

基于深度学习 SSD 算法的公路隧道 衬砌细小裂缝识别

金 虎, 申玉生, 方 勇, 于 丽, 周佳媚

(西南交通大学 土木工程学院, 成都 610031)

摘 要: 受公路隧道内照明条件变化、图像畸变等因素影响, 衬砌裂缝图像中不同尺度特征的提取难度增加, 影响了公路隧道衬砌细小裂缝的识别效果, 因此本文提出一种基于深度学习 SSD 算法的公路隧道衬砌细小裂缝识别方法。首先, 采用加权平均法对公路隧道图像进行灰度化处理, 通过线段检测算法提取图像中的线段特征, 利用 Sobel 算子获取图像在水平与垂直方向上的边缘检测结果, 基于透视几何原理对畸变图像进行校正; 其次, 引入深度学习 SSD 算法, 利用回归模型调整 SSD 算法先验框的位置, 并对有效特征层上的每个先验框进行类别预测, 结合非极大值抑制技术, 筛选出最优的预测框, 从而实现裂缝的精确识别。实验结果证明: 本文方法识别的衬砌裂缝与隧道图像中裂缝基本吻合, AUC 值为 0.956, 可有效提高公路隧道衬砌细小裂缝识别精度, 应用性能更好。

关键词: 深度学习 SSD 算法; 公路隧道; 衬砌细小裂缝; 识别

中图分类号: TP309 **文献标志码:** A **文章编号:** 1671-5497(2025)11-3653-07

DOI: 10.13229/j.cnki.jdxbgxb.20240845

Identification of small cracks in highway tunnel lining based on deep learning SSD algorithm

JIN Hu, SHEN Yu-sheng, FANG Yong, YU Li, ZHOU Jia-mei

(School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Affected by factors such as changes in lighting conditions and image distortion in highway tunnels, the difficulty of extracting features at different scales from lining crack images has increased, which has affected the recognition of small cracks in highway tunnel lining. Therefore, a method for identifying of small cracks in highway tunnel lining based on deep learning SSD algorithm is proposed in this paper. Firstly, using the weighted average method to perform grayscale processing on highway tunnel images, extracting line segment features from the images through line segment detection algorithms, obtaining edge detection results of the image in both horizontal and vertical directions using Sobel operators, and correcting distorted images based on perspective geometry principles; secondly, introducing deep learning SSD algorithm, using regression model to adjust the position of prior boxes in SSD

收稿日期: 2024-07-26.

基金项目: 国家自然科学基金面上项目(52278414)。

作者简介: 金虎(1974-), 男, 讲师, 博士。研究方向: 隧道及地下工程。E-mail: jinhulover@163.com

通信作者: 申玉生(1976-), 男, 教授, 博士。研究方向: 隧道及地下工程。E-mail: shenyusheng2024@163.com

algorithm, and predicting the category of each prior box on the effective feature layer, combining non maximum suppression technology, the optimal prediction box is selected to achieve accurate identification of cracks. Experimental results show that the lining cracks identification by this method are basically consistent with the cracks in tunnel images, with an AUC value of 0.956, which can effectively improve the accuracy of identifying small cracks in highway tunnel lining and have better application performance.

Key words: deep learning SSD algorithm; highway tunnel; small cracks in the lining; identificat

0 引言

随着交通基础设施的快速发展,公路隧道作为连接山川湖海的重要通道,其结构安全性和耐久性日益受到关注^[1]。隧道衬砌作为隧道的保护壳,其健康状况直接关系到隧道整体的安全性和通行能力。然而,在隧道长期运营过程中,隧道衬砌受到地质条件、环境因素等多种因素的影响,尤其在工程实施期间,细微的裂缝等病害容易显现。若未能及时识别并采取修复措施,则可能对工程结构及其效能产生不良影响,严重情况下甚至可能威胁隧道的正常安全运营^[2]。

目前,公路隧道衬砌细小裂缝识别方法多种多样,主要包括传统的人工检测、地质雷达探测等方法^[3]。其中,人工检测法虽然应用比较广泛,但是存在主观性强、效率低等问题。为了解决上述方法存在的不足,众多专家利用人工智能技术,对公路隧道衬砌细小裂缝识别方法展开了研究^[4]。例如,任松等^[5]采用自主研发的隧道智能快车采集隧道衬砌图像,组建数据集,同时引入深度学习进行公路隧道衬砌病害识别。但是该方法过度依赖图像处理技术和机器学习算法,在复杂多变的隧道环境中往往难以达到高精度的识别效果,尤其是在图像采集过程中,当隧道内光线比较昏暗或者纹理比较复杂采集的图像质量比较低,影响后续识别结果的准确性。王野等^[6]构建二维相场分析模型,通过模型实现裂缝识别,但实际应用中难以精确获取参数和边界条件,导致模型预测结果与实际存在偏差,进而影响识别性能。尹冠生等^[7]将图像划分为多个区域块,根据区域块将图像划分为目标背景区和目标病害区,然后通过特征提取、阈值分割及二值化处理实现裂缝识别。该方法在复杂环境下可能无法有效保留图像的关键信息,导致综合识别性能较差。张振海等^[8]结合 Canny 边缘检测和 Otsu 方法,对滤波后的图像进行分割处理,删除噪声点并获取裂缝完

整区域的二值图像;同时结合裂缝骨架图,对裂缝的长度、宽度和面积进行计算,最终达到裂缝识别的目的。尽管进行了滤波处理,但图像中仍可能残留一些难以完全去除的噪声点,这些噪声点在边缘检测过程中可能会被误判为裂缝边缘,影响后续的裂缝识别。

单阶段多框检测器(Single shot multibox detector, SSD)算法是一种基于深度学习的目标检测算法,可通过多框检测方法在不同尺度的特征图上进行检测,能有效识别不同尺寸的裂缝。为此,本文基于深度学习 SSD 算法,对公路隧道衬砌细小裂缝识别方法展开研究。

1 公路隧道衬砌细小裂缝识别

2.1 公路隧道图像预处理

裂缝在图像中主要表现为亮度或暗度的变化,而非颜色的变化。彩色图像中的颜色信息可能引入不必要的干扰,如隧道内照明条件的变化、隧道壁面的颜色差异等,这些干扰因素可能影响裂缝识别的准确性^[9,10]。而灰度图像去除了颜色信息的干扰,使得裂缝识别更加准确可靠。加权平均法可以通过给 RGB 3 个颜色分量分配不同的权重,然后加权求和得到灰度值。因此,本文采用加权平均法对公路隧道图像进行灰度化处理,具体的计算公式为:

$$\theta_{gray}(i, j) = 0.299 \times R(i, j) + 0.587 \times G(i, j) + 0.144 \times B(i, j) \quad (1)$$

式中: $\theta_{gray}(i, j)$ 为公路隧道图像的像素灰度值; $R(i, j)$ 、 $G(i, j)$ 和 $B(i, j)$ 为彩色图像像素的分量值。

1.2 Sobel算子边缘检测

预处理步骤能够为后续的裂缝识别提供更好的输入图像。边缘是图像中像素值发生剧烈变化的区域,通常对应物体的轮廓或不同区域的边界。图像边缘是图像中区域属性发生显著变化的界

限,分隔了具有不同灰度值的区域,尤其在检测图像中的凹槽线段等细节显得尤为重要。传统的边缘检测方法可能仅关注单一方向的边缘变化,而公路隧道图像中的裂缝可能沿多个方向延伸。Sobel算子是一种基于图像灰度值变化的微分算子,通过计算图像中各像素点的梯度来检测边缘。因此,本文采用Sobel算子分别在水平和垂直两个方向进行卷积处理,以获取图像在这两个方向上的边缘检测结果。卷积运算的计算公式为:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2)$$

$$G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (3)$$

式中: G_x 和 G_y 分别为 x 方向和 y 方向的卷积,经过卷积处理,可以获取两个方向的图像增强结果。

完成上述操作后,首先计算像素灰度值,并进行排序。其次,设定梯度阈值,选取梯度值较高且相等的像素点作为直线段的候选。再次,在候选区域内,通过拟合矩形定义候选线段,其中线段方向由矩形的主轴确定。最后,利用Contrario理论和Helmholtz原理进行验证,选择偏差较小的点作为对齐点,并基于二项分布模型计算每个对齐点对应的对齐概率。这一过程筛选出图像中与裂缝匹配的准确线段,为后续图像分析和处理提供基础。根据上述分析,可以获取:

$$\begin{cases} E(s) = (N)^{\frac{2}{5}} \cdot C(m(s), k(s), q) \\ C(n, k, q) = \sum_{i=k}^n \binom{n}{i} q^i (1-q)^{n-i} \end{cases} \quad (4)$$

式中: N 为公路隧道图像的分辨率大小; $(N)^{\frac{2}{5}}$ 为矩形数量; E 为虚警率; s 为矩形; q 为像素点属于对齐点的概率; n 为直线区域内像素点的总数; C 为二项概率分布; ρ 为阈值; k 为对齐点数量;当 $E < \rho$ 时,说明直线区域有效,可以将其看作独立线段进行处理。

线段检测算法能识别图像中的多条线段特征,尤其在包含线性凹槽的区域,可能检测到多个线段,这些线段在长度、斜率等参数上各不相同。为了有效分析和处理这些线段特征,首先采用线段聚类方法对数量最多的线段集合进行聚类;其次,利用最小二乘法对聚类后的线段进行拟合,得

到两条最能代表其整体走向的直线;最后通过计算两条直线的交点确定消失点的位置。在聚类过程中,通过聚类算法对检测到的所有线段进行遍历处理,计算线段间的距离 h_1 和夹角 α_1 ,并将已处理的线段集合排除在后续遍历之外,直至没有新的线段参与遍历,聚类过程终止。完成遍历后,对线段数量最多的两个集合进行计算,将拟合得到的两条直线的交点作为最终的消失点。

1.3 公路隧道图像畸变校正

根据消失点可以确定图像中的关键区域,从而使裂缝识别过程重点关注这些区域。但是,隧道表面可能存在的粗糙度、安装物(如灯管、牵引线等)的光洁度差异,以及隧道内的光线条件等,都可能对图像采集产生影响,间接导致图像畸变。因此,需要对公路隧道图像的畸变进行校正。具体操作步骤如下。

(1) 恢复平行直线

给定两条直线,记作 (l_1, l_2) 和 (m_1, m_2) ,它们在物理空间中原本平行。然而,在图像表示中,由于透视效果,在视觉上表现为交汇于两点,这两点在数学上被视为位于无穷远处的交汇点,通常被称为消失点,分别标记为 r_1 和 r_2 。两点的连线构成消失线 l 。为了确保物理空间的平行性在图像上得到合理描述,需要构建如式(5)所示的变换矩阵 B_1 :

$$B_1 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ l_1 & l_2 & l_3 \end{bmatrix} \quad (5)$$

(2) 垂线对齐

调整公路隧道图像中的垂线与 y 轴平行,实质是对矩阵 B_1 进行旋转操作,以确保图像中原本平行的直线在变换后仍然保持平行状态。在确定消失点坐标 (u_x, u_y) 后,依据垂直方向的消失点特性可构建如式(6)所示的消失点矩阵 U :

$$U = [u_x, u_y, 0]^T \quad (6)$$

将 y 轴的向量表示为 $[0, 1, 0]^T$,进而可得如式(7)所示的旋转角 τ :

$$\tau = \cos^{-1} \left(\frac{u_y}{\sqrt{u_x^2 + u_y^2}} \right) \quad (7)$$

结合式(7)得到的旋转角,构建旋转矩阵 S ,如式(8)所示:

$$S = \begin{bmatrix} \cos \tau & -\sin \tau & 0 \\ \sin \tau & \cos \tau & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (8)$$

采用式(6)(8)构建公路隧道图像畸变校正矩阵 W , 通过校正矩阵实现畸变校正, 具体如式(9)所示:

$$W = B_1 S \quad (9)$$

1.4 基于深度学习 SSD 算法的细小裂缝识别

SSD 算法采用多层次特征提取机制, 从输入图像中生成多个不同尺度的特征层。其中, 部分特征层被选定为有效特征层, 用于后续的裂缝检测

处理。在每个有效特征层上, 算法将图像细分为多个不同大小的网格, 每个网格内预设一定数量的先验框, 作为潜在的裂缝候选区域。因此, 在完成公路隧道图像的畸变校正处理后, 将处理结果输入深度学习 SSD 算法框架中, 以执行公路隧道衬砌细小裂缝的识别任务。

利用回归模型对 SSD 算法先验框的位置进行精细调整, 通过分类预测, 算法可判断每个调整后的先验框内是否包含裂缝。最终, 结合非极大值抑制技术, 筛选出最优预测框, 从而完成裂缝的精确识别。SSD 的网络结构图如图 1 所示。




图 1 SSD 网络结构图

Fig. 1 SSD network structure diagram

(1) 有效特征层

在有效特征层中, 高度和宽度信息反映的是该层特征图相对于公路隧道图像的尺寸变化, 而非直接将原始图像划分为网格。以尺寸为 3×3 、通道数为 256 的有效特征层为例, 其表示在该层上, 图像信息被编码为 3×3 个局部区域, 如图 2 所示。每个网格都被视为潜在的检测区域, 其中包含预设的先验框, 用于对输入的公路隧道图像进行目标检测, 以识别和定位需要的检测目标。

(2) 先验框

在 SSD 算法的有效特征层上, 每个网格不仅是检测区域的基准位置, 其中心还作为先验框的基准点, 用于初步定位可能的目标区域。



图 2 公路隧道图像的网格划分

Fig. 2 Grid division of highway tunnel images

在 SSD 算法的处理流程中, 基础网络通过卷积、最大池化和 ReLU 层处理输入的尺寸为 $300 \times 300 \times 3$ 的公路隧道图像。利用 3×3 的卷积核和 2×2 的最大池化, 网络逐步减小特征图的尺寸并增加通道数, 生成多个中间特征层。完成预定池化操作后, 采用特定参数的 3×3 卷积(填充 6, 膨胀 6)和后续的 1×1 卷积调整通道数, 最终输出如 $19 \times 19 \times 512$ 的特征层。该层被视为有效特征层的一部分, 用于后续的目标检测, 包括位置和类别的预测。

随着特征层进一步传递至辅助网络阶段, 通过更多的卷积操作, 特征图的尺寸继续减小, 而通道数可能进一步增加, 以实现特征的深层次抽象和压缩。在辅助网络的末端会生成一个或多个尺寸特殊的特征层, 如长度和宽度均缩减至 1, 而通道数扩展至 256 的特征层, 这些特征层中的特定部分被定义为有效特征层, 用于最终的预测。

预测网络的核心在于执行回归预测和分类预测。其中, 回归预测旨在精确估算和调整预测框的位置信息; 而分类预测则负责判断预测框内是否包含目标, 并确定目标类别。在回归预测过程

中,系统会对有效特征层中定义的所有先验框进行卷积运算,以调整其位置和尺寸,从而得到最终的预测框。此外,对有效特征层执行通道数量为 $4 \times n_p$ 的卷积操作。其中, n_p 为有效特征层单一网格中含有的先验框数量。为了调整预测框的中心位置,需要计算中心坐标偏移量 x_0 和 y_0 ,同时将预测框的高度和宽度分别设定为 w 和 h ,因此卷积运算的通道数量设定为 $4 \times n_p$ 。

分类预测时,需对有效特征层上的每个先验框进行类别预测。因此,对得到的所有有效特征层执行通道数量为 $n_c \times n_p$ 的卷积操作,其中 n_c 为需要划分的类别数量。

结合上述分析,SSD 网络训练的具体结构示意图如图 3 所示。

完成 SSD 网络训练后,即可开展公路隧道衬砌细小裂缝识别。首先,对需要识别的公路隧道图像进行预处理,将图像尺寸调整为 300×300 ,以确保其满足网络输入的要求。其次,将预处理后的图像输入 SSD 网络执行裂缝识别,获取网络输出的预测框信息。再次,选取置信度最高的 200 个预测边界框,并对它们进行置信度评估。系统会对这 200 个边界框进行全面遍历,逐一检查它们的置信度是否满足预设的最小置信度阈值。若所有边界框的置信度均未达到此标准,则系统直接终止后续处理流程,输出原始图像,不进行裂缝的识别与标注。相反,若至少存在一个边界框的置信度高于最小置信度阈值,则系统将采用非极大值抑制技术,最终保留置信度最高的单一边框作为裂缝的准确位置。最后,系统根据最高置信度的边界框绘制并标注裂缝,得到最终的公路隧道衬砌细小裂缝识别结果 H_{xy} ,如式(10)所示:




图 3 SSD 网络训练示意图

Fig. 3 Schematic diagram of SSD network training

$$H_{xy} = \frac{(x_0, y_0) \times \{w \cdot h\} - n_c \times n_p}{loss + loss_1} \quad (10)$$

式中: $loss$ 和 $loss_1$ 分别为定位损失和置信度损失。

至此,基于深度学习 SSD 算法的公路隧道衬砌细小裂缝识别方法设计完成。

2 实验分析

2.1 实验设置

为了有效验证本文方法的有效性,以 Z 城市公路隧道为研究对象,对其衬砌细小裂缝进行识别。该隧道衬砌的实验数据集来源于隧道加固修复工程项目的监测和检测数据,由隧道工程公司在施工过程中收集,实验选取数据集中部分样本用于实验分析。实验环境如图 4 所示。

采用 Matlab 仿真平台展开实验测试,相关的实验参数设置如表 1 所示。



图 4 实验环境

Fig. 4 Experimental environment

表 1 实验参数设置

Table 1 Experimental parameter settings	
内 容	参数
学习率	0.01
批量大小	128
迭代次数/次	100
优化器	Adam
损失函数	0.80
权重值	1.0

2.2 图像畸变校正处理

考虑到公路隧道内环境复杂,拍摄图像常受光线不均、灰尘干扰及设备抖动影响,导致图像质量下降,裂缝等特征难以辨识。因此,采用本文所提方法进行畸变校正处理,实验结果如图 5 所示。

分析图 5 可知,采用本文方法完成畸变校正后,图像中物体形状得到有效恢复,更接近物体在真实世界的形态,有效恢复图像丢失的细节,使校正后的图像更加清晰且细腻,图像的整体画质显




图 5 测试样本和本文方法的公路隧道图像畸变校正结果分析

Fig. 5 Analysis of distortion correction results of highway tunnel images using test samples and the proposed method

著提升,为后续的公路隧道衬砌细小裂缝识别奠定了坚实的基础。

2.3 对比实验结果与分析

为了进一步验证本文方法的优越性,选择文献[7]的基于图像分块的识别方法和文献[8]的基于改进 Otsu 算法的识别方法作为对比方法,与本文方法共同进行实验。

2.3.1 裂缝识别对比

分别采用不同方法进行公路隧道衬砌细小裂缝识别,识别出的裂纹边缘越清晰、与背景界限越分明,表明该方法的裂纹识别效果较好。测试结果如图 6 所示。

分析图 6 可知,基于图像分块的识别方法与基于改进 Otsu 算法的识别方法虽然可以识别出较大的衬砌裂缝,但是对于较小的裂缝存在识别不清、边缘模糊的问题,识别效果较差;而本文方法识别出的衬砌裂缝与隧道图像中裂缝基本吻合,裂缝边缘清晰、与背景界限分明,无论裂缝大小均能有效识别,识别效果较好。由此可见,本文所提方法可以显著提升公路隧道衬砌细小裂缝的




图 6 不同方法的公路隧道衬砌细小裂缝识别结果比较

Fig. 6 Comparison of identification results of small cracks in highway tunnel lining using different methods

识别性能。

2.3.2 ROC 曲线

为对各识别方法的综合性能进行测试,将 ROC 曲线下的面积作为测试指标,以此验证公路隧道衬砌细小裂缝的识别效果。受试者工作特征曲线 (Receiver operating characteristic curve, ROC) 通过绘制不同阈值下的真正例率 (True positive rate, TPR) 和假正例率 (False positive rate, FPR) 展示模型性能,其取值范围介于 0 到 1 之间。AUC 即 ROC 曲线下的面积, AUC 值越大,表示模型的分类性能越好,对细小裂缝的识别准确度越高。测试结果如图 7 所示。




图 7 不同识别方法的 F1 值实验结果对比

Fig. 7 Comparison of F1 value experimental results of different recognition methods

由图 7 可以看出,基于图像分块识别方法的 AUC 值为 0.893,基于改进 Otsu 算法识别方法的 AUC 值为 0.865,而本文方法的 AUC 值为 0.956。本文方法的 AUC 面积更大且更接近 1,说明本文方法可有效提高公路隧道衬砌细小裂缝的识别精度,应用性能更好。

3 结束语

针对传统公路隧道衬砌细小裂缝识别方法存在的一系列不足,本文提出一种基于深度学习 SSD 算法的公路隧道衬砌细小裂缝识别方法。实验结果表明:本文方法具有良好的公路隧道图像畸变校正能力,且 AUC 值为 0.956,可获得高精度的公路隧道衬砌细小裂缝识别结果,为隧道的长期安全运营提供更坚实的技术支撑。

参考文献:

- [1] 许献磊,郑浩翔,刘昱昊. 基于改进链码追踪算法的隧道衬砌裂缝识别方法[J]. 现代隧道技术, 2022, 59(4): 90-99.
Xu Xian-lei, Zheng Hao-xiang, Liu Yu-hao. Identification method for cracks in tunnel linings based on improved chain code tracking algorithm[J]. Modern Tunnelling Technology, 2022, 59(4): 90-99.
- [2] 乔建刚,陶瑞,刘翔. 改进组件树在隧道裂缝识别中的应用[J]. 中国安全生产科学技术, 2022, 18(6): 105-110.
Qiao Jian-gang, Tao Rui, Liu Xiang. Application of improved component tree in tunnel crack identification [J]. Journal of Safety Science and Technology, 2022, 18(6): 105-110.
- [3] 王平让,黄宏伟,薛亚东. 基于图像结构信息的隧道衬砌裂缝实时快速识别[J]. 科学技术与工程, 2022, 22(29): 13075-13082.
Wang Ping-rang, Huang Hong-wei, Xue Ya-dong. Real-time fast recognition of tunnel lining cracks based on image structure information[J]. Science Technology and Engineering, 2022, 22(29): 13075-13082.
- [4] 王耀东,朱力强,余祖俊,等. 基于样本自动标注的隧道裂缝病害智能识别[J]. 西南交通大学学报, 2023, 58(5): 1001-1008.
Wang Yao-dong, Zhu Li-qiang, Yu Zu-jun, et al. Intelligent tunnel crack recognition based on automatic sample labeling[J]. Journal of Southwest Jiaotong University, 2023, 58(5): 1001-1008.
- [5] 任松,朱倩雯,涂歆玥,等. 基于深度学习的公路隧道衬砌病害识别方法[J]. 浙江大学学报:工学版, 2022, 56(1): 92-99.
Ren Song, Zhu Qian-wen, Tu Xin-yue, et al. Lining disease identification of highway tunnel based on deep learning[J]. Journal of Zhejiang University (Engineering Science), 2022, 56(1): 92-99.
- [6] 王野,李宏哲,那通兴. 基于相场法的沉管隧道结构损伤区识别[J]. 公路交通科技, 2022, 39(6): 111-118.
Wang Ye, Li Hong-zhe, Na Tong-xing. Identification of damage zone in immersed tunnel structure based on phase field method[J]. Journal of Highway and Transportation Research and Development, 2022, 39(6): 111-118.
- [7] 尹冠生,高建国,史明辉,等. 图像分块下的隧道裂缝识别方法[J]. 交通运输工程学报, 2022, 22(2): 148-159.
Yin Guan-sheng, Gao Jian-guo, Shi Ming-hui, et al. Tunnel crack recognition method under image block[J]. Journal of Traffic and Transportation Engineering, 2022, 22(2): 148-159.
- [8] 张振海,贾争满,季坤. 基于改进的 Otsu 法的地铁隧道裂缝识别方法研究[J]. 重庆交通大学学报:自然科学版, 2022, 41(1): 84-90.
Zhang Zhen-hai, Jia Zheng-man, Ji Kun. Crack identification method of subway tunnel based on improved otsu method[J]. Journal of Chongqing Jiaotong University (Natural Science), 2022, 41(1): 84-90.
- [9] 何静,谢国亚,霍雅洁,等. 气动光学效应图像自适应校正方法与仿真[J]. 计算机仿真, 2022, 39(8): 230-234.
He Jing, Xie Guo-ya, Huo Ya-jie, et al. Adaptive correction method and simulation of pneumatic optical effect images[J]. Computer Simulation, 2022, 39(8): 230-234.
- [10] 周丽,冯百明,关煜,等. 面向智能手机拍摄的变形文档图像校正[J]. 计算机工程与科学, 2022, 44(1): 102-109.
Zhou Li, Feng Bai-ming, Guan Yu, et al. Correcting distorted document images on smartphones[J]. Computer Engineering & Science, 2022, 44(1): 102-109.