

基于深度学习算法的车辆外观瑕疵智能检测方法

董荣对¹ 陈明惠² 陈春飞³ 吴善岳⁴

(1 苍南县圆通机动车检测有限公司 浙江 温州 325800; 2 杭州宜捷机动车检测有限公司 浙江 杭州 311103;
3 乐清市宁康西路机动车检测有限公司 浙江 温州 325600; 4 玉环通达机动车辆综合性能检测站 浙江 台州 317605)

摘要: 常规的车辆外观瑕疵智能检测矩阵一般设定为单向, 检测区域受到限制, 导致最终的误检率增加, 为此提出基于深度学习算法的车辆外观瑕疵智能检测方法的设计与分析。根据实际的测定需求及标准, 进行外观瑕疵特征提取, 采用多方向的形式, 构建智能检测矩阵, 打破传统检测方式对检测范围的限制。以此为基础, 构建深度学习测算瑕疵智能检测模型, 采用二值化深度修正方法实现智能检测。测试结果表明: 本次设计的深度学习算法车辆外观瑕疵智能检测组最终获取的车辆瑕疵误检率较好地控制在 30% 以下, 表明瑕疵检测方法的针对性更强, 检测误差可控, 具有实际的应用价值。

关键词: 深度学习算法; 车辆外观; 瑕疵标定; 智能检测; 检测方法; 瑕疵识别

0 引言

汽车外观瑕疵检测实际上是一项十分复杂且繁琐的工作, 在实际执行的过程中, 存在较强的针对性与定向控制性, 所以, 通常对于不同的车型和品牌, 都会设计对应的外观瑕疵智能检测方法。参考文献 [1] 和文献 [2], 设定传统机器视觉车辆外观瑕疵智能检测方法、传统背景差分车辆外观瑕疵智能检测方法^[1,2], 这一类基础的检测方式虽然可以完成预期的检测任务, 但是在复杂的背景环境下, 仍然存在一定的问题, 举例来说: 识别检测范围受限制、感应搭接不灵敏、瑕疵定位不精准等^[3]。不仅如此, 传统检测方法的针对性与稳定性相对较低, 对于瑕疵的识别速度较慢、智能化程度不高, 一定程度上会影响日常的表征处理工作进度, 对后期的车辆检测修复造成阻碍^[4]。

为此提出基于深度学习算法的车辆外观瑕疵智能检测方法的设计与分析。所谓深度学习算法, 实际上指的是一种动态化的核算方式, 通过数据信息内在的规律和表示层次获取最终的计算目标^[5]。将其融合在汽车外观瑕疵的智能化检测工作中, 能够进一步加强检测工作中出现的误差, 缩短整体的处理时间, 逐步形成更为灵活、具体、多元化的智能瑕疵检测结构, 通过智能技术强化检测效果, 为后续相关技术及行业的发展奠定基础。

1 设计车辆外观瑕疵深度学习核算智能检测方法

1.1 外观瑕疵特征提取

不同类型的车辆, 表现在遭受到刚蹭之后, 均会形成不同程度的瑕疵, 影响车辆的视觉外观。为此, 针对瑕疵的种类, 提取对应的特征^[6]。首先, 需要在车辆上设定一定数量的基础检测节点, 通过特定的格式进行搭接, 形成循环性的智能化检测网^[7]。以此为基础, 采用纹理分析和模式识别的方式先对瑕疵位置作出模糊标定, 并将凹痕和划痕各自区分, 具体如图 1 所示。

根据图 1 完成对车辆瑕疵种类的分析 and 研究。按车辆瑕疵的种类, 对各种划痕、纹路进行特征总结。通常情况下, 纹理性质的瑕疵复杂度低, 但是范围覆盖范围较大, 对于车辆外观的影响较小。但是划痕类的瑕疵同时具有旋转不变性和灰度不变性等特征, 深度较大, 对于车辆本体的影响也更大一些。综合上述提取的特征, 结合基础性的检测数据, 进行检测二值化标准值的测算, 如公式 (1) 所示:

$$D = \sum_{i=1}^n \eta_i - \frac{\eta t + \frac{\zeta}{2}}{(1-t) \times \sigma^2} + (\sigma - t)^2 \quad (1)$$

式中: D — 二值化标准值;
 η — 检测范围;

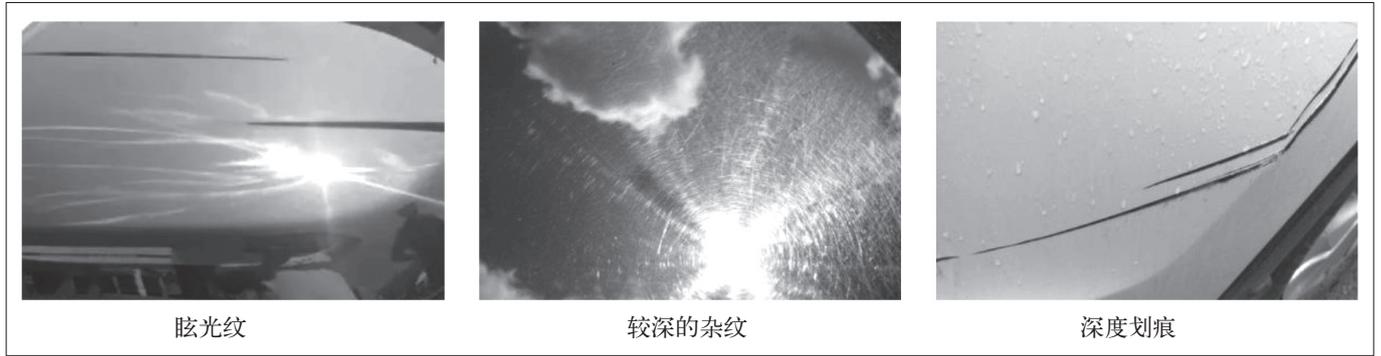


图1 车辆瑕疵种类分析图示

- i - 检测次数;
- t - 定向单元值;
- σ - 灰度值;
- ς - 预设检测总范围。

综合上述测定,完成对检测二值化标准值的测算,作为检测工作的初始标准,为后续工作的执行奠定基础。

1.2 构建多方向智能检测矩阵

与传统的智能检测矩阵不同的是,多方向处理矩阵的检测针对性较强,对于车辆内部的瑕疵识别精度更高,识别速度也更快。先利用识别系统对车体进行感应识别,形成虚拟的检测图像,将其转换为灰度图,依据实际的检测需求及标准,调整具体的指标参数,如表1所示。

表1 虚拟检测图像指标参数设定表

图像指标	初始设定标准	可控边缘标准
检测权重	11.35	10.25 ~ 16.25
输出点常值	+0.035	-0.001 ~ +0.047
检测定位时间 /s	0.21	0.14 ~ 0.23

根据表1完成对虚拟检测图像指标参数的设定。以此为基础,调整检测灰度图的整体状态,导致标定出车辆瑕疵的模糊位置。与检测节点进行搭接处理,形成实时可控程序,进行LBP值的测算,如公式(2)所示:

$$LBP = \sum_{y=1}^7 d(n_1 + g) \times^2 n_2 y$$

$$d(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

- 式中: $d(x)$ - 检测可控范围设定;
- d - 检测单元值;
- n_1 - 定向识别范围;

- n_2 - 预设识别范围;
- g - 堆叠看可控检测区域;
- y - 检测次数。

根据上述测算得出的LBP值,调整矩阵的检测状态,强化矩阵的检测能力。

1.3 构建深度学习测算瑕疵智能检测模型

基于深度学习算法,所构建的车辆瑕疵智能检测模型的覆盖范围相对较大,针对性更强,更符合实际的检测处理需求。根据提取的瑕疵特征,获取实时的检测图像,综合对应的检测任务,在车辆对应的位置上标定出瑕疵的位置。与此同时,融合Harr结构和深度学习算法,测定核算出灰度化偏差,如公式(3)所示:

$$L = \varpi - \int \frac{F - \frac{1}{\varpi}}{0.2F + (\Re r \times v)^2} \times r \varpi^2 \quad (3)$$

- 式中: L - 灰度化偏差;
- ϖ - 实时二值化标准值;
- F - 预设检测区域;
- \Re - Harr特征转换值;
- r - 转换次数;
- v - 识别堆叠区域。

综合测定得出的灰度化偏差作为检测标准设定在基础模型之中。在此基础之上,利用深度学习算法的辅助,对车辆各个部位的瑕疵进行二次标定,再次对检测图像灰度化处理,促使瑕疵位置和普通区域形成明暗对比,实现基础性检测处理。

1.4 二值化深度修正实现智能检测

所谓二值化深度修正,是对模型检测之后的一种二次异常定位检修。依据车辆自身的背景与纹理特征,构建二值化的检测环境,并对获取的原始检测图像再次处理。具体如图2所示。

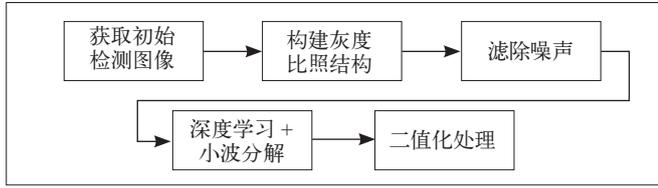


图2 二值化深度修正结构图示

根据图2完成对二值化深度修正结构的设计。依据图中流程，首先是灰度映射操作，使瑕疵和周围区域形成对比，随后，采用噪声滤除的方法，降低周围因素对检测的影响，综合深度学习算法，测定出瑕疵的分析波，完成小波分解，获取信息分量，最终通过二值化定向修正，对获取的检测结果比照研究，完成最终的智能化检测。

2 方法测试

此次主要是基于深度学习算法的车辆外观瑕疵智能检测方法的实际应用效果进行分析与研究。考虑到最终测试结果的真实性与可靠性，选定6辆车作为测定的主要目标对象，采用对比的方式展开分析，参考文献设定传统机器视觉车辆外观瑕疵智能检测组、传统背景差分车辆外观瑕疵智能检测组及本次设计的深度学习算法车辆外观瑕疵智能检测组。根据实际的测定需求及标准，对最终获取的测试结果比照验证，接下来进行具体测试环境的搭建。

2.1 测试准备

根据上述设计的车辆外观瑕疵智能化检测方法，综合深度学习算法，进行测试环境的搭建。先针对选定的6辆车进行虚拟性识别，获取对应的车辆数据和图像，并将其通过对应的格式转换为数据包，传输至相对的系统内部。根据布设的检测节点，采集瑕疵的相关数据信息。选定6个点位作为测定的核心节点，并进行基础测试指标的设定，如表2所示。

根据表2完成对基础测试指标参数的调整与设定。以此为基础，标定出车辆瑕疵的模糊位置。将部署的节点搭接关联，形成稳定的循环检测程序，便于后期测定数据信息的采集传输。需要注意的是，针对选定的6辆车，必须使用同一个系统进行检测处理，最大程度避免出现大范围的检测误差，影响后续检测工作的执行。

2.2 测试过程及结果分析

根据以上搭建的测试环境，采用深度学习算法，

表2 基础测试指标设定表

检测指标	基础参数	可用参数
单元检测比	1.03	1.16
最小检测率/%	70.25	82.11
检测配对偏差	1.12	1.01
标定检测位置/个	16	16
检测输入定向值	20.15	22.37

对车辆外观瑕疵智能化检测方法进行具体测试验证。可以先利用布设的节点采集实时数据信息。综合车辆外观的状态，模糊标定出瑕疵的位置。此时，将获取的检测图像调整为灰度图像，调整范围内的最小检测率，并修正两个节点之间的检测配对偏差标准，二次标定检测的位置，针对瑕疵位置和普通位置进行对比，进一步缩短瑕疵所在的区域。利用设计的模型和深度学习算法，测定出车辆外观瑕疵的误检率，如公式(4)所示：

$$D = l - (\psi + \sum_{r=1}^r l r \times \rho)^2 \times \frac{(1-z) \times r^2}{\psi \rho} \quad (4)$$

式中： D —车辆外观瑕疵误检率；

l —定向检测范围；

ψ —可识别检测区域；

r —检测次数；

ρ —单向输入值；

z —堆叠区域。

根据以上测算，完成对测试结果的分析，如图3所示。

根据图3完成对测试结果的分析与研究：对比于传统的机器视觉车辆外观瑕疵智能检测组、传统背景差分车辆外观瑕疵智能检测组，本次设计的深度学习算法车辆外观瑕疵智能检测组最终获取的车辆瑕疵误检率较好地控制在30%以下，表明瑕疵检测方法的针对性更强，检测误差可控，具有实际的应用价值。

3 结语

综上所述，便是基于深度学习算法的车辆外观瑕疵智能检测方法的设计与分析。对比于传统的车辆瑕疵检测模式，此次融合深度学习算法，所设计的检测结构更为多变、完整，针对复杂的识别环境，仍然可以确保预设的检测精准度。此外，基于深度学习算法的车辆外观瑕疵智能检测方法的应用一定程度上可以

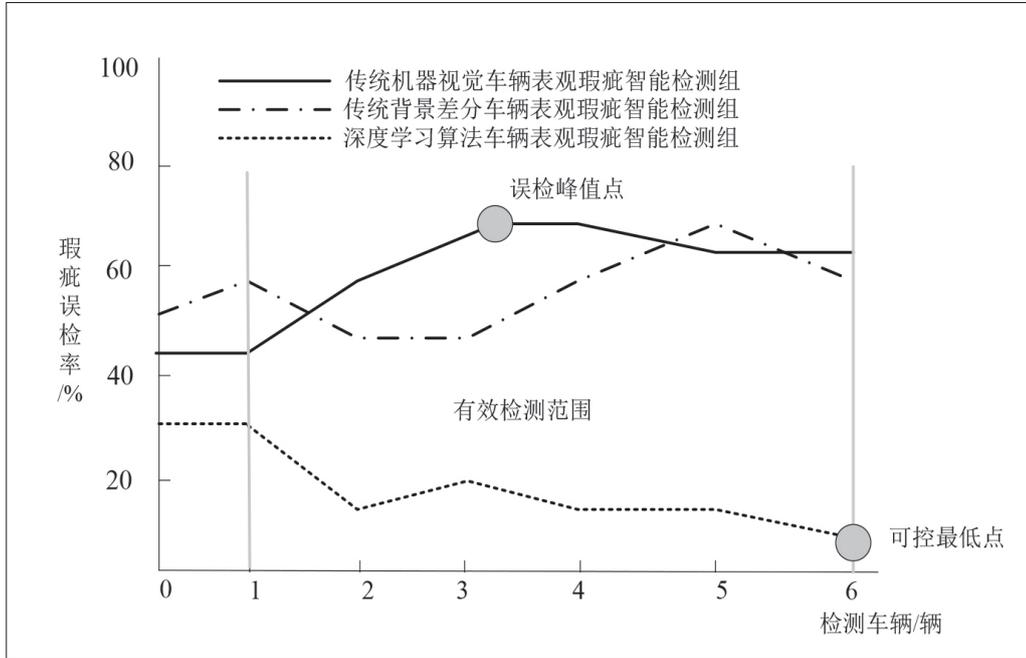


图3 测试结果对比分析图示

合理扩大检测范围，缩短检测的时长，更好地标定出瑕疵的具体位置，便于后期的维护和修补，推动瑕疵检测技术迈入一个新的发展台阶。

参考文献:

[1] 张魏魏. 基于机器视觉的航天装备元器件瑕疵检测系统

研究[J]. 电子技术与软件工程, 2022(11):164-167.

[2] 郭林, 周倩, 汤唯业. 基于背景差分的汽车漆面瑕疵视觉检测算法[J]. 信息与电脑(理论版), 2020, 32(04):47-49.

[3] 王焱潇, 王梦怡, 郭佳怡, 等. 基于机器视觉的工程机械配件表面瑕疵检测[J]. 湖州师范学院学报, 2021, 43(08):40-45.

[4] 陈亮, 张浩舟, 燕浩. 基于深度学习算法的尿素泵体用铝型材表面瑕疵检测[J]. 流体机械, 2020, 48(08):47-52+77.

[5] 肖禹辰, 张键. 基于机器视觉的稳健汽车外观瑕疵检测方法研究[J]. 信息与电脑(理论版), 2020, 32(15):59-62.

[6] 吴志新, 聂留阳, 董容君, 等. 基于深度学习的机场道面外观缺陷检测[J]. 电子技术与软件工程, 2021(08):174-177.

[7] 朱宗洪, 李春贵, 李炜, 等. 改进Faster R-CNN模型的汽车喷油器阀座瑕疵检测算法[J]. 广西科技大学学报, 2020, 31(01):1-10.

