



(12) 发明专利申请

(10) 申请公布号 CN 104598908 A

(43) 申请公布日 2015. 05. 06

(21) 申请号 201410504654. 8

(22) 申请日 2014. 09. 26

(71) 申请人 浙江理工大学

地址 310018 浙江省杭州市下沙高教园区浙江理工大学

(72) 发明人 桂江生 郝丽 张青 汪博 包晓安

(74) 专利代理机构 杭州求是专利事务有限公司 33200

代理人 叶志坚

(51) Int. Cl.

G06K 9/46(2006. 01)

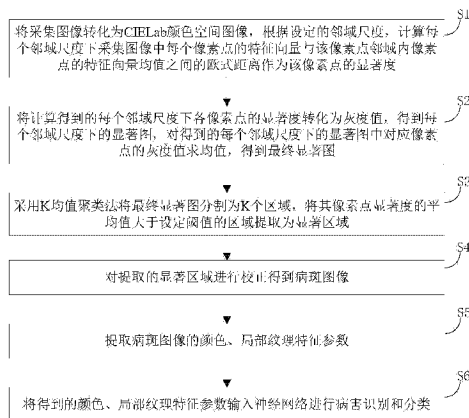
权利要求书2页 说明书8页 附图1页

(54) 发明名称

一种农作物叶部病害识别方法

(57) 摘要

本发明公开了一种农作物叶部病害识别方法,该方法将采集图像转化为 CIELab 颜色空间图像,对每个像素点基于多尺度邻域计算像素点的显著度得到最终显著图,并采用 K 均值聚类法将最终显著图分割为 K 个区域,将其像素点显著度的平均值大于设定阈值的区域提取为显著区域;对提取的显著区域进行校正得到病斑图像;提取病斑图像的颜色、局部纹理特征参数,将得到的颜色、局部纹理特征参数输入神经网络进行病害识别和分类。本发明的方法提取后的病斑图像不存在颜色失真的情况,病害识别准确率高。



1. 一种农作物叶部病害识别方法,其特征在于,包括如下步骤:

将采集图像转化为 CIELab 颜色空间图像,根据设定的邻域尺度,计算每个邻域尺度下采集图像中每个像素点的特征向量与该像素点邻域内像素点的特征向量均值之间的欧式距离作为该像素点的显著度;

将计算得到的每个邻域尺度下各像素点的显著度转化为灰度值,得到每个邻域尺度下的显著图,对得到的每个邻域尺度下的显著图中对应像素点的灰度值求均值,得到最终显著图;

采用 K 均值聚类法将最终显著图分割为 K 个区域,将其像素点显著度的平均值大于设定阈值的区域提取为显著区域;

对提取的显著区域进行校正得到病斑图像;

提取病斑图像的颜色、局部纹理特征参数,将得到的颜色、局部纹理特征参数输入神经网络进行病害识别和分类。

2. 根据权利要求 1 所述的农作物叶部病害识别方法,其特征在于,所述将采集图像转化为 CIELab 颜色空间图像之后,还包括步骤:

将采集图像在 CIELab 颜色空间进行量化处理,量化方法如下:

$$L' = L/L_0$$

$$a' = a/a_0$$

$$b' = b/b_0$$

其中,(L, a, b) 表示采集图像像素点的 CIELab 参数值,(L', a', b') 表示量化后的像素点 CIELab 参数值,L₀、a₀、b₀为量化参数。

3. 根据权利要求 2 所述的农作物叶部病害识别方法,其特征在于,所述量化参数 L₀=6.25, a₀=15, b₀=15。

4. 根据权利要求 1-3 任一权利要求所述的农作物叶部病害识别方法,其特征在于,所述设定的领域尺度为三个,对于宽为 W 像素,高为 H 像素的采集图像,其中 W>H,像素点的邻域尺度 w 变化范围为:

$$\frac{W}{8} \leq w \leq \frac{W}{2} \quad \circ$$

5. 根据权利要求 1 所述的农作物叶部病害识别方法,其特征在于,所述设定阈值为像素点最大显著度的 5%~20%。

6. 根据权利要求 1 所述的农作物叶部病害识别方法,其特征在于,所述对提取的显著区域进行校正得到病斑图像,包括步骤:

首先选择提取了显著区域的采集图像的 RGB 图像中的 R 分量通过最大类间方差法得到最佳阈值,利用这个阈值对提取了显著区域的采集图像进行二值化,得到包括背景区域和目标区域的二值化图像 RW₁;

然后对二值化图像 RW₁中目标区域中出现的空洞进行区域填充,并去除面积小的一些目标区域;

将二值化图像 RW₁对应的 RGB 图像转换到 CIELab 颜色空间里,选择利用 a 分量根据设定的阈值将图像转换为二值图像 RW₂,再将 RW₂转换为 RGB 彩色图像,得到病斑图像。

7. 根据权利要求 1 所述的农作物叶部病害识别方法,其特征在于,所述提取病斑图像

的颜色、局部纹理特征参数,包括步骤:

分别提取病斑图像的 R、G、B、H、S、V 分量的一阶矩、二阶矩作为颜色特征;

采用局部二值模式 LBP 算子均匀模式对病斑图像计算 LBP 值并进行统计得到局部纹理特征。

8. 根据权利要求 1 所述的农作物叶部病害识别方法,其特征在于,所述神经网络为网络结构为 65-50-5 的 Dropout 神经网络,dropout 的比例为 50%。

一种农作物叶部病害识别方法

技术领域

[0001] 本发明属于农作物栽培技术领域,尤其涉及一种基于图像处理的农作物叶部病害识别方法。

背景技术

[0002] 我国幅员辽阔,地形、气候类型复杂多样,从南到北分为热带、亚热带、温带和寒带。然而我国人口众多,耕地面积相对较少,因此农业特别是种植业在我国地位非常重要,关系整个国计民生。我国主要粮食作物有水稻、小麦、玉米、大豆等,经济作物有棉花、花生、油菜、甘蔗和甜菜等。然而随着工业发展,我国的生态系统日渐薄弱,农作物的病害非常严重,病害种类繁多,分布广泛,发生频繁。因此准确、快速地实现农作物病害识别,是农作物病害治理防治的重要环节,成为科技工作者的重要研究方向。

[0003] 在目前的病害识别技术中,已经广泛的采用了计算机和图像处理技术,例如专利号为 201210235693.3 的中国发明专利,就公开了一种农作物叶部病害检测方法,采集待检测农作物的叶部图像并上传至在线检测平台,对待检测农作物叶部病斑图像实现分割与识别,输出检测结果并给出防治建议。

[0004] 但是现有的农作物病害识别分类中病斑分割主要是利用边缘检测法、最大类间方差法、模糊 C 均值法和分水岭分割法,这些方法都需要进行复杂的田间背景分割和一系列的预处理,增加了病斑分割的复杂性。同时在特征提取中,现有的方法中的纹理特征主要是相关性、能量、熵、对比度和逆差等等,这些基于灰度共生矩阵定义许多基于统计法的纹理特征量是全局特征,而局部特征较全局特征来说具有旋转不变性和灰度不变性等显著的优点;而农作物病害识别分类中病害的识别分类主要是利用神经网络、支持向量机以及改进的支持向量机方法,虽然这些方法能够识别出病害种类,但是这些方法所识别的种类数不多,一般都只识别 3 类病害,而且这些方法在进行训练时需要的样本很多,并且识别率不高。

发明内容

[0005] 本发明的目的是提供一种农作物叶部病害识别方法,以避免现有技术病斑图像分割复杂,病害识别不高的技术问题。

[0006] 为了实现上述目的,本发明技术方案如下:

[0007] 一种农作物叶部病害识别方法,包括如下步骤:

[0008] 将采集图像转化为 CIELab 颜色空间图像,根据设定的邻域尺度,计算每个邻域尺度下采集图像中每个像素点的特征向量与该像素点邻域内像素点的特征向量均值之间的欧式距离作为该像素点的显著度;

[0009] 将计算得到的每个邻域尺度下各像素点的显著度转化为灰度值,得到每个邻域尺度下的显著图,对得到的每个邻域尺度下的显著图中对应像素点的灰度值求均值,得到最终显著图;

[0010] 采用 K 均值聚类法将最终显著图分割为 K 个区域,将其像素点显著度的平均值大于设定阈值的区域提取为显著区域;

[0011] 对提取的显著区域进行校正得到病斑图像;

[0012] 提取病斑图像的颜色、局部纹理特征参数,将得到的颜色、局部纹理特征参数输入神经网络进行病害识别和分类。

[0013] 进一步地,所述将采集图像转化为 CIELab 颜色空间图像之后,还包括步骤:

[0014] 将采集图像在 CIELab 颜色空间进行量化处理,量化方法如下:

$$[0015] \quad L' = L/L_0$$

$$[0016] \quad a' = a/a_0$$

$$[0017] \quad b' = b/b_0$$

[0018] 其中, (L, a, b) 表示采集图像像素点的 CIELab 参数值, (L', a', b') 表示量化后的像素点 CIELab 参数值, L₀、a₀、b₀ 为量化参数。因此量化后 CIELab 颜色空间的采集图像被平均分成 16*16*16 个部分并以直方图的形式呈现。通过量化处理这样就解决了 CIELab 颜色空间中三个参数值的范围是不同问题,减少了计算量,便于后续计算。

[0019] 其中,所述量化参数 L₀= 6.25, a₀= 15, b₀= 15。

[0020] 本发明所述设定的领域尺度为三个,对于宽为 W 像素,高为 H 像素的采集图像,其中 W>H,像素点的邻域尺度 w 变化范围为:

$$[0021] \quad \frac{W}{8} \leq w \leq \frac{W}{2} \quad \circ$$

[0022] 本发明设定三个邻域尺度,即保证了显著度的准确性,又考虑了计算量,能便捷准确的获取显著图。

[0023] 本发明所述设定阈值为像素点最大显著度的 5%~20%,优选地选取最大显著度的 10% 来作为设定阈值来提取显著区域。该设定阈值能够较为准确地区分病斑与背景区域,识别效果好。

[0024] 进一步地,所述对提取的显著区域进行校正得到病斑图像,包括步骤:

[0025] 首先选择提取了显著区域的采集图像的 RGB 图像中的 R 分量通过最大类间方差法得到最佳阈值,利用这个阈值对提取了显著区域的采集图像进行二值化,得到包括背景区域和目标区域的二值化图像 RW₁;

[0026] 然后对二值化图像 RW₁ 中目标区域中出现的空洞进行区域填充,并去除面积小的一些目标区域;

[0027] 将二值化图像 RW₁ 对应的 RGB 图像转换到 CIELab 颜色空间里,选择利用 a 分量根据设定的阈值将图像转换为二值图像 RW₂,再将 RW₂ 转换为 RGB 彩色图像,得到病斑图像。

[0028] 通过上述步骤对对提取出显著区域的图像在 RGB 颜色空间基于 R 分量进行二值化处理后,再在 CIELab 颜色空间进行二值化处理,得到病斑图像,所得到的病斑图像更加准确,接近自然人眼观察到的病斑图像。

[0029] 本发明所述提取病斑图像的颜色、局部纹理特征参数,包括步骤:

[0030] 分别提取病斑图像的 R、G、B、H、S、V 分量的一阶矩、二阶矩作为颜色特征;

[0031] 采用 LBP (Local binary Pattern) 算子均匀模式对病斑图像计算 LBP 值并进行统计得到局部纹理特征。

[0032] 本发明所述神经网络为网络结构为 65-50-5 的 Dropout 神经网络, dropout 的比例为 50%。

[0033] 本发明提出的一种农作物叶部病害识别方法,在 CIELab 颜色空间对采集图像进行处理得到病斑图像,对采集的病斑图像的背景没有要求,可以直接在农田中采集即可。提取后的病斑图像不存在颜色失真的情况,为之后的病斑识别打下很好的基础。本发明应用 LBP 算子的均匀模式,提取的纹理特征是局部纹理特征,具有旋转不变性和光照不变性,更适合用来进行识别病害。采用 Dropout 神经网络识别率更高。

附图说明

[0034] 图 1 为本发明农作物叶部病害识别方法的流程图;

[0035] 图 2 为本发明实施例病害识别率的对比图。

具体实施方式

[0036] 下面结合附图和实施例对本发明技术方案做进一步详细说明,以下实施例不构成对本发明的限定。

[0037] 本发明利用计算机视觉技术,对图像采集设备采集到的农作物叶片图像进行分析处理,来识别病害。本实施例以大豆叶部病害为例来进行说明,如图 1 所示,一种农作物叶部病害识别方法,包括如下步骤:

[0038] 步骤 S1、将采集图像转化为 CIELab 颜色空间图像,根据设定的邻域尺度,计算每个邻域尺度下采集图像中每个像素点的特征向量与该像素点邻域内像素点的特征向量均值之间的欧式距离作为该像素点的显著度。

[0039] 由于 CIELab 颜色空间是用来描述人眼可见的所有颜色的最完备的色彩模型,它致力于感知均匀性,它的 L 分量密切匹配人类亮度感知。因此可以被用来通过修改 a 和 b 分量的输出色阶来做精确的颜色平衡,或使用 L 分量来调整亮度对比。这些变换在 RGB 或 CMYK 中是困难或不可能的,它们基于物理设备的输出,而不是人类视觉感知。因此本申请采用 CIELab 颜色空间来进行识别,识别的效果更加准确,并且对于采集的大豆叶部病害图像的背景没有要求,可以直接在农田中采集即可,而且不需要进行预处理。例如不需要进行图像增强预处理,也不需要进行背景分离再分割病斑,减少了分割的复杂性。从而直接在原图像上分割,没有颜色失真,便于后面的颜色特征提取。

[0040] 在 CIELab 颜色空间中三个参数值的范围是不同的,其中 $L \in [0, 100]$, $a \in [-120, 120]$, $b \in [-120, 120]$,为了便于后续的计算,将采集图像在 CIELab 颜色空间进行量化处理,量化方法如下:

$$[0041] \quad L' = L/L_0$$

$$[0042] \quad a' = a/a_0$$

$$[0043] \quad b' = b/b_0$$

[0044] 其中, (L', a', b') 表示量化后的参数值,本实施例设置量化参数 $L_0 = 6.25$, $a_0 = 15$, $b_0 = 15$,这样三个参数的范围就转换为了 $L' \in [1, 16]$, $a' \in [-8, 8]$, $b' \in [-8, 8]$ 。因此量化后 CIELab 颜色空间的采集图像被平均分成 $16*16*16$ 个部分并以直方图的形式呈现。

[0045] 通过量化处理这样就解决了 CIELab 颜色空间中三个参数值的范围是不同问题,减少了计算量,便于后续计算。

[0046] 为了计算采集图像中每个像素点的显著度,需要设置像素点邻域的大小,本实施例结合多尺度分析方法,为采集图像的像素点设置邻域,然后根据邻域计算像素点的显著度。本实施例分别为像素点设置三种不同大小的邻域,邻域的大小对应为邻域尺度,分别计算三种邻域尺度下每个像素点的显著度。本实施例中邻域尺度的数量 h 取为三个,是因为取 3 个尺度相比较取 1、2 计算的显著度来求平均会更加准确,而相比较大于 3 的尺度来说计算量又减小了很多。

[0047] 对于采集图像的任意像素点 p ,通常以像素点 p 的特征向量 V_p 与其邻域中各像素点 q 的特征向量 V_q 的均值的欧式距离为该像素点 p 的显著度 C_p ,计算公式为:

$$[0048] \quad C_p = D[V_p, \frac{1}{N} \sum_{q=1}^N V_q] \quad (1)$$

[0049] 其中, $V_p = [L_p, a_p, b_p]$ 为像素点 p 的特征向量, $V_q = [L_q, a_q, b_q]$ 为其邻域中各像素点 q 的特征向量, N 为其邻域中像素点的个数, D 为欧氏距离。由于在 CIELab 颜色空间中,人所感觉的颜色差距近似为欧氏距离,这里为了方便计算, D 可以表示为:

$$[0050] \quad D = \left\| V_p - \frac{1}{N} \sum_{q=1}^N V_q \right\| \quad (2)$$

[0051] 通常像素点 p 的邻域为宽度为 w 的正方形区域, w 随着输入采集图像的大小选取不同的值。以宽为 W 像素,高为 H 像素的采集图像为例 ($W > H$), w 变化范围为:

$$[0052] \quad \frac{W}{8} \leq w \leq \frac{W}{2} \quad (3)$$

[0053] 在本实施例中, w 选取式 (3) 范围内的 3 个尺度,通过由左到右、由上到下遍历整幅图像,分别计算 3 个尺度下的 C_p 作为像素点 p 的显著度。

[0054] 需要说明的是,本实施例的方法在采集图像存在噪声的情况下,可以将采集图像分割为由像素块组成的图像,每个像素块包括至少一个像素点。本实施例就是以每个像素块为一个像素点来进行说明的,如果每个像素块包括多个像素点,则将每个像素块看作一个单元(一个像素点),按照本发明的方法进行处理,将进一步有效减少噪声的影响。当以像素块为一个处理单元的时候,与将每个像素点作为一个处理单元不同的是,计算显著度时,该处理单元对应的 V_p 是该处理单元中像素点特征向量的均值。

[0055] 步骤 S2、将计算得到的每个邻域尺度下各像素点的显著度转化为灰度值,得到每个邻域尺度下的显著图,对得到的每个邻域尺度下的显著图中对应像素点的灰度值求均值,得到最终显著图。

[0056] 将每个邻域尺度下各像素点的显著度转化到 0 到 255 范围内,由此得到每个邻域尺度下的灰度显著图,对得到的每个邻域尺度下的多幅显著图对应像素点的灰度值求和,就得到与原采集图像一样大小的最终显著图。

[0057] 将各像素点的显著度转化到 0 到 255 范围内,即将显著度规范到图像灰度值的范围内,例如显著度范围是 (0, 100) 时,就相应的都乘以 2.55,这样显著度范围就规范到 0-255 了。

[0058] 最终显著度图 M 为 w 在不同尺度下显著度的均值,如式 (4) :

$$[0059] \quad m_p = \frac{1}{h} \sum C_p \quad (4)$$

[0060] 其中 m_p 为最终显著图中每个像素点对应的最终显著度,本实施例中,对于某一个像素点,其最终显著度为三个尺度下显著度的均值。

[0061] 步骤 S3、采用 K 均值聚类法将最终显著图分割为 K 个区域,将其像素点显著度的平均值大于设定阈值的区域提取为显著区域。

[0062] K 均值聚类法是常用的基于颜色的图像分割方法,本实施例首先采用 K 均值算法对最终显著图进行分割,把最终显著图分割为 K 个区域,再根据平均显著度来判断分割区域是否为显著区域。K 均值聚类算法中的 K 个初始点由爬山算法在图像的三维 CIELab 直方图中自动选取,在获取了 K 个初始点后通过聚类进而得到分割区域 $r_k (k = 1, 2, \dots, K)$ 。

[0063] 对最终显著图 M,对每个分割区域内各个像素点的显著度求平均值 P_k , 如式 (5) :

$$[0064] \quad P_k = \frac{1}{|r_k|} \sum_{p \in r_k} m_p \quad (5)$$

[0065] 其中 $|r_k|$ 为每个分割区域的像素点数。通过设定阈值 T_θ , P_k 小于阈值 T_θ 的区域被去除,剩下的就为采集图像的显著区域。根据经验,设定阈值为像素点最大显著度的 5%~20%,本实施例该设定阈值(显著度阈值)设为 25,即显著图中最大显著度的 10%。

[0066] 需要说明的是,虽然通过上述方法能够更快更准确的提取出显著区域,但是仍然存在一个的问题,当采集图像中的真正的病斑区域与周围区域对比不明显时,会造成误判,导致将非病斑区域作为显著区域保留下来。显然在这种情况下,上述显著区域并不仅仅包含病斑区域,通常还包括病斑区域周围的被误判为病斑区域的部分。对于农作物病害这个比较特殊的对象,要求能够比较完整且准确的分割出病斑,为后续病害特征提取的可靠性和模式识别的准确性提供保证,就需要对提取出来的显著区域做进一步的处理。

[0067] 步骤 S4、对提取的显著区域进行校正得到病斑图像。

[0068] 现有技术对农作物原始图像进行处理得到病斑图像的方法较多,例如背景技术中提到的申请号为 201210235693.3 的中国发明专利就提出了如下的方法:

[0069] 将原始图像从 RGB 模型空间转换至 HIS 模型空间,对 H 分量图像使用最大类间方差法进行动态阈值分割,初步分割得到叶部病斑区域的二值化图像;将所得二值化图像与 I 分量的图像进行叠加运算,消除背景区域对病斑分割造成的误判,得到仅包含病斑区域的二值图像;对上一步所得二值图像,采用形态学方法填充病斑区域内部的孔洞,完整病斑形状。

[0070] 由于病斑的颜色非常复杂,难以用 RGB 颜色空间中任何一种颜色进行描述,而 Lab 颜色空间是一种感官均匀的颜色模式,图像的所有颜色信息都包含在 ab 二维空间中。本实施例选择结合这两种颜色空间对显著区域校正,包括如下步骤:

[0071] 1、首先选择提取了显著区域的采集图像的 RGB 图像中的 R 分量通过最大类间方差法得到最佳阈值,利用这个阈值对提取了显著区域的采集图像进行二值化,得到包括背景区域和目标区域的二值化图像 RW_1 。

[0072] 最大类间方差法是按图像的灰度特性,将图像分成背景和目标两部分,背景和目

标之间的类间方差越大,说明构成图像的两部分的差别越大,当部分目标错分为背景或部分背景错分为目标都会导致两部分差别变小。

[0073] 通过最大类间方差法得到最佳阈值的步骤如下:

[0074] 假设图像的灰度级为 L , 灰度为 i 的像素数目为 e_i , 则总的像素数目是 $E = \sum_{i=0}^{L-1} e_i$,

不妨假设各灰度值出现的概率 $p_i = \frac{e_i}{E}$ ($p_i \geq 0, \sum_{i=0}^{L-1} p_i = 1$), 设以灰度 T 为阈值将待分割图像分割成两个部分, 即大于阈值 T 的目标部分 A 和小于阈值 T 的背景部分 B , 则两部分出现的概率分别为:

$$[0075] \quad p_A = \sum_{i=T+1}^{L-1} p_i, p_B = \sum_{i=0}^T p_i = 1 - p_A$$

[0076] 两部分的灰度均值分别为:

$$[0077] \quad L_A = \sum_{i=T+1}^{L-1} ip_i / p_A, L_B = \sum_{i=0}^T ip_i / p_B$$

[0078] 图像总的灰度均值为:

$$[0079] \quad L_o = p_A L_A + p_B L_B = \sum_{i=0}^{L-1} ip_i$$

[0080] 因此, 可得到两部分的类间方差为:

$$[0081] \quad \sigma^2 = p_A (L_A - L_o)^2 + p_B (L_B - L_o)^2$$

[0082] 显然, p_A 、 p_B 、 L_A 、 L_B 、 L_o 、 σ^2 都是关于阈值 T 的函数。为了得到最优分割阈值, 最大类间方差法把两类的类间方差作为判别的准则, 认为使类间方差最大的阈值即为所求的最优分割阈值。

[0083] 二值化就是根据最佳阈值将提取显著区域后采集图像中的小于该阈值的像素值设置为 0, 通常是背景区域, 而将大于该最佳阈值的像素值设置为 1, 通常对应于目标区域, 从而将目标区域突出出来。

[0084] 由步骤 S3 中得到的显著区域图像 RGB 图像中就只含有不太准确的病斑和黑色的背景, 所以经过二值化后, 小于阈值的设置为 0, 对应的是背景区域, 而大于阈值的设置为 1, 对应的就是目标区域了。

[0085] 2、然后对二值化图像 RW_1 中目标区域中出现的空洞进行区域填充, 并去除面积小的一些目标区域。

[0086] 对目标区域中出现的空洞进行区域填充, 即对目标区域中的空洞 (值为 0), 将其值置为 1。并去除面积小的一些目标区域, 例如去除二值化图像中像素点小于 200 个的目标区域, 将其置为 0。经过上述处理后的二值图像 RW_1 中只剩下的一些面积较大的目标区域, 在本实施例中通常为大豆叶片健部。

[0087] 3、将二值化图像 RW_1 对应的 RGB 图像转换到 CIELab 颜色空间里, 选择利用 a 分量根据设定的阈值将图像转换为二值图像 RW_2 , 再将 RW_2 转换为 RGB 彩色图像, 得到病斑图像。

[0088] 本实施例中设定的阈值为 0, 由于二值图像 RW_2 使图像中背景区域的 R/G/B 分量为 0, 从而保留了目标区域的 R/G/B 分量, 将二值图像 RW_2 重新转换为彩色图像, 就得到目标区

域的 RGB 图像,所得到的目标区域的 RGB 图像就是要求得的病斑图像。

[0089] 步骤 S5、提取病斑图像的颜色、局部纹理特征参数。

[0090] 分别采用颜色矩和 LBP(Local Binary Pattern 局部二值模式)算子均匀模式来提取颜色特征和局部纹理特征:

[0091] (1) 分别提取病斑图像的 R、G、B、H、S、V 分量的一阶矩、二阶矩作为颜色特征,其公式分别为:

$$[0092] \quad \delta_1 = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |I(x, y)|$$

$$[0093] \quad \delta_2 = \left[\frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |I(x, y - \delta_1)|^2 \right]^{1/2} \quad (6)$$

[0094] 其中 $I(x, y)$ 为图像灰度; δ_1 为一阶矩, δ_2 为二阶矩, W 为图像的高度, H 为图像的宽度,得到 12 个颜色特征。

[0095] (2) 采用 LBP 算子均匀模式对病斑图像计算 LBP 值并进行统计得到局部纹理特征。

[0096] 由于 LBP 算子均匀模式是 59 维的,所以根据统计后归一化可以得到 59 维的局部纹理特征。

[0097] LBP 算子均匀模式下 LBP 的计算公式:

$$[0098] \quad LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & U(LBP_{P,R}) \leq 2 \\ P+1, U(LBP_{P,R}) > 2 \end{cases} \quad (7)$$

[0099] 其中

$$[0100] \quad U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (8)$$

[0101] 其中, R 表示邻域的半径, P 表示邻域的像素点个数, g_c 表示中间点的灰度值, g_p ($p = 0, 1, \dots, p-1$) 表示围绕 g_c 以 R 为半径的像素点的灰度值, $U(LBP_{P,R})$ 表示 LBP 算子的均匀性度量,当 $U(LBP_{P,R}) \leq 2$ 时为均匀模式。

[0102] 由于当邻域内包含的采样象素个数 P 取较大值时,得到的直方图向量维数就会较高,导致分类时间耗费较多,因此本实施例中选用模版为 $LBP_{8,1}$ 均匀模式,对计算得到的 LBP 值进行统计,统计 LBP 值中任意一个 LBP 值对应的像素点个数占图像总像素点的比例,这样就得到了 59 维的局部纹理特征。

[0103] 步骤 S6、将得到的颜色、局部纹理特征参数输入神经网络进行病害识别和分类。

[0104] Dropout 是 hinton 最近 2 年提出的,源于其文章 Improving neural networks by preventing co-adaptation of feature detectors(通过阻止特征检测器的共同作用来提高神经网络的性能)。Dropout 是指在模型训练时随机让网络某些隐含层节点的权重不工作,不工作的那些节点可以暂时认为不是网络结构的一部分,但是它的权重得保留下来,因为下次样本输入时它可能又得工作了。

[0105] 本实施例采用 Dropout 神经网络来进行病害识别,Dropout 神经网络首先需要进行训练,在训练过程中,并不是像通常那样对权值采用 L2 范数惩罚,而是对每个隐含节点的权值 L2 范数设置一个上限常数 C ,如果该节点不满足这个约束时,则用 C 值对权值进行一

个规范化操作（即同时除以该 L2 范数值）。然后进入神经网络前向传播函数中，在神经网络的隐含层节点，激发函数值，被计算出来后，隐含层节点的激发函数值 dropoutFraction 百分比的几率被随机清 0。在反向传播中计算节点误差那一项时，其误差项也应该清 0。

[0106] 在测试阶段，使用“mean network（均值网络）”来得到隐含层的输出，也就是在网络前向传播到输出层前时隐含层节点的输出值都要减半（如果 dropout 的比例为 50%）。本实施例采用的网络结构是 65-50-5 的神经网络结构，dropout 的比例为 50%。

[0107] 采用本实施例的方法，实验数据显示，对于五中大豆常见病害来看，大豆会办病的识别率是 100%，叶斑病为 71.15%，黑斑病为 88.33%，褐斑病为 94.23%，靶点病为 94.23%，其分类准确率更高。同时，采用本实施例所需训练样本数比传统的方法所需训练样本数大大减少，一般只需要 10 个左右，并且该方法可以识别的病害种类更多，常见的识别方法一般可识别 3 种病害，而本实施例的方法可识别 5 种以上。如图 2 所示，采用本实施例的 Dropout 神经网络来进行病害识别，比利用神经网络、支持向量机以及改进的支持向量机方法的病害识别率更高。

[0108] 以上实施例仅用以说明本发明的技术方案而非对其进行限制，在不背离本发明精神及其实质的情况下，熟悉本领域的技术人员当可根据本发明作出各种相应的改变和变形，但这些相应的改变和变形都应属于本发明所附的权利要求的保护范围。

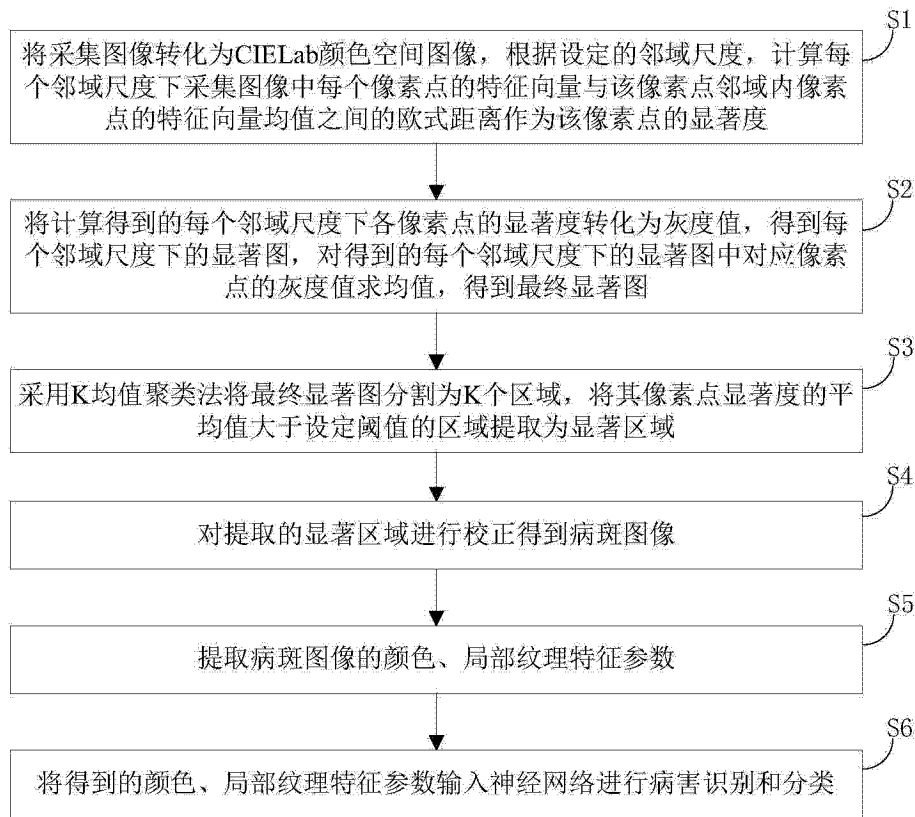


图 1

识别方法	Dropout 神经网络	神经网络	蚁群算法改进的支持向量机	支持向量机
大豆病害				
大豆灰斑病	100%	96.1538%	63.3333%	96.5385%
大豆叶斑病	71.1538%	48.0769%	53.8461%	59.6154%
大豆黑斑病	88.3333%	46.1538%	98.3333%	58.3333%
大豆褐斑病	94.2308%	53.8461%	92.3077%	100%
大豆靶点病	94.2308%	90.3846%	94.2308%	90.3846%
5类病害混合	89.9848%	69.9219%	79.5455%	77.2727%

图 2