稻飞虱图像分类算法, 分类精度可达92.3%; Tsung等^[6]提出了一种感兴趣区域(region of interest, ROI)方法来检测稻飞虱并利用决策树算法对分析数据进行分类识别, 分类精度可达80%; Yue等^[7]探讨了一种基于颜色特征和边缘特征的多特征融合均值偏移方法, 分类精度可达80%; 虽然以上研究均取得了一定的成果, 但是在识别速度与分类精度方面仍需进一步提高。

由于图像稀疏表示的识别速度快、分类精度高, 近年来, 图像稀疏表示技术得到了深入研究, 目前已被广泛用于图像处理的各个领域^[8]。在人工智能行业, 稀疏表示已广泛用于人脸识别与人脸修复^[9]; 在医学行业, 医学影像去噪、影像增强以及影像序列分析中也离不开稀疏表示^[10]; 在电子产品行业, 稀疏表示更是计算机视觉跟踪中最常用方法之一^[11]。但是, 在农业工程领域中, 基于稀疏表示的图像分类还处于起步阶段。

收稿日期: 2019-04-24 修订日期: 2019-09-27

基金项目: 国家自然科学基金面上项目(61773216)、江苏省自然科学基金面上项目(BK20171386)

※通信作者: 林相泽, 教授, 博士生导师, 研究方向为交换系统理论及其在农用移动平台中的控制研究; 农用移动平台的实时定位及姿态控制研究; 多机器人的协同控制研究及电机的控制系统设计, 基于人工智能的稻飞虱等病虫害图像的自动获取、识别、预警及防治的研究。

Email: xzlin@njau.edu.cn

因此,为了加快稻飞虱图像分类速度,提高识别精度,本文提出了一种基于K-SVD和OMP稀疏表示的稻飞虱图像分类方法。该方法在图像识别过程中可自行对信号进行降维,剔除多余噪声,提高收敛速度,可对稻飞虱虫害的预防治理提供信息和技术支持。

1 稻飞虱图像获取

1.1 野外昆虫图像采集装置

根据稻飞虱趋光性强的特点,稻飞虱图像通过团队自主研发的野外昆虫图像采集装置^[12-13]自动采集,装置结构如图1所示。



1. 高压汞灯 2. Z向调节装置 3. X向调节装置 4. 采集工作台 5. 环形光源 6. 高清工业相机 7. Y向调节装置 8. 工作台基座

1. High pressure mercury lamp 2. Z-direction adjustment device 3. X-direction adjustment device 4. Collection workbench 5. Ring light source 6. HD industrial camera 7. Y-direction adjustment device 8. Workbench base

图1 野外昆虫图像采集装置

Fig.1 Field insect image acquisition device

其中,工作台基座是整个装置的支撑部分,采用轻便牢固的铝合金材料制成;采集工作台由透明亚克力板和白色的确良幕布组成,尽可能保证采集背景干净,减少拍摄干扰。根据稻飞虱的趋光性,试验通过高压汞灯将昆虫吸引至采集工作台,使用高清工业相机进行拍摄;由于拍摄环境光线较暗,拍摄装置前方装有环形光源,用于增强光照并使光线均匀扩散。 X 、 Y 、 Z 向三向调节装置控制相机的移动方向与拍摄距离,控制单元由台达DVP32EH00T3型PLC组成并搭载于 X 、 Z 向调节装置顶端,控制调节装置的移动速度;相机以每次移动5 cm、停留5 s的运动状态在 X 、 Z 向上进行往返运动。

整个试验过程在无人监督的情况下自动获取清晰完整的水稻害虫图像,图像以782像素×576像素、JPEG格式存储于计算机中。

1.2 稻田昆虫图像采集

试验地点:南京农业大学江浦农场(32°01'N, 118°37'E)、白马国家农业科技园(31°37'N, 119°10'E)。

试验时间:2015年8月至10月、2016年6月至9月、2017年8月至9月。

试验环境:温度20~30℃、相对湿度6%~8%。

试验共采集到1 186幅昆虫图像,通过在不同时间、地点下对稻飞虱图像进行采集,有效保证了试验数据的完整性与多样性。采集到的图像背景复杂、目标模糊,需要进一步对其进行分割,增强图像的可检测性。

1.3 OTSU 阈值分割

本试验采用OTSU阈值分割法(又叫大津法)^[14]对图像进行分割,当阈值为148时,图像背景与目标的分割效果最佳,经OTSU处理后的图像如图2所示。

从图2可知,经过OTSU分割处理后,背景与目标可明确进行区分,根据像素大小的不同,将目标进行提取,最终获得300像素×300像素大小的单一稻田昆虫图像,部分结果如图3所示。

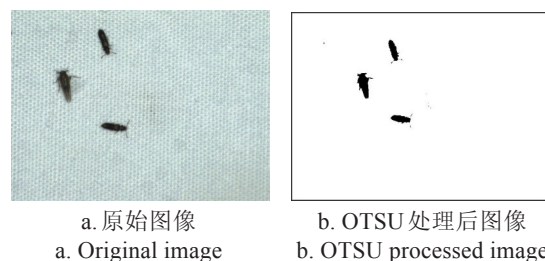



图2 OTSU分割处理结果

Fig.2 OTSU split processing result



a. 稻飞虱 b. 叶甲 c. 长蝽 d. 隐翅虫
a. Rice planthopper b. Chrysomelid beetle c. Lygaeidae d. Vxytelux

图3 部分数据样本

Fig.3 Partial data sample

试验中,将白背飞虱、褐飞虱、灰飞虱归为稻飞虱类,其他水稻害虫均归为非稻飞虱类。选取1 100幅单一稻田昆虫图像作为试验数据。

2 算法设计

稀疏表示是在给定的过完备字典中用尽可能少的原子来对图像信号进行线性表示^[15]。其实质是在稀疏度不变的情况下,对过完备字典上的信号进行稀疏逼近,有效提取图像信号内部结构和本质特征,以便于对信号进行进一步压缩、编码等处理^[16]。其稀疏表达式如下:

$$Y = DX \quad (1)$$

式中 $D \in R^{n \times K}$ 表示过完备字典; $Y = \{y_i\}_{i=1}^n$ 表示输入信号; $X = \{x_i\}_{i=1}^K$ 表示稀疏系数。

图像的稀疏表示主要分为稀疏编码和更新字典两部分。本文采用OMP算法^[17]对输入信号进行稀疏分解并计算重构误差,采用K-SVD(K-means singular value decomposition)算法^[18]对字典进行构造更新。

2.1 OMP稀疏分解算法

试验采用OMP算法来实现图像信号稀疏分解。OMP算法是一种典型的贪婪算法,其基本思想是将正交化的输入信号作为局部最优解,从过完备字典中选择与其最匹配的信号进行稀疏逼近并求解残差,通过反复迭代计算来获得全局最优解,当达到预设迭代次数 N 时停止迭代^[19]。具体的算法过程如下:

输入:过完备字典 D ,原始信号 Y ,稀疏度 T_0 ;
输出:稀疏系数 x 的稀疏度 T_0 约束下的稀疏逼近 x' ;
初始化:残差 $r^{(0)} = y$,索引集 $\Lambda^{(0)} = \emptyset, J = 1$;
循环执行步骤1)~5):
1)找出残差 $r^{(J-1)}$ 与字典 D 中某列 d_j 内积最大所对应的下标 $\lambda, \lambda = \arg \max_{j=1 \dots N} |\langle r^{(J-1)}, d_j \rangle|$;
2)更新索引 $\Lambda^{(J)} J = \lambda$,更新字典原子构成的集合 $D^{(J)} = D(:, \Lambda^{(J)}(1:J))$;
3)最小二乘法计算得 J 阶逼近 $x^{(J)} = \|y - D^{(J)}x\|_2$;
4)更新残差 $r^{(J)} = D^{(J)}x^{(J)}, J = J + 1$;
5)如果 $J > N$,迭代结束;否则重复1。

2.2 K-SVD字典学习算法

对于复杂的高维图像信号来说,构造合适的过完备字典是图像进行稀疏表示的关键步骤^[20]。K-SVD算法是在K-means^[2]算法的基础上发展起来的一种聚类字典构建算法。K-SVD算法以误差最小原则作为基本思想、聚类最大值作为分类中心,使用 K 个原子的线性组合来表示图像信号,通过计算其与原始信号的误差 ε ,选择 ε 最小项进行SVD后分解作为字典的新原子,从而达到更新字典的目的^[22-23]。其目标方程为

$$\min_{D,x} \varepsilon = \{ \|Y - DX\|_F^2 \} \text{ s.t } \forall i, \|x_i\|_0 \leq T_0 \tag{2}$$

其中 T_0 表示非零稀疏系数上限。
算法具体流程如图4所示。

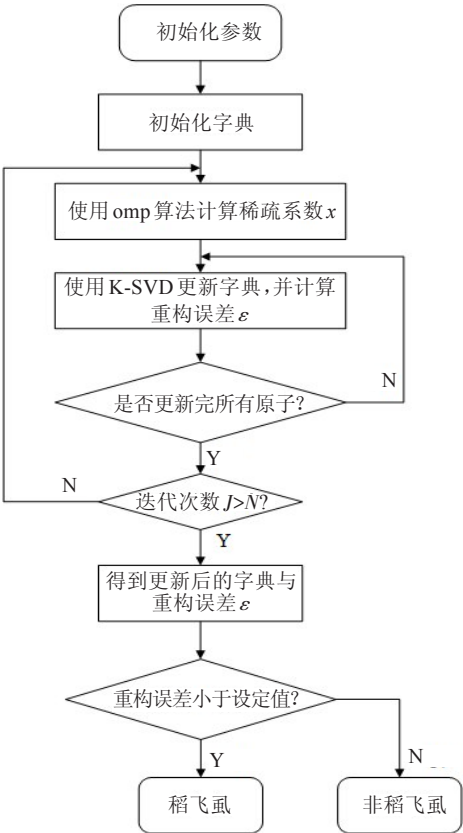


图4 试验流程图
Fig.4 Experimental flow chart

试验选取500幅稻飞虱图像作为过完备字典数据、200幅稻飞虱图像作为原始输入图像,再取稻飞虱图像(rice planthopper, RPH)和非稻飞虱图像(non-rice planthopper, nRPH)各200幅,并按照3:1的比例分成测试

集和验证集2部分。经试验测试,迭代次数为500时,分类精度趋于稳定,稻飞虱的重构误差均低于0.1,而非稻飞虱的重构误差均在0.1以上,所以试验设定重构误差值设为0.1。

字典特征选取文献[24]中的20个优化特征,其中包括颜色特征中向量 L 的熵、能量与偏度;形态特征中的球状性、矩形度和Hu不变矩;纹理特征中的能量、逆差矩和熵等,并标记为 M_1 。为了增强试验结果的可信度,选取文献[25]和[26]中的20个特征进行对比验证,其中包括7组Hu不变矩和13组傅里叶描述子,并标记为 M_2 。稻飞虱与非稻飞虱的部分特征参数如表1所示。其中 M_1 类特征分别为熵、能量、偏度、球状性、矩形度与逆差矩; M_2 类特征分别为3个傅里叶描述子与3个Hu不变矩。

1 水稻昆虫特征参数
Table 1 Feature parameters of rice insect

特征类别 Feature category	稻飞虱 Rice planthopper(RPH)	非稻飞虱 Non-rice planthopper(NRPH)
M_1 类特征 Feature M_1	0.545、0.391、0.735、1.142、 0.513、0.486	0.224、2.147、0.003、0.027、 2.848、1.976
M_2 类特征 Feature M_2	傅里叶描述子 0.570、0.118、 0.006	1.248、0.374、0.259
	Hu不变矩 0.510、0.028、 0.034	1.184、0.086、0.031

3 试验结果与分析

3.1 过完备字典的获取

获得良好的过完备字典,是图像进行有效分类的关键。因此,为了保证试验的准确性,初始过完备字典数据从样本集中随机选取,部分初始字典如图5所示。




图5 部分初始字典样本集
Fig.5 Partial initial dictionary sample set

由于初始过完备字典中存在大量背景信息,通过对初始字典进行迭代更新,可有效剔除无关信息,尽量保留用于重构的显著特征。进行初次迭代时,使用OMP算法对初始字典进行稀疏编码,计算输入信号的初始稀疏系数 x_0 。在满足稀疏度的约束下,使用K-SVD算法对字典进行逐列更新并重构误差 ε ,直至更新完字典的全部原子。当迭代次数满足设定值时,停止迭代。重构后的部分字典如图6所示。




图 6 部分重构字典样本集
Fig.6 Partially reconstructed dictionary sample set

如图 6 所示,将初始过完备字典中的图像按列分割,并提取相应的显著特征。更新时,不带有显著特征的图像块将会被带有显著特征的图像块取代,从而到达字典更新的目的。所以,重构后的字典样本均是带有显著特征的图像块。在 M_1 和 M_2 类特征下分别生成过完备字典 D_1 、 D_2 。

3.2 最优稀疏度的获取

选取合适的稀疏度是提高分类速度的关键。任意选取 M_1 和 M_2 特征各 3 组测试重构误差随着稀疏度的变化趋势,结果如图 7 所示。




图 7 重构误差变化趋势
Fig.7 Reconstruction error trend

从图 7 中可以看出,随着稀疏度 T_0 的增加,重构误差不断减小。在 $T_0 = 1, \dots, 6$ 时, ε 随着 T_0 的增加而快速降低,变化幅度在 0.4~0.6 之间;在 $T_0 = 6, \dots, 11$ 时, ε 的变化幅度在 0.2~0.3 之间,趋势较为平缓;但在 $T_0 = 12$ 时, ε 的数值陡然下降且均小于 0.1;在 $T_0 = 12, \dots, 18$ 时,变化趋势几乎趋于平稳,并且在 $T_0 = 18$ 时, ε 达到最小并且不再随着稀疏度的变化而改变。可见,在 $T_0 = 6, 12, 18$ 时, ε 会发生明显变化。因此,本文选取 $T_0 = 6, 12, 18$ 时对全部试验数据进行测试。

首先,每次选取 1 组稻飞虱的 M_1 和 M_2 类特征信号作为原始参考值,然后使用多组稻飞虱特征信号依次进行测试,分别在过完备字典 D_1 、 D_2 下进行稀疏重构,最后,分别在 $T_0 = 6, 12, 18$ 时计算重构误差。部分计算结果如表 2 所示。

根据表 2 可知, $T_0 = 6$ 时, M_1 和 M_2 的重构误差 ε 的变化范围在 0.02~0.09 之间; $T_0 = 12$ 时, ε 的变化范围在 0.003~0.02 之间; $T_0 = 18$ 时, ε 的变化范围在 0.002~0.02 之间。随着稀疏度 T_0 数值的升高,重构误差 ε 逐渐减小,但是 ε 均低于 0.1。重构误差变化趋势如图 8 所示。

表 2 不同稀疏度 M_1 和 M_2 类特征的重构误差
Table 2 Reconstruction errors of feature M_1 and M_2 under different sparsity T_0

特征类别 Feature category	$T_0=6$	$T_0=12$	$T_0=18$
M_1	0.0677	0.0061	0.0055
	0.0494	0.0031	0.0028
	0.0637	0.0117	0.0115
	0.0548	0.0067	0.0052
	0.0456	0.0053	0.0024
	0.0459	0.0075	0.0071
	0.0512	0.0062	0.0034
	0.0590	0.0094	0.0026
	0.0656	0.0109	0.0093
	0.0832	0.0055	0.0035
M_2	0.0297	0.0035	0.0032
	0.0377	0.0097	0.0079
	0.0363	0.0068	0.0046
	0.0206	0.0050	0.0036
	0.0392	0.0048	0.0034
	0.0315	0.0038	0.0023
	0.0197	0.0048	0.0025
	0.0230	0.0078	0.0051
	0.0314	0.0051	0.0045
	0.0238	0.0030	0.0027

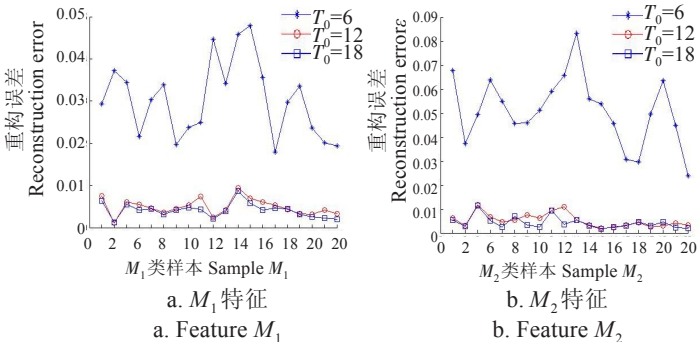


图 8 M_1 和 M_2 特征的重构误差变化趋势

Fig.8 Reconstruction error variation trend of feature M_1 and M_2

从图 8 中可以看出, $T_0 = 6$ 时的重构误差最大,与 $T_0 = 12, 18$ 时重构误差平均相差 0.037 1;在 $T_0 = 12$ 与 $T_0 = 18$ 时,重构误差相差很小,几乎难以区分。图像越稀疏,分类速度越快,但是重构误差也最大。即当 $T_0 = 6$ 稀疏度最高,分类速度最快,重构误差最大; $T_0 = 18$ 时,稀疏度最低,分类速度最慢,但是重构误差最小,但是相对于 $T_0 = 12$ 时的重构误差变化甚微。所以,综合稀疏程度与重构误差两方面考虑,当 $T_0 = 12$ 时,重构速度与分类效果最好。因此,选取 $T_0 = 12$ 作为最优稀疏度并在此稀疏度下测试稻飞虱与非稻飞虱的重构误差。

3.3 稻飞虱分类试验

3.3.1 数据分类结果

经大量试验验证,稻飞虱的重构误差 ε 均在 0.1 之下,因此,将 ε 的阈值设定为 0.1,当 ε 小于 0.1 时判断为稻飞虱,否则为非稻飞虱。

当 $T_0 = 12$ 时,分别选取 M_1 和 M_2 类特征信号,在字典 D_1 、 D_2 上对稻飞虱与非稻飞虱进行稀疏重构并计算重构误差,部分试验结果如表 3 所示。

表3 稻飞虱与非稻飞虱图像的重构误差($T_0=12$)
Table 3 Reconstruction error of rice planthopper and non-rice planthopper image($T_0=12$)

RPH1	nRPH1	RPH2	nRPH2
0.0061	0.4683	0.0035	0.3742
0.0031	0.4997	0.0097	0.2675
0.0117	0.5001	0.0068	0.3003
0.0067	0.3852	0.0050	0.3407
0.0053	0.3869	0.0048	0.3022
0.0075	0.5173	0.0038	0.3195
0.0062	0.4854	0.0048	0.2911
0.0094	0.5903	0.0078	0.2354
0.0109	0.3686	0.0051	0.2586
0.0055	0.2947	0.0030	0.3196

注：RPH1, nRPH1, RPH2, nRPH2 分别为 M_1 类特征下的稻飞虱和非稻飞虱、 M_2 类特征下的稻飞虱和非稻飞虱。
Note: RPH1, nRPH1, RPH2, nRPH2 are the rice planthoppers and non-rice planthoppers under the feature M_1 , the rice planthoppers and non-rice planthoppers under the feature M_2 , respectively.

由表3可知,当 $T_0=12$,在2种不同的分类特征下,稻飞虱的重构误差 ε 约在0.01左右,而非稻飞虱的重构误差 ε 均在0.2以上,根据重构误差对图像进行明确分类,分类精度分别达到93.3%和94.1%,平均分类精度可达93.7%。

3.3.2 图像分类结果与分析可视化

为了明显区分图片目标与背景,图像使用 `imagesc` 函数将像素矩阵中的元素数值按大小转化为不同颜色,并显示在坐标轴的不同位置。在图像彩色通道下,输入一幅300像素×300像素大小的稻飞虱图像作为参考,分别提取稻飞虱和非稻飞虱的 M_1 和 M_2 组特征在更新后的过完备字典 D_1 和 D_2 上进行重构,结果如图9所示。

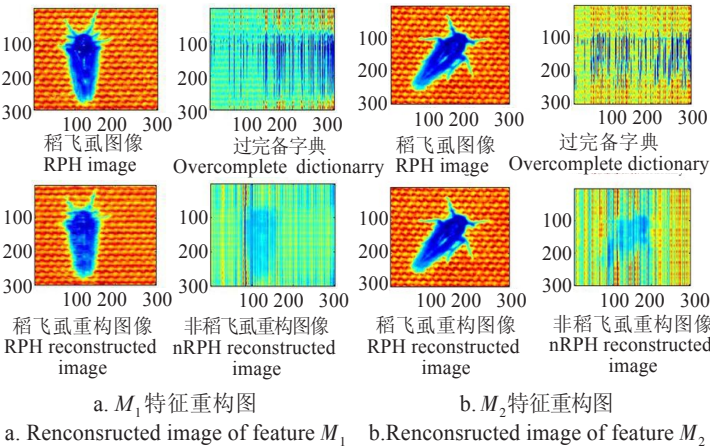


图9 M_1 和 M_2 特征的重构结果
Fig.9 Reconstruction result of feature M_1 and M_2

从图9中可以看出,稻飞虱重构图像与原始图像基本一致,吻合度极高,可获得良好重构;非稻飞虱重构图像模糊,难以辨认,对原图像还原程度低,不可稻飞虱图像进行稀疏重构。

试验结果表明,在2组不同的分类特征下,稻飞虱与非稻飞虱的重构误差值差别大,重构图像吻合度区别明显。因此,本文所提出的方法对采集到稻田昆虫图像可进行有效分类。

3.4 对比验证试验

为了证明本文方法的优越性,将本文方法与SVM、BP神经网络方法进行比较。选取 M_1 、 M_2 特征的稻飞虱

与非稻飞虱图像各500幅作为训练样本,不重复的400幅稻飞虱图像和100幅非稻飞虱图像按照3:1的比例分成验证样本与测试样本进行分类实验,其中,SVM设置惩罚系数为100,核参数为0.07,BP神经网络的输入层神经节点个数为20,输出节点个数为2,初始权值与偏差均设为0,Sigmoid参数设为0.5;迭代次数均为500。试验结果如表4所示。

表4 对比试验结果
Table 4 Comparative test results

算法 Algorithm	分类精度 Classification accuracy/%	检测速率 Detection rate / (帧·s ⁻¹)
BPNN	78	1.0
SVM	65.5	0.5
稀疏表示 Sparse representation	93.7	6.0

根据表4可知,SVM的分类精度为65.5%,BP神经网络的分类精度为78%。传统的图像分类方法分类精度均在80%以下,而本文所提方法的分类精度可达到93.7%。比传统分类方法的分类精度分别提高15.7和28.2个百分点。稀疏表示在图像初步处理时进行阈值分割,并结合稀疏表示的算法复杂程度低、数据处理量少的特点,使处理速度远大于传统的分类方法。与BP神经网络1.0帧/s(即每1s处理1帧图像)和SVM0.5帧/s(即每2s处理1帧图像)的检测速率相比,稀疏表示检测速率可达到6帧/s,分类速度分别提高5和5.5帧/s。。

4 结论

- 1)结合稻飞虱趋光性强的生物特点,通过使用团队自主研发的野外昆虫图像采集装置在无人监督的情况下对稻飞虱图像进行采集,为试验提供完整的图像数据集。
- 2)试验采用OMP算法对原始图像进行稀疏表示,结合K-SVD算法对字典进行构造更新并计算重构误差。在稀疏度不同、分类特征不同的情况下,对稻飞虱和非稻飞虱分别进行重构与分类。
- 3)试验结果表明,在稀疏度为12时,图像分类效果最好。与传统的图像分类算法SVM、BP神经网络进行对比,本文提出的方法分类速度到达6.0帧/s,且平均识别精度达到93.7%,可以为稻飞虱的虫情控制提供信息和技术支持。

[参考文献]

[1] 蒋敏,李秀彬,辛良杰,等.南方水稻复种指数变化对国家粮食产能的影响及其政策启示[J].地理学报,2019,74(1): 32—43.
Jiang Min, Li Xiubin, Xin Liangjie, et al. The impact of paddy rice multiple cropping index changes in Southern China on national grain production capacity and its policy implications[J]. Acta Geographica Sinica, 2019, 74(1): 32—43. (in Chinese with English abstract)

[2] 程家安,祝增荣.中国水稻病虫害治理60年:问题与对策[J].植物保护学报,2017,44(6): 885—895.
Cheng Jiaan, Zhu Zengrong. Development of rice pest management in the past 60 years in China: problems and strategies[J]. Journal of Plant Protection, 2017, 44(6): 885—895. (in Chinese)

- with English abstract)
- [3] 何艳, 严田蓉, 郭长春, 等. 秸秆还田与栽插方式对水稻根系生长及产量的影响[J]. 农业工程学报, 2019, 35(7): 105—114.
He Yan, Yan Tianrong, Guo Changchun, et al. Effect of methods of straw returning and planting on root growth and rice yield[J]. Transactions of the Chinese Society of Agricultural Engineering, (Transactions of the CSAE) 2019, 35(7): 105—114. (in Chinese with English abstract)
 - [4] Sarin W, Ithipan M. Mobile-device based image processing for rice brown planthopper classification and outbreak monitoring[J]. Applied Engineering in Agriculture, 2019, 35(1): 15—21. (in Chinese with English abstract)
 - [5] 林相泽, 朱赛华, 张俊媛, 等. 基于迁移学习和Mask R-CNN的稻飞虱图像分类方法[J]. 农业机械学报, 2019, 50(7): 201—207.
Lin Xiangze, Zhu Saihua, Zhang Junyuan, et al. Research on rice planthopper image classification via transfer learning and mask R-CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(7): 201—207. (in Chinese with English abstract)
 - [6] Tsung Han Tsai, Ting Yu Lee, Po Hsun Chen, et al. The ROI of rice planthopper by image processing[C]. International Conference on Applied System Innovation IEEE, 2017, 126—129.
 - [7] Yue Hongwei, Man Hong, Wang Keqiang, et al. Rice planthopper segmentation based on multi-feature fusion[C]. 2016 IEEE International Conference on Signal and Image Processing (ICSIP), Beijing, 2016, 6: 16—21.
 - [8] 桑园. 动态稀疏表示方法在非接触式指纹图像识别中的应用[J]. 科学技术与工程, 2018, 18(21): 258—263.
Sang Yuan. Application of dynamic sparse representation in non-contact fingerprint image recognition[J]. Science Technology and Engineering, 2018, 18(21): 258—263. (in Chinese with English abstract)
 - [9] 王林, 邓芳娟. 改进的加权稀疏表示人脸识别算法[J]. 计算机系统应用, 2018, 27(6): 134—139.
Wang Lin, Deng Fangjuan. Improved weighted sparse representation algorithm for face recognition[J]. Computer Systems & Applications, 2018, 27(6): 134—139. (in Chinese with English abstract)
 - [10] 赵海峰, 鲁毓苗, 陆明, 等. 基于快速稀疏表示的医学图像压缩[J]. 计算机工程, 2014, 40(4): 233—236.
Zhao Haifeng, Lu Yumiao, Lu Ming, et al. Medical image compression based on fast sparse representation[J]. Computer Engineering, 2014, 40(4): 233—236. (in Chinese with English abstract)
 - [11] 王琳, 陈志国, 傅毅. 基于多任务结构稀疏表示的跟踪算法[J]. 传感器与微系统, 2018, 37(10): 140—142, 146.
Wang Lin, Chen Zhiguo, Fu Yi. Tracking algorithm based on multi-task structure sparse representation[J]. Transducer and Microsystem Technologies, 2018, 37(10): 140—142, 146. (in Chinese with English abstract)
 - [12] 刘德营, 王家亮, 林相泽, 等. 基于卷积神经网络的白背飞虱识别方法[J]. 农业机械学报, 2018, 49(5): 51—56.
Liu Deying, Wang Jiangliang, Lin xiangze, et al. Automatic identification method forogatella furcifera based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 51—56. (in Chinese with English abstract)
 - [13] 谢堂胜, 刘德营, 陈京, 等. 白背飞虱智能识别技术研究[J]. 南京农业大学学报, 2016, 39(3): 519—526.
Xie Tangsheng, Liu deying, Chen Jing, et al. Automatic identification ofogatella furcifera[J]. Journal of Nanjing Agricultural University, 2016, 39(3): 519—526. (in Chinese with English abstract)
 - [14] 易三莉, 张桂芳, 陈菊. 基于信息熵的OTSU二次分割算法[J]. 昆明理工大学学报: 自然科学版, 2019, 44(2): 56—62.
Yi Sanli, Zhang Guifang, Chen Ju. OTSU secondary segmentation algorithm based on information entropy[J]. Journal of Kunming University of Science and Technology Natural Science, 2019, 44(2): 56—62. (in Chinese with English abstract)
 - [15] Pelin Görgel, Ahmet Simsek. Face recognition via deep stacked denoising sparse autoencoders (DSDSA)[J]. Applied Mathematics and Computation, 2019, 355: 325—342.
 - [16] 黄宏图, 毕笃彦, 侯志强, 等. 基于稀疏表示的视频目标跟踪研究综述[J]. 自动化学报, 2018, 44(10): 1747—1763.
Huang Hongtu, Bi Duyan, Hou Zhiqiang, et al. Research of sparse representation-based visual object tracking: A survey[J]. Acta Automatica Sinica, 2018, 44(10): 1747—1763. (in Chinese with English abstract)
 - [17] 石曼曼, 李雷. 一种改进的OMP算法及其在图像重构上的应用[J]. 计算机技术与发展, 2018, 28(2): 94—97.
Shi Manman, Li Lei. An improved orthogonal matching pursuit algorithm and its application in image reconstruction[J]. Computer Technology and Development, 2018, 28(2): 94—97. (in Chinese with English abstract)
 - [18] 张文颢, 李永健, 张卫华. 基于K-奇异值分解和层次化分块正交匹配算法的滚动轴承故障诊断[J]. 中国机械工程, 2019, 30(4): 406—412.
Zhang Wenhao, Li Yongjian, Zhang Weihua. Bearing fault diagnosis based on K-SVD and HBW-OOMP[J]. China Mechanical Engineering, 2019, 30(4): 406—412. (in Chinese with English abstract)
 - [19] 石昊苏. OMP算法参数对超声图像重构质量的实证分析[J]. 计算机与数字工程, 2018, 46(5): 1020—1024.
Shi Haosu. An empirical analysis of the quality of ultrasound image reconstruction based on OMP algorithm parameters[J]. Computer & Digital Engineering, 2018, 46(5): 1020—1024. (in Chinese with English abstract)
 - [20] 白志亮, 陈世利, 贾乐成, 等. 基于贪婪算法的汽轮机叶轮相控阵信号压缩感知[J]. 机械工程学报, 2018, 54(18): 33—41.
Bai Zhiliang, Chen Shili, Jia Lecheng, et al. Compressed sensing of ultrasonic phased array signal in turbine disc rims inspection based on greedy algorithms[J]. Journal of Mechanical Engineering, 2018, 54(18): 33—41. (in Chinese with English abstract)
 - [21] 薛晨杰, 林婷薇. 基于异常检测的K-means改进算法研究[J]. 软件导刊, 2019, 18(4): 74—78.
Xue Chenjie, Lin Tingwei. Improved K-means algorithm based on anomaly detection[J]. Software Guide, 2019, 18(4): 74—78.
 - [22] Victor M Garcia-Molla, Pablo San Juan, Tuomas Virtanen, et al. Generalization of the K-SVD algorithm for minimization of β -divergence[J]. Digital Signal Processing, 2019, 92, 47—53.
 - [23] 王佳境, 吴建宁, 凌云, 等. 基于K-SVD的最大似然稀疏表示领域网动作分类算法[J]. 计算机系统应用, 2018, 27(2): 144—150.
Wang Jiajing, Wu Jianning, Ling Yun, et al. Maximum likelihood sparse representation activity recognition algorithm based on K-SVD in body sensor networks[J]. Computer system & Applica-

- tions, 2018, 27(2): 144—150. (in Chinese with English abstract)
- [24] 陆静,王家亮,朱赛华,等. 基于特征优化的稻飞虱图像分类[J]. 南京农业大学学报, 2019, 42(4): 767—774.
Lu Jing, Wang Jialiang, Zhu Saihua, et al. Classification of rice planthoppers image based on feature optimization[J]. Journal of Nanjing Agricultural University, 2019, 42(4): 767—774.
- [25] 邹修国, 丁为民, 刘德营, 等. 基于4种不变矩和BP神经网络的稻飞虱分类[J]. 农业工程学报, 2013, 29(18): 171—178.
Zou Xiuguo, Ding Weimin, Liu Deying, et al. Classification of rice planthopper based on invariant moments and BP neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2013, 29(18): 171—178. (in Chinese with English abstract)
- [26] 赵三琴, 丁为民, 刘德营. 基于傅里叶描述子的稻飞虱形状识别[J]. 农业机械学报, 2009, 40(8): 181—184, 160.
Zhao Sanqin, Ding Weiming, Liu Deying. Rice hopper shape recognition based on Fourier descriptors [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(8): 181—184, 160. (in Chinese with English abstract)

Sparse representation classification method of rice planthopper image based on K-SVD and orthogonal matching pursuit algorithm

Lin Xiangze, Zhang Junyuan, Zhu Saihua, Liu Deying

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

Abstract: Rice is a staple crop in China. Controlling rice pests and diseases is important to safeguard its sustainable production, in which classification and identification of rice planthoppers plays an important part. While there has been an increased interest over the past few years in image-classification of the rice planthoppers, currently, this method is not automatic and susceptible to faulty recognition and low efficiency. To circumvent these shortcomings, a sparse-representation image-based classification method was proposed based on the K-SVD and OMP. A field insect collection device was used to collect insect images, in which a high-pressure mercury lamp was used to attract the insects to the collection workbench based on their phototaxis characteristics. A PLC was mounted on the top of the three-phase adjustment device to control high-definition industrial cameras to take images of the insects. The images were then segmented using the maximum inter-class variance method (OTSU threshold segmentation method) to extract the image of the insects. Overall, 1186 single insect images were obtained from the field experiment. Two insect characteristics were selected as initial over-complete dictionary and they were extracted from 500 images. K-SVD dictionary learning algorithm was used to iteratively update the over-complete dictionary of the rice planthopper image features and the number of iterations was set at 500. 200 images of the rice planthoppers were selected as the original input comparing images, and 150 and 50 images of the rice and non-rice planthopper were used as testing and verifying sets respectively. The appropriate sparsity is an important factor for improving efficiency and accuracy, and the errors of the testing images was calculated from the OMP algorithm when the sparsity was 6, 12 and 18 respectively. Comprehensive analysis of the errors and convergence rate showed that the optimal sparsity was 12. Finally, classification features of the rice and non-rice planthoppers were sparsely reconstructed in line with the updated reconstruction dictionary, and the reconstruction error was calculated for the sparsity of 12. Hundreds of experiments revealed that the classification threshold of 0.1 was quick and effective to classify the rice and non-rice planthopper. Using the same experimental data, we compared the proposed method with the traditional image-based classification algorithms, SVM and BP neural network. The results showed that the accuracy and classification speed were 65.5% and 0.5 frames/s respectively for SVM, and 78.0% and 1.0 frames/s respectively for the BP neural network. In contrast, the proposed method improved the accuracy to 93.7% and the classification speed to 6.0 frames/s

Keywords: image processing; classification; rice planthopper; sparse representation; K-SVD; orthogonal matching pursuit