

太阳能电池背面电极的分割与缺陷检测*

邬依林¹, 萧华希², 李万益¹, 陈国明¹, 张谦¹, 刘屹^{2,3}

1. 广东第二师范学院计算机学院, 广东 广州 510303
2. 华南理工大学自动化科学与工程学院, 广东 广州 510640
3. 广州现代产业技术研究院, 广东 广州 511458

摘要: 自动化质量检测系统是太阳能电池生产过程中必不可少的环节, 其目的是识别潜在产品缺陷, 但鲜见对太阳能电池的背面电极的检测问题的文献, 针对该问题提出一种完整的背面电极分割和缺陷检测算法。首先, 利用边缘强度投影和模板匹配方法依次获得电极的粗略位置和较精准位置; 然后采用阈值法和种子生长法提取电极边缘点。第三, 利用边缘点生成一个闭合的区域来表示电极的形状。最后, 设计了一种判断电极是否存在缺陷的方法。为了验证该方法的性能, 针对电极分割的精确度进行了实验。实验结果表明, 提出的电极分割检测方案优于实验中四种著名的方法。

关键词: 机器视觉; 缺陷检测; 图像分割; 太阳能电池

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 2097-0137(2022)04-0160-10

Segmentation and defect detection for back electrodes in solar cells

WU Yilin¹, XIAO Huaxi², LI Wanyu¹, CHEN Guoming¹, ZHANG Qian¹, LIU Yu^{2,3}

1. School of Computer Science, Guangdong University of Education, Guangzhou 510303, China
2. College of Automation Science and Engineering, South China University of Technology, Guangzhou 510640, China
3. Guangzhou Institute of Modern Industrial Technology, Guangzhou 511458, China

Abstract: An automatic quality inspection system, aiming to identify potential product defects, is essential for the production of solar cells. But few papers focus on the detection of back electrodes in solar cells, for which a complete algorithm is proposed to segment back electrodes and check for defects on them. Firstly, coarse and fine positions of electrodes are obtained using the edge intensity projection and template matching method. Secondly, the edge of electrodes is extracted by the threshold method and seed growing method. Thirdly, an edge-to-region method is adopted to generate a closed region with edge points. Finally, a method is designed to judge whether there are defects in electrodes or not. To verify the performance of the proposed method, an experiment is carried out. From the ex-

* 收稿日期: 2021-02-02 录用日期: 2021-03-18 网络首发日期: 2021-08-24

基金项目: 国家自然科学基金(61273109); 广东省普通高校特色创新项目(自然科学类)(2018KTSCX163); 广东省科技计划项目(2022A1515010485, 2019A050510015); 广东省基础与应用基础研究基金(2020B1515120071); 广东省高等学校教学质量与教学改革工程项目“广东第二师范学院计算机实验教学示范中心”; 广东第二师范学院教学质量与教学改革工程项目(2018sfzx01); 广州市科技计划项目(201804010280); 广东第二师范学院网络工程重点学科(ZD2017004); 华南理工大学中央高校基本科研业务费重点项目(2020ZYGXZR059)

作者简介: 邬依林(1970年生), 男; **研究方向:** 复杂系统建模、图像处理、网络控制、非线性系统;
E-mail: lyw@gdei.edu.cn

periment result, the proposed segmentation method for electrodes outperforms the four famous methods implemented in the experiment.

Key words: machine vision; defect detection; image segmentation; solar cell

众所周知, 太阳能是一种可再生能源, 具有容易获取、可持续利用、环保等优点。基于光伏效应, 太阳能电池可以将太阳能转化为电能, 因此太阳能电池有着很大的市场前景。但是, 太阳能电池的生产是一个复杂的过程, 在生产过程中出现任何意想不到的错误都会导致缺陷的发生, 这可能会对电池造成很大的损害。因此, 一个质量检测体系对于太阳能电池生产线是至关重要的。

为了识别和分割太阳能电池或其他工业产品中的各种缺陷, 在过去的十年里, 大量基于机器视觉的方法被提出。在文献[1]中, Rebhi等提出了一种基于局部均匀性和数学形态学的织物疵点检测算法, 但是没有给出任何关于结果的数据。文献[2]提出了一种用于球栅阵列组件的在线定位和缺陷检测方案。独立成分分析在文献[3]中被用于检测光伏模块的缺陷。Dhimish等^[4]提出了一种利用逐位网格技术和“OR”操作来检测太阳能电池微裂纹的新方法。然而, 将两张带有纹理或结构背景的图像对齐不是一件容易的工作。文献[5]采用OTSU^[6]的方法检测基于介观技术获得的图像的表面缺陷, 但是该方法只能检测灰度与背景不同的缺陷。文献[7]基于Canny^[8]的方法, 设计了自适应阈值检测织物上的缺陷。为了克服光照不均的问题, 文献[9]采用离散余弦变换(discrete cosine transform, DCT)重建背景, 增强缺陷。在文献[10]中, 图像被分割成多个超像素, 然后训练支持向量机(support vector machines, SVM)分类器来判断某个超像素是否属于被分割的目标。文献[11]基于图的层次聚类算法实现脑组织磁共振图像的自动分割, 文献[12]采用马氏距离分类法对柑桔彩色图片中的不同元素进行了分类。上述方法大多是针对特定类型的缺陷检测, 如微裂纹、污渍、划痕、孔洞等与背景灰度不同的缺陷。除了分割缺陷外, 机器视觉技术也用于分割其他物体, 如文献[13]提出了分割LED支架的算法。在生物邻域, 文献[14]给出了白细胞的分割方案。经典的活动轮廓模型^[15-16]是一种通用的分割方法, 但由于其计算量大, 而且需要人手动初始化轮廓, 对图像质量要求较高, 因此没有广泛应用到实时的缺陷检测中。

由于不需要为特定类型的缺陷设计特征, 基于神经网络的方法成为近年来流行和强大的技术。Chen等^[17]利用深度卷积神经网络成功地分割了塑料外壳表面划痕。Dong等^[18]利用全卷积网络(fully convolutional network, FCN)^[19]自动提取的特征来训练随机森林分类器, 成功检测到了航空焊缝射线图像中的微小缺陷。在生物医学邻域, 文献[20]设计了带有引导模板的神经网络来分割眼球血管, 文献[21]使用集成深度学习的方法来分割皮肤病变区域。在实际应用中, 针对特定任务训练一个网络模型仍然面临数据不足、样本不平衡、性能不稳定等问题。

本文从效率和性能两个方面考虑, 提出了一套完整的太阳能电池背面电极的定位和分割方法。

1 电极分割算法

本节阐述了太阳能电池背面电极的分割和缺陷检测完整方法, 包括粗定位、精定位、边缘分割, 区域生成算法和缺陷检测5个部分, 其流程图如图1所示。

1.1 粗定位

由于初始图像的尺寸比较大, 为了减少处理时间和亮度不均匀的背景的影响, 需要从初始图像中裁剪电极。投影方法和多项式拟合是粗定位算法中使用的基本方法, 其细节在后文阐述。

如图2所示, 在电池硅片上, 一共有54个背面电极, 以9行6列的方式排列。在获得硅片的包围矩形后(如图2中的黄色大矩形框), 下一步是定位电极阵列9行和6列的大概位置。据观察, 电极周围有很强的梯度强度。因此, 应用Sobel算子得到两个方向的梯度, 分别记为 G_x 和 G_y , 计算一个矩阵每一行或列的某个量(如均值、最大值), 称为投影法, 它是将二维矩阵转换为一维向量的常见方法。本小节中, 通过均值投影, 将 G_x 投影到Y轴上, 将 G_y 投影到X轴上, 结果分别记为 M_y 和 M_x 。

下面以 M_x 为例, 描述粗定位的算法流程。粗定位算法的主要变量如图3所示。首先, 利用3阶多项式曲线来拟合 M_x , 拟合结果记为 M_{fx} 。在实际工程中, 为降低运算量, 可对 M_x 以间隔10个长度单位进行采

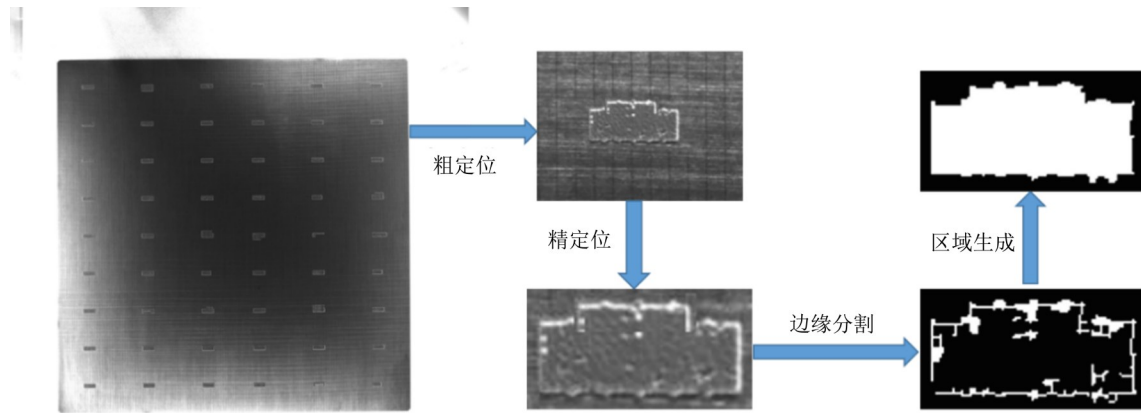


图1 本文方法的流程图

Fig. 1 The flow chart of the proposed method




图2 原始图像以及粗定位结果

Fig. 2 Initial image with coarse positioning result

样。定义中间变量 M_p 为

$$M_p = \max\{M_x - M_{fx}, 0\}. \quad (1)$$

定义阈值 T_m 为

$$T_m = \frac{1}{2n_p} \sum_{M_p(i) > 0} M_p(i), \quad (2)$$

其中 n_p 是 M_p 中值大于 0 的数的个数。利用此阈值, 将 M_p 二值化为

$$B_x(i) = \begin{cases} 1, & M_p(i) > T_m; \\ 0, & \text{其他}, \end{cases} \quad (3)$$

在式(2)、式(3)中, $i = 1, 2, \dots, N_x$, N_x 是 M_x 的长度。

在 B_x 中等于 1 的区域就是可能的电极列位置, 而列与列之间的相对的位置都是固定的, 因此需要一个模板来确定列的位置。模板 T_p 由无缺陷的样品中获得, 使用二值曲线表示每列电极的相对位置。接着, 需要将 T_p 与 B_x 进行对齐。将 T_p 视为滑动窗口, 在 B_x 上滑动, 计算 T_p 与 B_x 的交集的大小。偏置 Bias 在交集最大的地方得到, 图 3 清楚地展示这个过程。同样, 由 M_y 可确定电极行位置。由粗定位算法得到的电极




图 3 粗定位算法的主要变量

Fig. 3 Main variables in the coarse positioning method

阵列的行区域和列区域结果如图 2 所示。

1.2 精定位

利用粗定位的结果, 从原始图像中裁剪出 54 个较小尺寸的图像, 每个图像最多包含一个电极。本小节将描述精定位算法, 以得到一个更加精确的定位。首先使用 Sobel 算子计算图像的梯度图, 记为 I_c 。使用最大值投影, 即分别计算 I_c 每行和每列的最大值, 结果分别记为 P_x , P_y , 如图 4 所示。为了简便, 以 P_y 为例说明精定位算法。对整个 P_y 计算一个加权平均值, 记为 A_w , 由下式计算

$$A_w = \frac{\sum_{i=1}^{n_y} w_i P_y(i)}{\sum_{i=1}^{n_y} w_i}, \quad (4)$$

其中 $w_i = \text{abs}(i - n_y/2)$, $i = 1, 2, \dots, n_y$, n_y 是 P_y 的长度。图 4 中, 将 A_w 视为一条水平直线, 与 P_y 画在一起。在 A_w 与 P_y 相交而形成闭合的区域中, 面积最大的区域就是电极所在的位置。该区域的两个端点, 记为 p_1 , p_2 , 向 P_y 两侧移动到最近的极小值点。对 P_x 进行相同的处理, 最终得到一个电极的包围矩形(图 4 中红色矩形框), 就是精定位的结果。该精定位算法的主要贡献是将电极定位在小范围内, 去除大部分不均匀、复杂的背景。




图 4 精定位算法结果

Fig. 4 Result of the fine positioning method

1.3 边缘分割

据观察, 电极的灰度和纹理特征是变化的, 且较大概率与背景相似。从图 5 的测试图像中可以看出, 电极最明显的特征是其周围或内部有较强的梯度强度。因此, 梯度是用于分割电极的主要信息, 即使它可能在电极边界的一侧较弱, 对噪声敏感。通常情况下, 梯度图的强度范围较大, 很难选择一个阈值来区分目标和噪声。本小节首先利用电极的形状先验, 基于直方图选取了 3 个阈值, 得到对应的二值图像, 然后使用种子生长方法来选择目标边缘点。具体步骤阐述如下。

可由 Sobel 算子计算得到两个方向的梯度图 I_x 和 I_y , 再经过一个 5×5 的高斯核模糊后, 对 I_x 和 I_y 使用

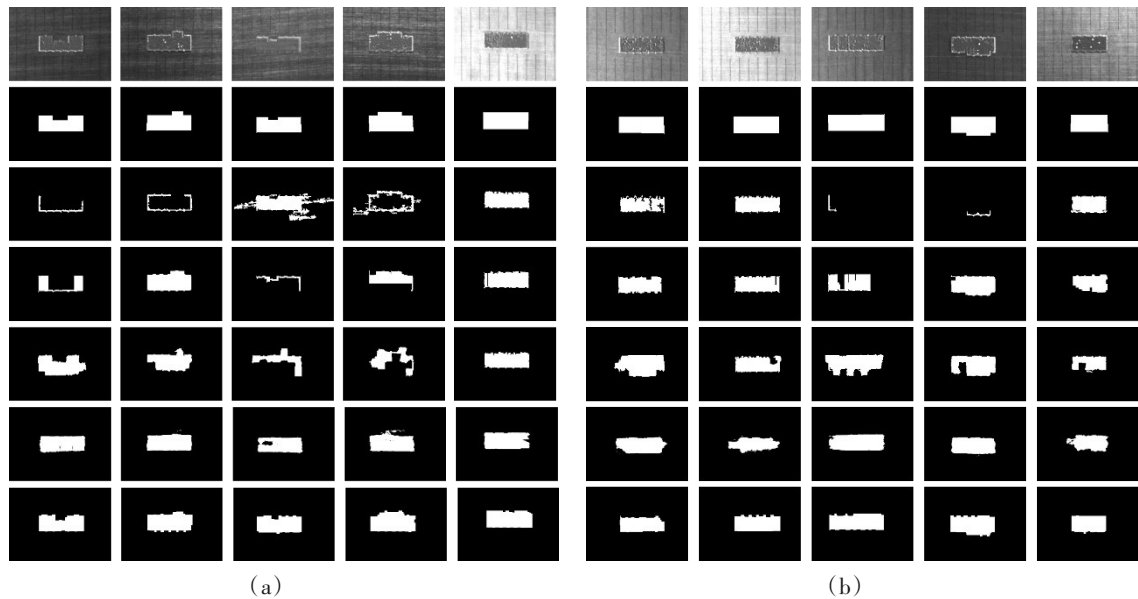


图 5 不同方法的分割结果。从第一行到最后一行依次是：测试图像，标签，
分别来自 DCT-T, CED, DCT-SVM, FCN 和 PM 的结果

Fig. 5 The segmentation results of different methods. The raw images, ground truth, and segmentation results obtained by DCT-T, CED, DCT-SVM, FCN, and PM are shown from top to bottom

非极大值抑制(non-maximum suppression, NMS)来细化边缘。接下来以 I_y 为例, 阐述一种基于直方图的阈值选择方法。首先将 I_y 归一化到 0~255 范围内, 计算其直方图 H_y , 再将 H_y 转换到 0~1 的概率范围。 H_y 的累加和 A_{sy} , 由下式计算

$$A_{sy}(i) = \sum_{j=0}^i H_y(j), \quad (5)$$

其中 $i = 0, 1, \dots, 255$. 给定一个比例系数 p , 找到满足以下条件的阈值 T

$$A_{sy}(T+1) > p \text{ 且 } A_{sy}(T) \leq p. \quad (6)$$

这个方法的意义是选择一个大于 $100 \times p\%$ 的点的阈值, 因为梯度越大, 就越可能是目标的边缘点。 I_y 代表的是水平的边缘, 而无缺陷电极是矩形的。因此对于一个 $h \times w$ 图像, 在理想情况下, 大约有 $2 \times w$ 水平边缘点属于电极的水平边界。因此, 可设计 I_y 的比例系数 p 为

$$p_y(i) = 1 - \frac{i \times w}{h \times w} = 1 - \frac{i}{h}. \quad (7)$$

类似地, I_x 的比例系数 p 定义为

$$p_x(j) = 1 - \frac{j \times h}{h \times w} = 1 - \frac{j}{w}. \quad (8)$$

我们设置 $i = 2, 3, 4$, $j = 3, 4, 5$, 分别得到 I_y 和 I_x 各 3 个阈值。从高阈值到低阈值, 从 I_y 得到 3 个二值图像, 分别记为 B_{y1} , B_{y2} 和 B_{y3} . 从 I_x 得到 3 个二值图像, 分别记为 B_{x1} , B_{x2} 和 B_{x3} . 使用“按位或”操作将两张对应的二值图像进行组合, 再使用 3×3 核的形态学闭操作来连接小间隙, 用公式可表达为:

$$G_i = (B_{yi} \cup B_{xi}) \cdot K, \quad i = 1, 2, 3, \quad (9)$$

其中 \cup 表示按位或操作, \cdot 表示形态学闭操作, K 是一个 3×3 的结构元素。结果如图 6(a)~6(c) 所示。 G_1 由最高的阈值获得, 表示梯度最强的边缘点。 G_2 和 G_3 由更低的阈值得到, 包含更多的目标点和噪声点。

为了进一步减少背景的面积, 使用 G_1 来获得一个掩模。具体来说, G_1 的每一列中, p_l 和 p_r 分别对应第一个和最后一个白点的位置。令 p_l 和 p_r 之间的点为 1, 其他的点 0, 结果记为 M_c . 对 G_1 中的每一行进行相同的操作, 得到 M_r . 二者的并集, $M_{or} = M_c \cup M_r$, 即为需要的掩模。以上 3 个掩模如图 6(e)~6(g) 所示。 M_{or} 可以用来消除 G_2 , G_3 中的噪声点:

$$G_2' = G_2 \cdot M_{or}, \quad (10)$$




图6 边缘分割算法中的一些中间变量

Fig. 6 Some variables in the edge segmentation algorithm

$$G_3' = G_3 \cdot M_{or}, \quad (11)$$

其中 \cdot 表示点乘运算。

本文采用一种基于种子生长的方法来选择目标边缘点。经典的种子生长方法, 由种子点和候选点进行, 任意与种子点连通的候选点都会被选中, 结果 G_{sc} 可表示为

$$G_{sc} = G_s \oplus G_c, \quad (12)$$

其中 G_s 是种子点掩模, G_c 是候选点掩模, \oplus 表示种子生成过程。依次进行以下的步骤

$$G_{12} = G_1 \oplus G_2', \quad (13)$$

$$G_n = G_2' - G_{12}, \quad (14)$$

$$G_3'' = G_3' - G_n, \quad (15)$$

$$G_{123} = G_{12} \oplus G_3'', \quad (16)$$

其中 G_{123} 是最终的边缘分割结果, 显示在图6(d)中。本文的目的是得到电极的区域, 而不是零散的边缘点, 因此下一节将会描述使用边缘点生成闭合区域的方法。

1.4 区域生成算法

用边缘分割方法得到边缘图后, 下一步是为 G_{123} 绘制封闭轮廓。可将轮廓分为上、下、左、右4个部分, 分别表示为 P_u , P_d , P_l 和 P_r 。下面介绍一种利用标志 F 修改曲线 C 的方法。如果在一个连续的区间, $F(i) = 1$, 比如 $i = a_1, a_2, \dots, a_k$, 则区间两端的相邻点 $C(a_1 - 1)$, $C(a_k - 1)$ 可以通过一个函数 $f(C(a_1 - 1), C(a_k + 1))$ 计算替代值, 来取代曲线 C 在这个区间上的值。在图7的例子中, 则使用了线性插值函数来修改曲线 C 。




图7 使用标志修改曲线的例子

Fig. 7 An example of modifying curve with flag

以 P_u , P_d 为例, 它们分别记录了 G_{123} 中每一列第一个和最后一个白点的位置, 两个白点分别记为 p_t , p_b . 如果 p_t , p_b 相连, 即二者之间的点全是白点, 标志 f_{ud} 被设为 1, 否则设为 0. 这个标志代表某一侧轮廓点丢失. 利用标志 f_{ud} 和上述的曲线修改方法, P_u 使用最小值函数修改, P_d 使用最大值函数修改.

为了消除 P_u 中由于噪声引起的剧烈跳变, 将 P_u 与 $k = [-1, 2, -1]$ 进行卷积运算, 可得

$$g_u = |P_u \otimes k|, \quad (17)$$

其中 \otimes 表示卷积运算. 当 $g_u(i) > T_u$ 时, 对应的标志 $f_i(i) = 1$, 否则为 0, 其中 T_u 是一个阈值, 在实验中设为 10. 类似地, 使用线性插值方法来修改 P_u . 此外, 漏边缘会导致 P_u 产生间隙, 可以采用上述的处理方法进行平滑处理, 即找到间隙位置, 用线性插值方法更新 P_u . 上述处理的结果如图 8 所示.

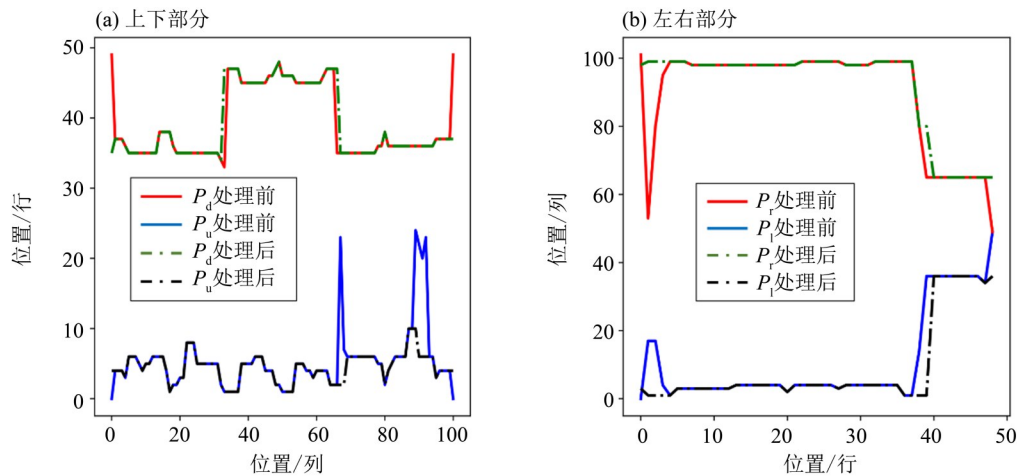


图 8 四部分轮廓处理前后

Fig. 8 Four parts of contours before and after processing, (left) up and down parts; (right) left and right parts

使用相同的步骤来获得和处理 P_l 和 P_r . 然后令 P_u 和 P_d 之间的点为 1 生成掩模 M_1 , 令 P_l 和 P_r 之间的点为 1 生成掩模 M_2 . 计算二者的交集

$$M_3 = M_1 \cap M_2, \quad (18)$$

其中 \cap 表示“按位与”运算, M_3 表示最后的结果, 代表电极的区域, 显示在图 6(h) 中.

1.5 缺陷检测

为了评价所提出的电极分割算法的性能, 设计了一种利用上述步骤的分割结果 M_3 来判断电极上是否存在缺陷的方法. 无缺陷电极为矩形, 可以根据其形状判断电极是否有缺陷. 标准的宽度和长度可以用无缺陷电极计算获得. 可将其长宽表示成一个区域范围, 即 $w_s = [w_{\min}, w_{\max}]$ 和 $h_s = [h_{\min}, h_{\max}]$. 这里 $w_{\min} = 31$, $w_{\max} = 41$, $h_{\min} = 88$ 和 $h_{\max} = 98$. 通过形态学处理剔除 M_3 的小尖峰和小凹坑, 然后计算其包围矩形的尺寸 $h_b \times w_b$. 如果 h_b 或 w_b 超出 h_s 或 w_s 的范围, 则说明电极有缺陷, 否则需进一步判断. 在本文中, 所有二值图像白色部分的值等于 1. 分别计算 M_3 在包围矩形中, 在 X 和 Y 方向上的“和”投影 (即为每行和每列求和), 结果分别记为 S_w 和 S_h . 然后定义两个阈值

$$T_w = \max\{w_{\min}, w_b - T_a\}, \quad (19)$$

$$T_h = \max\{h_{\min}, h_b - T_a\}, \quad (20)$$

其中 T_a 设为 5. 对于 S_w 或 S_h , 如果在一个连续的区间, 有 $S_w < T_w$ 或 $S_h < T_h$, 并且这个区间的长度大于一个阈值 T_b , 则认为该电极有缺陷. 在实验中取 $T_b = 7$. T_a 和 T_b 是两个控制缺陷大小的参数, 即只有尺寸大于 $T_a \times T_b$ 的缺陷才会被检测到.

2 实验

在本节中, 设计了一个实验, 通过与四种著名的方法对比来评估本文方法的分割精度. 所有的算法都是由 Python 语言编写, 运行在 2.9 GHz Intel Core i5 处理器和 8 GB 内存的笔记本电脑上.

2.1 数据集

测试图像由第1.1节所述的粗定位算法获得, 图像大小相同, 为 158×218 。事实上, 大部分电极只要使用简单的阈值法就能分割。为了评估所提出方法在复杂情况下的性能, 选取至少包含以下情形之一的100个样本作为数据集: 光照不均匀、存在强光污染、电极边界弱以及电极灰度与背景灰度相似。然后在选取的样品中随机添加漏印和漏浆这两种人工缺陷。漏印使得电极缺失一部分, 而漏浆使得电极多出一部分。每个样本的像素级标签掩模由人工画出。考虑到涉及学习方法, 这里选取50幅有缺陷图像和50幅无缺陷图像作为测试集, 训练集中包含25幅有缺陷图像和25幅无缺陷图像。实验中的所有方法都使用测试集进行性能评估。

2.2 对比方法

实验中将四种方法与本文提出的方法进行了比较, 并对传统方法进行了一些预处理操作。将本文提出的方法缩写为PM(proposed method)。为了克服光照不均的问题, 可以采用离散余弦变换(DCT)^[9]重构背景。第一种方法是OTSU阈值法^[6]加DCT, 记为DCT-T。第二种方法是Canny^[8]的边缘检测方法(记为CED), 其两个阈值的选取方法与1.3节相同, 预处理和后处理操作与PM相同。联合DCT和文献[10]中的支持向量机(SVM)分类器是第三种方法, 记作DCT-SVM。全连接网络(FCN)^[19]是第四种方法。

2.3 评价指标

采用3个指标来评价方法的性能, 分别为假阳性率(false positive rate, FPR)、假阴性率(false negative rate, FNR)和平均绝对误差(mean absolute error, MAE), 定义如下

$$FPR = \frac{FP}{FP + TN}, \quad (21)$$

$$FNR = \frac{FN}{FN + TP}, \quad (22)$$

$$MAE = \frac{FP + FN}{FP + TP + FN + TN}, \quad (23)$$

其中 FP 为 TP 分别是实验中的假阳性和真阳性, FN 和 TN 分别为假阴性和真阴性。电极区域被定义为阳性, 背景区域被定义为阴性。比如, 一个属于阳性的像素, 被某种方法判别为阴性, 则称为假阴性, 其他定义以此类推。FPR是实验中阴性像素被错判为阳性的比例, FNR则是阳性像素被错判为阴性的比例, MAE是错分类的像素占有所有像素的比例。使用对比方法的预测结果和样本的像素级标签计算以上3个指标, 可以评价方法的像素级分割精度。另外, 分割是为了识别缺陷, 若是一个方法的像素级精度略低, 但它能准确表示出样本是否有缺陷, 则这个方法也是优秀的。因此, 利用1.5节的缺陷检测方法, 判断每个测试样本是否有缺陷。根据检测结果, 计算以上3个评价指标。总的来说, 3个评价指标会以两种形式计算, 一种是像素级形式(pixel-wise form), 用来评估分割方法的像素级精度, 另一种是样本级形式(sample-wise form), 用来评估方法识别缺陷的能力。

2.4 实验结果分析

图5中展示了10幅测试图像及不同方法对应的分割结果, 表1中展示了不同算法总体性能的3个指标, 包括像素级形式和样本级形式。在3个指标之中, MAE是最能体现图像分割总体性能的指标。从表1可看出, DCT-T方法的效果最差, MAE值最大, 因为阈值方法只利用了灰色信息。当目标的灰度值与背景相似, 或边界具有较强的灰度强度时, 利用灰度信息很难将目标与背景分离。DCT-SVM的效果也较差, 因为该方法将每个超像素视为一个待分类的对象, 用灰度值、一阶导数和二阶导数的协方差作为特征向量, 遗憾的是, 目标的灰度值或梯度强度不稳定或与背景相似, 无法训练出满意的SVM分类器。CED方法采用边缘信息对目标进行分割, 但CED方法的两个阈值的选取不够稳健, 无法得到满意的结果。本文提出的方法与CED算法都是基于梯度的分割方法, 它们的区别是, CED使用双阈值, 而PM使用3个阈值, 同时利用最高阈值生成的二值图像, 计算了一个初始掩码, 将目标限定在这个掩码内, 有效消除了掩码外的噪声干扰。而CED方法并没有利用高阈值得到的二值图像。FCN在像素精度方面似乎比PM有更好的结果, 而从样本级的指标却得到了相反的结论。从图5也可以看出, FCN并不能很好地识别缺陷的区域。图5(a)中第一个样品的FN和FP如图9所示。对于FCN, FP和FN分别为370和42, 错分类像素数为410; 对于PM, FP和FN分别为233和117, 错分类像素数为350。二者有着相近的像素分割精度, 但从

表 1 两种形式的评价指标
Table 1 Evaluation metrics of two forms

形式	方法	FPR	FNR	MAE
像素级	DCT-T	0.018 8	0.605 1	0.075 4
	CED	0.002 9	0.226 5	0.024 5
	DCT-SVM	0.019 0	0.194 0	0.035 9
	FCN	0.005 2	0.067 1	0.011 2
	PM	0.005 1	0.095 7	0.013 9
样本级	DCT-T	0.64	0.02	0.33
	CED	0.26	0.58	0.42
	DCT-SVM	0.90	0.00	0.45
	FCN	0.64	0.24	0.44
	PM	0.00	0.02	0.01

分割结果的形状来看, PM 的结果的形状比 FCN 的更接近真实标签。这就是采用本文 1.5 节设计的检测缺陷方法来计算样本级形式的指标的原因。尽管 FCN 在像素形式下的 MAE 较低, 但在样本形式下的 MAE 较高, 这意味着它无法以准确的形状分割电极。另外, 可以看出, PM 在像素级上的 FNR 比 FCN 高。其原因是, 电极具有较厚的边界, 从而导致出现双边缘, NMS 操作可能删除其中一个, 即当删除外缘时, 则得到的区域面积变小, FN 增大。从样本形式计算的指标来看, PM 的 MAE 最小, 这意味着 PM 的性能优于 FCN。总的来说, PM 的性能优于实验中用于对比的四种方法。




图 9 图 5(a) 第一个测试图像分别来自 FCN 和 PM 的 FP 和 FN

Fig. 9 FP, FN from the FCN and PM of the first sample in Fig. 5 (a)

3 结论

本文设计了一种基于机器视觉技术的太阳能电池背面电极分割算法。首先, 采用投影法和模板匹配法对电极进行粗、精定位, 减少了后处理的运行时间; 然后根据形状先验, 设计 3 个阈值, 生成 3 个二值边缘图。采用种子生长法得到目标边缘点。此外, 还采用了一种将边缘点转换为区域的方法。为了评价所提出算法的性能, 进行了实验, 与四种著名的算法在电极分割任务中的性能进行对比, 从实验结果看, 该算法总体上优于对比的四种算法。但该算法也存在一些不足, 比如区域轮廓不够光滑, 双边缘导致的 FN 增大, 导致分割结果不够准确。因此, 改进所提出的算法或寻找一种新的方法来解决上述问题将是笔者下一步的工作。

参考文献:

- [1] REBHI A, ABID S, FNAIECH F. Fabric defect detection using local homogeneity and morphological image processing [C]//2016 International Image Processing, Applications and Systems (IPAS), IEEE, 2016. [DOI: 10.1109/IPAS. 2016. 7880062]
- [2] BAI L, YANG X, GAO H. A novel coarse-fine method for ball grid array component positioning and defect inspection [J].

- IEEE Transactions on Industrial Electronics, 2018, 65(6): 5023–5031.
- [3] ZHANG X, SUN H, ZHOU Y, et al. A novel method for surface defect detection of photovoltaic module based on independent component analysis [J]. *Mathematical Problems in Engineering*, 2013, 2013(6): 147–160.
- [4] DHIMISH M, HOLMES V, MATHER P. Novel photovoltaic micro crack detection technique [J]. *IEEE Transactions on Device and Materials Reliability*, 2019, 19(2): 304–312.
- [5] WIN M, BUSHROA A R, HASSAN M A, et al. A contrast adjustment thresholding method for surface defect detection based on mesoscopy [J]. *IEEE Transactions on Industrial Informatics*, 2015, 11(3): 642–649.
- [6] OTSU N. A threshold selection method from gray-level histograms [J]. *IEEE Transactions on Systems Man & Cybernetics*, 2007, 9(1): 62–66.
- [7] MA R, DENG S, SUN H, et al. An algorithm for fabric defect detection based on adaptive canny operator [C]//2019 International Conference on Intelligent Computing, Automation and Systems (ICICAS), 2019: 475–481. [DOI: 10.1109/ICICAS48597.2019.00105]
- [8] CANNY J. A computational approach to edge detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986, 8(6): 679–698.
- [9] CHEN L C, KUO C C. Automatic TFT-LCD mura defect inspection using discrete cosine transform-based background filtering and ‘just noticeable difference’ quantification strategies [J]. *Measurement Science & Technology*, 2007, 19(1): 015507.
- [10] DORNAIKA F, MOUJAHID A, MERABET Y E, et al. Building detection from orthophotos using a machine learning approach: An empirical study on image segmentation and descriptors [J]. *Expert Systems with Applications*, 2016, 58(1): 130–142.
- [11] 张竞丹. 基于图的脑组织磁共振图像分割方法[J]. *中山大学学报(自然科学版)*, 2010, 49(2): 53–59.
- [12] 李震, 洪添胜, 王卫星, 等. 基于多元统计的柑桔图像分割和目标识别[J]. *中山大学学报(自然科学版)*, 2005, 44(2): 136–140.
- [13] FANG X, WU F, ZENG Z, et al. An image segmentation algorithm for LED bracket's detection [C]//2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2016: 1486–1490. [DOI: 10.1109/IMCEC.2016.7867463]
- [14] SUNDARA S M, AARTHI R. Segmentation and evaluation of white blood cells using segmentation algorithms [C]//2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI), 2019: 1143–1146.
- [15] CASELLES V, CATTÉ F, COLL T, et al. A geometric model for active contours in image processing [J]. *Numerische Mathematik*, 1993, 66(1): 1–31.
- [16] CHAN T F, VESE L A. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266–277.
- [17] CHEN Y F, YANG F S, SU E, et al. Automatic defect detection system based on deep convolutional neural networks [C]//2019 International Conference on Engineering, Science, and Industrial Applications (ICESI), 2019: 6–9. [DOI: 10.1109/ICESI.2019.8863029]
- [18] DONG X, TAYLOR C J, COOTES T F. Small defect detection using convolutional neural network features and random forests [C]//2018 European Conference on Computer Vision Workshops, 2018: 398–412.
- [19] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640–651.
- [20] YIN P, YUAN R, CHENG Y, et al. Deep guidance network for biomedical image segmentation [J]. *IEEE Access*, 2020, 8: 116106–116116.
- [21] GOYAL M, OAKLEY A, BANSAL P, et al. Skin lesion segmentation in dermoscopic images with ensemble deep learning methods [J]. *IEEE Access*, 2020, 8: 4171–4181.

(责任编辑 冯兆永)