

李翠娜,石广玉,余正泓,等,2020. 农作物实景监测中的图像数据质量控制方法研究[J]. 气象,46(1):119-128. Li C N, Shi G Y, Yu Z H, et al, 2020. Research on image data quality control method in crop real landscape observation[J]. Meteor Mon, 46(1):119-128(in Chinese).

# 农作物实景监测中的图像数据 质量控制方法研究\*

李翠娜<sup>1,2,3,4</sup> 石广玉<sup>1</sup> 余正泓<sup>5</sup> 白晓东<sup>6</sup>

1 中国科学院大气物理研究所大气科学和地球流体力学数值模拟国家重点实验室,北京 100029

2 中国科学院大学,北京 100049

3 中国气象局气象探测中心,北京 100081

4 中国气象局沈阳大气环境研究所,沈阳 110300

5 广东科学技术职业学院,珠海 519090

6 南京邮电大学,南京 210023

**提 要:** 农作物实景自动监测系统具有自动、非接触、非破坏性等优点,是传统农业气象观测的补充。开展图像质量控制是合理使用农作物实景自动监测系统资料的基础。利用郑州、泰安和固城三地的历史农作物实景图像资料,设计了基于颜色特征参数检测和基于暗通道先验直方图检测的图像数据质量控制方法。通过对 2010—2012 年三年夏玉米和冬小麦等不同天气条件下得到的农作物实景自动观测资料进行质量控制与应用效果检验。结果表明:两种质量控制方法均可判断出农作物实景自动监测系统中图像观测资料的异常数据;基于颜色特征参数检测方法可有效识别出像素缺失图像,准确率达 100%;基于暗通道先验直方图检测方法能有效识别出污染图像,平均准确率为 95.7%,平均召回率为 87.5%。该质量控制方法可减小模型估算值与观测数据之间的误差,目前已应用于省级农业自动观测业务系统。

**关键词:** 机器学习,农作物实景监测图像,质量控制,暗通道

中图分类号: P414

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2020.01.012

## Research on Image Data Quality Control Method in Crop Real Landscape Observation

LI Cuina<sup>1,2,3,4</sup> SHI Guangyu<sup>1</sup> YU Zhenghong<sup>5</sup> BAI Xiaodong<sup>6</sup>

1 State Key Laboratory of Numerical Modeling for Atmospheric Sciences and Geophysical Fluid Dynamics,  
Institute of Atmospheric Physics, Chinese Academy of Sciences, Beijing 100029

2 University of Chinese Academy of Sciences, Beijing 100049

3 CMA Meteorological Observation Centre, Beijing 100081

4 Institute of Atmospheric Environment, CMA, Shenyang 110300

5 Guangdong Institute of Science and Technology, Zhuhai 519090

6 Nanjing University of Posts and Telecommunications, Nanjing 210023

**Abstract:** The automatic monitoring system for crops has the advantages of automatic, non-contact and non-destructive, and is a useful supplement to traditional agrometeorological observations. The charge

\* 中国气象局沈阳大气环境研究所开放基金课题(2016SYIAE12)和国家自然科学基金项目(61701260)共同资助

2018 年 10 月 18 日收稿; 2019 年 11 月 7 日收修定稿

第一作者:李翠娜,主要从事农业气象自动化观测方法研究. Email:licn1030@126.com

通讯作者:石广玉,主要从事大气物理与大气环境研究. Email:shigy@mail.iap.ac.cn

coupled device (CCD) sensor protects the cover from water, dust, fog-haze, rain and snow, etc., which may cause observation data error of automatic crop monitoring system. Therefore, the quality control is the basis for the rational usage of the automatic crop monitoring system. Based on the historical crop image data of Zhengzhou, Tai'an and Gucheng, this paper designs a quality control method for image data based on color feature parameter detection and dark channel prior histogram detection. According to different weather conditions, we carried out quality control on the summer maize and winter wheat image observation data in 2010—2012, and the effects were tested. The results show that both types of inspection methods can determine the anomaly data of image observation data in the automatic crop monitoring system. The color feature parameter detection method can effectively identify the missing image of pixels, and the accuracy rate can reach 100%. The proposed method based on the histogram of dark channel can effectively identify the contaminated image, with the average precision being 95.7% and recall average 87.5%. This quality control method can reduce the error between the model estimate and the observed data. At present, this method has been applied to automatic agricultural meteorology observation operational software.

**Key words:** machine learning, crop monitoring picture, control quality, dark channel

## 引 言

农作物实景自动监测系统是借助机器学习、图像处理 and 无线多媒体网络技术和方法,利用电荷耦合器件(charge coupled device, CCD)传感器、图像采集器和通信装置,采集自然光照条件下农作物图像并传输至计算机终端,通过内置的图像识别算法提取图像特征参数,进而反演得到农作物生长特征信息(Sakamoto et al, 2010; Yu et al, 2013; 李翠娜等, 2016)。它具有 24 h 连续工作、时间分辨高、非接触、非破坏性等优点,是对传统农业气象观测的补充,在农业灾害监测领域有重要应用价值(武永峰等, 2010; 李修华等, 2011; 张雪芬等, 2012)。农作物实景监测具有野外观测特质,不同天气条件下其探测资料的精度有差异。桓宗圣等(2014)研究指出受雾-霾、雨雪等气象环境因素影响,由于大气散射作用,农作物图像对比度、颜色清晰度等特征改变,图像特征难以辨认,进而影响图像后期处理和农作物长势的客观判断。因此,开展系统的质量控制是合理使用农作物实景自动监测系统探测资料的基础。

传统的质量控制主要是根据气象学、天气学、气候学原理以及气象要素的时空变化规律和各要素间相互规律为线索,分析观测资料是否合理(Peterson et al, 1998; 熊安元, 2003; 金莉莉等, 2016)。其方法包括:范围检查、极值检查、内部一致性检查、空间一致性检查、气象学公式检查、统计学检查、均一性

检查(任芝花等, 2010; 张乐坚等, 2016; 江勤等, 2017; 刘佩廷等, 2017; 王佳强等, 2018)。农作物实景自动监测系统探测资料主要包括农作物可视图像和农作物生长特征要素。这些要素不同于常规气象要素,传统的质量控制方法不能对其直接使用。目前国内外科学家在农业气象自动化监测领域研究重点主要集中在分割算法和图像特征提取算法等方面,针对农作物图像以及基于图像识别的农作物生长特征参数质量控制的研究很少(Sakamoto et al, 2011; 陆明等, 2011; 孙涛等, 2014; 刘夏等, 2015)。因此,亟需研制一套适用于农作物实景自动监测系统探测资料的质量控制方法。

目前农作物自动监测系统探测资料中的异常数据分为两类:图像像素缺失和图像污染。前者是通信或供电异常引起的图像关键信息缺失,后者是受雾-霾、雨雪和沙尘等气象环境因素引起的图像模糊。本研究利用郑州农业气象试验站、泰安农业试验站和固城生态与农业气象试验站农作物实景自动监测系统 2010—2012 年三年的农作物图像探测资料,设计了一套适用于这两类异常情况下的农作物实景自动监测系统质量控制方法,为业务中有效使用相关图像数据资料提供技术支撑。

## 1 试验情况

以矮秆和高秆代表作物玉米和小麦为研究对象,以郑州农业气象试验站(34.46°N、113.40°E)、

泰安农业气象试验站(36.11°N、117.08°E)和固城生态与农业气象试验站(39.13°N、115.67°E)为主要研究区,试验区地势平坦,土壤类型为壤土。试验选择当地主栽夏玉米优质品种,分别为浚单 20、郑单 958 和冀单 32,行间距均为 90 cm,行内距约为 19 cm,成株株高 250 cm 左右,生育期为每年 6—10 月上旬,出苗至成熟期约需 100 d;而当地主栽冬小麦品种,成株株高 70 cm 左右,生育期为每年 10 月至次年 6 月,出苗至成熟期约需 250 d。

## 2 图像采集

农作物实景自动监测系统由 CCD 传感器、图像采集器、通信传输装置和数据处理终端组成。通过图像采集器设置 CCD 传感器每日 09—16 时整点拍摄作物图像,再利用通信传输装置通过无线网络将获取的农作物图像远程传输至数据处理终端,数据处理终端利用内置的图像识别算法实现农作物覆盖度和叶面积指数的实时自动计算。其中,CCD 传感器镜头焦距为 16 mm,图像采集器和 CCD 传感器离地高度分别为 1 和 5 m,图像分辨率为 2736 px×3648 px。

## 3 质量控制方法设计

### 3.1 图像像素缺失检测方法

#### 3.1.1 图像像素缺失检测原理

本文提出了一种基于图像 RGB 颜色特征参数的图像像素缺失自动检测方法。

众所周知,RGB 色彩模式使用 RGB 模型,为图像中每一个像素的 RGB 分量分配一个 0~255 范围内的强度值。例如:纯红色 R 值为 255,G 值为 0,B 值为 0;白色 R、G、B 值都为 255,而灰色的 R、G、B 三个值相等。当三色灰度数值相同时,产生不同灰度值的灰色调,即三色灰度都为 0 时,是最暗的黑色调;三色灰度都为 255 时,是最亮的白色调。CCD 传感器拍摄农作物图像传输完成时是完整的彩色图像,当图像没有传输完全或传感器异常时,图像像素部分缺失,对于图像像素缺失,图像传输的质量控制算法会自动把缺失像素补充为默认的灰色。通过分析试验中图像像素缺失时的 R、G、B 值,发现当三者

均为 128 时即为农作物图像缺失时的灰色调。

#### 3.1.2 图像像素缺失检测流程

本文通过引入图像不完整率来定量评价图像缺失情况,即整幅图像缺失信息所占的像素数与整幅图像总像素数之比,以此作为图像质量控制的一个重要检测指标。以 2011—2013 年固城生态与农业气象试验站的农作物图像为训练样本,人工挑选出所有像素缺失图像,并统计历史图像缺失时不完整率,设定最小值作为图像像素缺失时质量控制的阈值。主要工作流程见图 1。首先输入农作物图像,接着计算整幅图像的不完整率判别农作物图像是否残缺。最后,若图像不完整率大于阈值,即视为不完整图像,不做进一步的图像污染检测。图 2 为农作物完整图像和不完整图像示例。从图中可以看出图像下部有灰色,即为不完整部分。

图 3 给出了固城生态与农业气象试验站所有样本的图像缺失以及分布比例。2011—2013 年图像像素缺失样本共 88 个,其中图像不完整率在 10% 以下所占比例最低,占总样本数的 6.8%,图像不完整率在 90% 以上所占比例最高,占 17%,说明图像像素缺失严重。为了能尽可能检测到所有图像像素缺失样本,将图像不完整率最小值(即 1.8%)作为阈值。

### 3.2 图像污染检测方法

#### 3.2.1 图像污染检测原理

在基于图像 RGB 颜色特征参数的图像像素缺

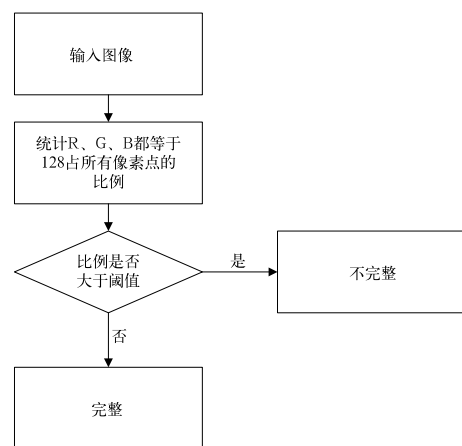


图 1 图像像素缺失质量控制流程

Fig. 1 Pixel missing images quality control process




图 2 夏玉米图像完整(a)和图像像素缺失示例(b)

Fig. 2 An example of complete image (a) and pixel missing image (b) for summer maize




图 3 图像像素缺失样本不完整率(a)及其分布(b)

Fig. 3 Image pixel missing sample incomplete rate (a) and dustrition (b)

失自动检测基础上,农作物实景监测中还有可能出现镜头被灰尘或雾天污染等特殊情况,这些现象会直接影响到农作物的分割以及对覆盖度和叶面积指数的准确计算。图 4 为图像污染时和图像清晰时的夏玉米冠层图像以及农作物分割实例。从图中可以看出,镜头被灰尘污染时,图像清晰度下降且偏色严重,土壤等背景像素也会呈现出一定的绿色,作物分割时误将某些土壤背景像素分割为作物,当清晰拍摄时,相机白平衡正常,不存在偏色情况,因此分割结果较为理想。相机镜头模糊影响了相机白平衡自动调节,使得相机拍摄的照片整体偏色严重。因此,当利用作物分割算法进行作物提取时与非模糊情况相比会产生较大差异。

为了解决以上问题,本文提出了一种基于暗通道先验直方图的图像污染检测方法。该方法源于对大量自然图像进行观测时所产生的的一种先验知识/规律,即在大多数非天空图像块中,一些像素点在至少一个颜色通道中具有很低的强度值。He et al

(2011)指出这样的图像块的最低强度具有非常低的值。基于这样的观测规律,可以从一个新的视角来研究此类现象:暗通道图像。暗通道图像即是获得给定图像的暗像素之后的图像,暗像素表示那些在给定图像块中拥有最低强度值的像素。暗通道图像的形式化表达如下式所示。

$$J_{\text{dark}}(x, y) = \min_{c \in (R, G, B)} \{ \min_{x, y \in \Omega(x, y)} [J_c(x, y)] \} \quad (1)$$

式中,  $J_c$  表示图像的 R, G, B 三个颜色通道的颜色值,  $\Omega(x, y)$  表示以像素  $(x, y)$  为中心的图像块,  $(x, y)$  表示待检测图像像素的坐标值。

暗通道图像的灰度直方图[记为  $H(P)$ ]实际上是灰度级的函数,描述图像中每一灰度级的像素个数(或某一灰度级像素出现的频率);其横坐标是灰度级  $0 \sim 255$ ,纵坐标表示图像中该灰度级出现的个数(频率)。形式化表示见式(2)和式(3)。

$$H(P) = [h(x_1), h(x_2), \dots, h(x_n)] \quad (2)$$

$$h(x_i) = \frac{S(x_i)}{\sum_j S(x_j)} \quad (3)$$

式中,  $h(x_i)$  代表第  $x_i$  阶灰度出现的概率,  $S(x_i)$  为灰度值为  $x_i$  的所有像素数量,  $\sum_j S(x_j)$  为图像总的像素数。

图 5a 和 5d 为被污染图像和未被污染原图, 图 5b 和 5e 为原图对应的暗通道图像, 从图中可以

发现, 被污染图像的暗通道图像较未被污染图像灰度值整体偏高一些, 图像整体更明亮一点。图 5c 和 5f 展示了两个原始图像分别对应的灰度直方图特征, 从图中可以明显地刻画出被污染图像灰度值整体偏高这一灰度分布特性, 被污染图像灰度值较高




图 4 图像污染(a,b)与清晰(c,d)时夏玉米冠层图像(a,c)及其提取结果(b,d)

Fig. 4 Summer maize canopy (a, c) contamination image (a, b) and clear image (c, d) and its extraction results (b, d)

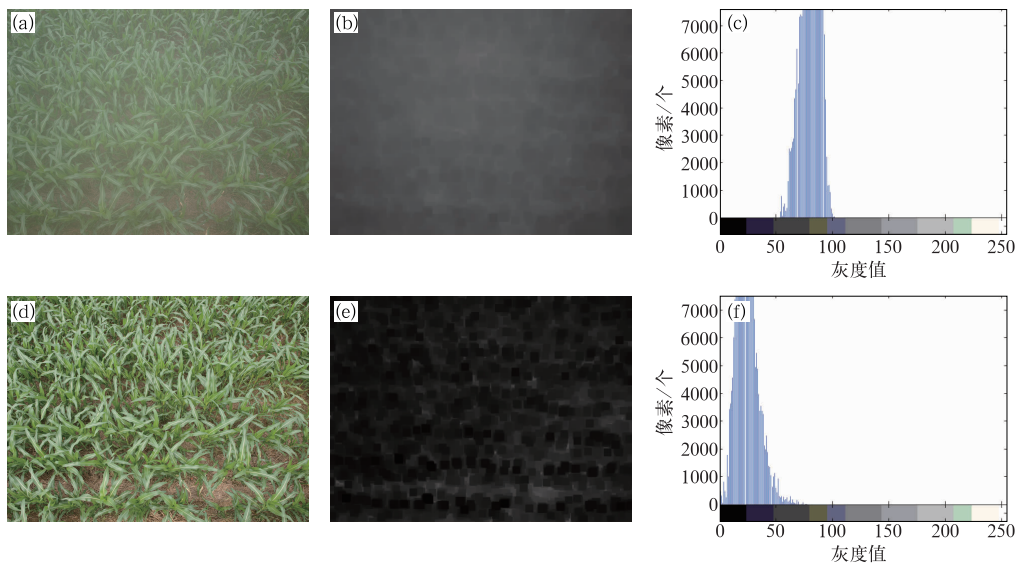


图 5 被污染图像(a,b,c)和未被污染图像(d,e,f)

(a,d)原图,(b,e)暗通道图像,(c,f)暗通道直方图

Fig. 5 Contaminated images (a, b, c) and clear images (d, e, f) including original images (a, d), dark channel images (b, e) and dark channel histograms (c, f)

集中在 60~110 左右,而未被图像污染灰度值则较低,主要集中在 0~60 左右。

确定了图像特征之后,下一步就是确定判别的方法。由于农业气象观测场景相对稳定,因此利用机器学习方法对图像是否被污染进行判别。采用支撑向量机(support vector machines, SVM)技术来完成训练与检测。支撑向量机是将核机制(Muller et al, 2001)应用到监督学习中的机器学习方法,它主要用来解决分类问题。一般来讲,一个分类任务通常由两部分组成,即训练阶段和测试阶段(或分类阶段)。在训练阶段中所采用的数据包括特征集和每个特征对应的类别标记。SVM 的目标就是生成一个分类器模型,使之能够在测试阶段对给定的测试样本特征进行准确地分类。

假设给定一个训练集  $D$ ,该训练集中包括  $n$  个训练样本,形式如下:

$$D = \{(x_i, y_i) \mid x_i \in R^p, y_i \in \{-1, 1\}\}_{i=1}^n \quad (4)$$

式中,  $y_i$  表示给定特征  $x_i$  的类别标签,  $x_i$  表示特征向量,在文中它表示一个 256 维的直方图特征  $H(p)$ ,  $p$  为训练样本所在的特征空间维数。SVM 将特征向量  $H(p)$  映射到一个更高维的空间,在这个空间里建立一个最大间隔超平面,以分开两类特征。在分开数据的超平面的两边建有两个相互平行的超平面,分隔超平面使得这两个平行超平面的距离最大化。

给定一组可分隔空间中的点集(特征),肯定存在一个超平面  $\pi: w \cdot x + b = 0$  能够将这组特征  $x, i = 1, \dots, n$  分割成两个不同的类别。因此, SVM 最终是为了解决如下所示的二次规划问题:

$$\min_{w, b} \frac{1}{2} \|w\|^2 \quad (5)$$

满足

$$y_i(w \cdot x + b) \geq 1 \quad i = 1, \dots, n \quad (6)$$

对于非线性分类问题, SVM 的处理方法是选择一个核函数  $k(\cdot, \cdot)$ , 通过将数据映射到高维空间,来解决在原始空间中线性不可分的问题。

### 3.2.2 图像污染检测方法流程

基于暗通道先验直方图的图像污染检测算法分为训练阶段和检测阶段。主要工作流程见图 6。

(1) 训练阶段:首先人工选取若干张正常图像和受污染图像分别作为正样本和负样本,组成训练样本集。然后获取正负样本图像的暗通道图像,并提取其暗通道直方图特征,再将该特征送入到 SVM

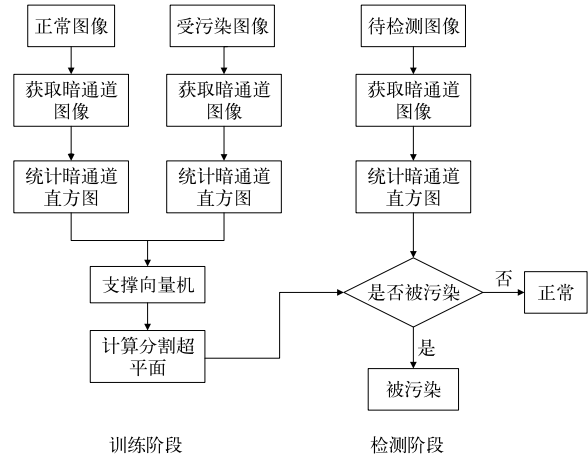


图 6 基于暗通道先验直方图的图像污染检测算法流程图

Fig. 6 Flowchart of pollution image detection algorithm based on dark channel prior histogram

计算分割超平面或分类器。

(2) 检测阶段:先对待检测图像进行特征提取,即获取其暗通道直方图。再用训练得到的 SVM 分类器对该特征进行判断,确定其是否被污染。

通过该算法可以在出现异常情况时会立即自动提醒台站观测人员进行及时的维护,以避免影响后续的自动观测任务。

## 4 结果与分析

### 4.1 图像像素缺失检测方法检验

为了验证本算法的有效性,我们以河南、山东两地 2010—2012 年的作物序列为例进行试验。选择小麦和玉米两种作物序列共计 9993 张图像为对象,根据 3.1 节中设定的阈值对上述作物序列进行检验和分析,检测出图像不完整样本共 99 个(如图 7 所示),占总样本的 1.0%。通过人工目视诊断分析,基于颜色特征参数的图像像素缺失检测算法准确率为 100%,具体检出结果见表 1。

### 4.2 图像污染检测方法检验

为了验证本算法的有效性,我们以河南、山东和河北三地 2010—2012 年拍摄的作物序列为例进行试验。选择小麦和玉米两种作物序列作为考察对象。为了生成 SVM 分类器,从 2010 年拍摄的序列图像中获取正负训练样本,正样本为受污染的图像

表 1 多站点、多作物图像像素缺失检测结果

Table 1 Detection results of multi-site, multi-crop pixel missing images

2010—2012 年 序列	总图像数 /个	不完整图像数 /个	不完整图像 百分比/%
河南玉米	2423	26	1.1
山东玉米	1767	5	0.3
河南小麦	3149	36	1.1
山东小麦	2654	32	1.2

(图 8),负样本为正常图像(图 9),训练样本数量分别为 100 和 250 个。为了减少计算时间,我们将原始采集的图像从 3648 px × 2736 px 降采样到 600 px × 450 px。此外,计算暗通道图像时图像块长宽设为 15 px;对 2011—2012 年的序列图像进行随机采样作为最后的测试样本。

关于 SVM 分类器的参数,由于采用线性核进行训练和测试,因此只有惩罚因子C和最优分类超

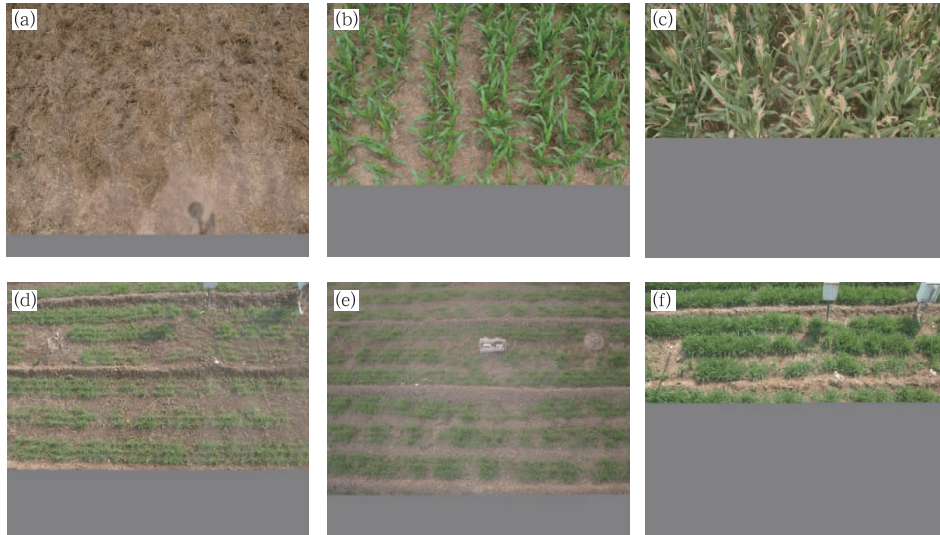


图 7 2010 年玉米(a,b,c)和小麦(d,e,f)图像不完整检测示例  
Fig. 7 Example of incomplete images detection of maize (a, b, c) and wheat (d, e, f) in 2010




图 8 2010 年灰尘或雾-霾正样本图像(a,c,f)和雨滴正样本图像(b,d,e)示例  
Fig. 8 Positives sample images under dust or fog-haze (a, c, f) and raindrops (b, d, e) in 2010

平面的参数需要学习。通过利用 Chang and Lin (2011)提供的 LIBSVM 库,以上的参数都可以自动求解。

试验中利用准确率 (precision) 和召回率 (recall) 两个参数来评估算法的性能。真的正样本 (true positives,  $t_p$ ) 表示利用自动检测方法获取到的受污染图像中,真正被污染的数量;假的真样本 (false positives,  $f_p$ ) 表示利用自动检测方法获取到的受污染图像中,没有被污染的数量。准确率定义为  $t_p$  与标记为受污染图像总数 ( $t_p$  与  $f_p$  之和) 之比,召回率定义为  $t_p$  与真正受污染图像总数 ( $t_p$  与  $f_n$  之和) 之比,公式如下所示:

$$precision = \frac{t_p}{t_p + f_p} \quad (7)$$

$$recall = \frac{t_p}{t_p + f_n} \quad (8)$$

式中,假的负样本 (false negative,  $f_n$ ) 表示利用自动检测方法获取到未被污染图像中真实被污染的数量。

一方面,当准确率越高时,自动检测算法所检测的结果就越可信;反之,越不可信。另外一方面,当召回率越高时,表示漏掉的数量就越少,越有利于保证后续的作物监测。因此,统计了 6 个序列自动检测算法的准确率和召回率,结果如表 2 所示。6 个序列的平均准确率为 95.7%,平均召回率为 87.5%。

经过分析,发现导致检测错误的主要原因包括:(1)户外强光照射下,图像出现亮斑使得图像呈现类似污染的特征(图 10a);(2)镜头拍摄时由于其他原

表 2 不同站点、多种作物图像污染检测结果

Table 2 The detection results of multi-site, multi-crop contaminated images

2011—2012 年序列	准确率/%	召回率/%
河北玉米	98	94
河南玉米	98	90
山东玉米	96	86
河北小麦	94	88
河南小麦	95	87
山东小麦	93	80




图 9 2010 年玉米(a,b,d,e,f)和小麦(c)负样本图片示例

Fig. 9 Negative sample images of maize (a, b, d, e, f) and wheat (c) in 2010




图 10 亮斑(a)、模糊(b)、局部污染(c)和轻度污染(d)检测结果分析示例

Fig. 10 Analysis examples of detection results including bright spot (a), blur (b), local contamination (c), mild contamination (d)



因没有聚焦在作物上导致图片模糊,而实际并非污染所致(图 10b)。此外,导致召回率不高的情况主要发生在算法判别临界区域,例如:发生局部污染而非全局污染(图 10c),或者是虽然受污染但是污染程度较低(图 10d)。

## 5 结论与讨论

(1) 本文分析 2010—2012 年郑州农业气象试验站、泰安农业气象试验站和固城生态与农业气象试验站作物图像探测资料中的异常数据特征,并设计了 2 类质量控制方法,即图像像素缺失检测和图像污染检测。其中,图像像素缺失检测采用基于图像 RGB 颜色特征参数的自动检测方法,图像污染检测则采用一种基于暗通道先验直方图的自动检测方法。

(2) 利用河南和山东两地 2010—2012 年三年的作物生长序列以及 2011—2012 年年河南、山东和河北三地的作物图像观测资料对质量控制方法的应用效果进行检验,结果表明两类检测方法均可有效识别出农作物图像资料中对应的异常数据。

(3) 图像像素缺失检测方法是引入图像不完整率定量评价图像像素缺失程度。试验结果表明,该方法能有效识别出因通信传输或 CCD 传感器异常导致的像素缺失图像,准确率达 100%。

(4) 图像污染检测方法源于对大量自然作物图像进行观测时产生的一种先验知识/规律,采用 SVM 方法对图像是否被污染进行自动判别。试验结果表明,该方法能有效识别出镜头被灰尘或雾天、雨天污染等引起的模糊图像,尤其是大面积污染(全局污染)图像,平均准确率为 95.7%,平均召回率为 87.5%。

(5) 该方法已初步应用于省级农业自动观测业务系统,满足了现有业务中图像质量控制的需要,论文中提供的异常图像的剔除方法确保了后续对观测作物的精细化提取与分析的需要。

## 参考文献

桓宗圣,陶青川,田旺,2014. 野外视频监控图像去雾算法研究[J]. 计算机工程,40(2):240-245. Huan Z S, Tao Q C, Tian W, 2014. Research on image defogging algorithm of field video surveillance[J]. Comput Eng, 40(2):240-245(in Chinese).

江勤,张蕾,王晓峰,等,2017. 飞机气象探测资料(AMДАР)质量控制与质量分析[J]. 气象,43(5):598-609. Jiang Q, Zhang L, Wang X F, et al, 2017. Quality control and quality analysis of aircraft meteorological data[J]. Meteor Mon, 43(5):598-609(in Chinese).

金莉莉,何清,李振杰,等,2016. 乌鲁木齐市气象塔梯度观测资料质量控制与处理[J]. 气象,42(6):732-742. Jin L L, He Q, Li Z J, et al, 2016. Quality control method and treatment for Urumqi meteorology tower gradient observation data[J]. Meteor Mon, 42(6):732-742(in Chinese).

李翠娜,张雪芬,余正泓,等,2016. 基于图像提取技术计算夏玉米覆盖度和反演叶面积指数的精度评价[J]. 中国农业气象,37(4):479-491. Li C N, Zhang X F, Yu Z H, et al, 2016. Accuracy evaluation of summer maize coverage and leaf area index inversion based on images extraction technology[J]. Chin J Agrometeorol, 37(4):479-491(in Chinese).

李修华,李民赞,崔迪,等,2011. 基于双波段作物长势分析仪的东北水稻长势监测[J]. 农业工程学报,27(8):206-210. Li X H, Li M Z, Cui D, et al, 2011. Monitoring of rice plant growth in North-east China using dual-wavebands crop growth analyzer[J]. Trans CSAE, 27(8):206-210(in Chinese).

刘佩廷,徐枝芳,朱克云,等,2017. 地面气压同化递进式 OMB 质量控制方法研究[J]. 气象,43(9):1138-1151. Liu P T, Xu Z F, Zhu K Y, et al, 2017. Study of surface progressive OMB pressure quality control for data assimilation[J]. Meteor Mon, 43(9):1138-1151(in Chinese).

刘夏,陈和平,陈黎,等,2015. 一种自适应的图像去雾算法[J]. 计算机应用与软件,32(2):189-193. Liu X, Chen H P, Chen L, et al, 2015. An adaptive algorithm of image haze removal[J]. Comput Appl Softw, 32(2):189-193(in Chinese).

陆明,申双和,王春艳,等,2011. 基于图像识别技术的夏玉米生育期识别方法初探[J]. 中国农业气象,32(3):423-429. Lu M, Shen S H, Wang C Y, et al, 2011. Initial exploration of maize phenological stage based on image recognition[J]. Chin J Agrometeorol, 32(3):423-429(in Chinese).

任芝花,赵平,张强,等,2010. 适用于全国自动站小时降水资料的质量控制方法[J]. 气象,36(7):123-132. Ren Z H, Zhao P, Zhang Q, et al, 2010. Quality control procedures for hourly precipitation data from automatic weather stations in China[J]. Meteor Mon, 36(7):123-132(in Chinese).

孙涛,刘振波,葛云健,等,2014. 基于数码相片 Gamma 校正的水稻叶面积指数估算[J]. 生态学报,34(13):3548-3557. Sun T, Liu Z B, Ge Y J, et al, 2014. Estimation of paddy rice leaf area index based on photo gamma correction[J]. Acta Ecol Sin, 34(13):3548-3557(in Chinese).

王佳强,赵煜飞,任芝花,等,2018. 中国自动土壤水分观测资料质量控制方法设计与效果检验[J]. 气象,44(2):244-257. Wang J Q, Zhao Y F, Ren Z H, et al, 2018. Design and verification of quality control methods for automatic soil moisture observation data

- in China[J]. Meteor Mon, 44(2):244-257(in Chinese).
- 武永峰, 宫志宏, 刘布春, 等, 2010. 基于远程监控的农业气象自动采集系统设计[J]. 农业机械学报, 41(10):174-179. Wu Y F, Gong Z H, Liu B C, et al, 2010. Automatic collecting system of agro-meteorology information based on remote monitoring technique [J]. Trans Chin Soc Agric Mach, 41(10):174-179(in Chinese).
- 熊安元, 2003. 北欧气象观测资料的质量控制[J]. 气象科技, 31(5):315-320. Xiong A Y, 2003. Quality control of meteorological observational data in Nordic countries[J]. Meteor Sci Technol, 31(5):315-320(in Chinese).
- 张乐坚, 俞小鼎, 李峰, 等, 2016. 地面降水的多源数据辅助质量控制方法[J]. 气象, 42(3):363-371. Zhang L J, Yu X D, Li F, et al, 2016. Quality control method for multi-source data of surface rainfall[J]. Meteor Mon, 42(3):363-371(in Chinese).
- 张雪芬, 薛红喜, 孙涵, 等, 2012. 自动农业气象观测系统功能与设计[J]. 应用气象学报, 23(1):105-112. Zhang X F, Xue H X, Sun H, et al, 2012. Function and designing of automatic observing system for agro-meteorology[J]. J Appl Meteor Sci, 23(1):105-112(in Chinese).
- Chang C C, Lin C J, 2011. LIBSVM: a library for support vector machines[J]. ACM Trans Intell Syst Technol, 2(3):27.
- He K M, Sun J, Tang X O, 2011. Single image haze removal using dark channel prior[J]. IEEE Trans Pattern Anal machine Intell, 33(12):2341-2353.
- Muller K R, Mika S, Ratsch G, et al, 2001. An introduction to kernel-based learning algorithms[J]. IEEE Trans Neural Netw, 12(2):181-201.
- Peterson T C, Vose R, Schmoyer R, et al, 1998. Quality control of monthly temperature data: the GHCN experience[R]. Asheville: National Climatic Data Center/NOAA.
- Peterson T C, Vose R, Schmoyer R, et al, 1998. Global historical climatology network (GHCN) quality control of monthly temperature data[J]. Inter J Climatol, 18:1169-1179.
- Sakamoto T, Shibayama M, Kimura A, et al, 2011. Assessment of digital camera-derived vegetation indices in quantitative monitoring of seasonal rice growth[J]. ISPRS J Photogramm Remote Sens, 66(6):872-882.
- Sakamoto T, Shibayama M, Takada E, et al, 2010. Detecting seasonal changes in crop community structure using day and night digital images[J]. Photogramm Eng Remote Sens, 76(6):713-726.
- Yu Z H, Cao Z G, Wu X, et al, 2013. Automatic image-based detection technology for two critical growth stages of maize: emergence and three-leaf stage[J]. Agric Forest Meteor, 174-175:65-84.