

基于图像预处理和语义分割的电力巡检 机器人视觉导航方法

杨 权, 樊绍胜

(长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

摘 要: 由于光照和恶劣天气的影响, 传统图像处理方法用于巡检机器人视觉导航方面的识别效率不高, 为此, 提出一种基于图像预处理和语义分割的电力巡检机器人视觉导航方法。首先, 提出基于自适应伽马校正方法的图像增强方法, 解决强光、弱光和光照不均对图像的影响, 针对曝光情况采用 LSTM 预测模型自适应调整摄像头角度消除曝光, 提升图像良好曝光度; 然后, 采用改进 DenseNet 网络对导航路径进行语义分割, 提取路径目标区域, 通过目标区域像素值的分布拟合机器人的前进路线并计算出偏移量, 提供机器人调整行驶姿态的关键参数并利用模板匹配判断导航路径中的走向、定位与分叉标志。实验结果表明, 该算法能有效解决由光照和恶劣天气所导致的识别精度低的问题, 提高复杂环境下巡检机器人导航定位的精准度。

关 键 词: 巡检机器人; 视觉导航; 伽马校正; DenseNet

DOI: 10.19781/j.issn.1673-9140.2023.06.026 中图分类号: TP2; TM75 文章编号: 1673-9140(2023)06-0248-11

Visual navigation method for electric power inspection robot based on image preprocessing and semantic segmentation

YANG Quan, FAN Shaosheng

(School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: Due to the influence of lighting and harsh weather, the traditional image processing methods have low recognition efficiency in visual navigation of inspection robots. This paper proposes a visual navigation method for power inspection robots based on image preprocessing and semantic segmentation. An image enhancement method based on the adaptive gamma correction method is proposed to solve the influence of strong light, weak light and uneven illumination on the image. Aiming to the exposure conditions, the LSTM prediction model is used to adaptively adjust the camera angle to eliminate the exposure and improve the good exposure of the image. The improved DenseNet is used to semantically segment the navigation path and extract the path target area, fitting the robot's forward route through the pixel value distribution of the target area and calculate the offset, which provides the key parameters of robots to adjust the driving posture. Template matching is used to determine the direction, location and bifurcation signs in the navigation path. Experimental results show that the algorithm could effectively solve the problem of low recognition accuracy caused by lighting and adverse weather, and improve the accuracy of navigation and positioning of inspection robots in complex environments.

Keywords: inspection robot; visual navigation; gamma correction; DenseNet

收稿日期: 2021-12-25; 修回日期: 2022-04-14

基金项目: 国家自然科学基金(61573049)

通信作者: 樊绍胜(1966—), 男, 博士, 教授, 主要从事图像处理与电力机器人等研究; E-mail: fss508@163.com

为了保障正常供电,工作人员需要对户外变电站、升压站内的电力设施开展周期性巡检,以尽早发现安全隐患并排除运行故障。由于机器人巡检安全性高且节约人力,故逐渐取代人工巡检方式^[1-2]。机器人自动巡检的关键是导航定位技术,目前主流的机器人导航方法是磁轨、激光及视觉导航。磁轨导航原理简单且可靠,但是其导航线铺设复杂,更改或增减线路麻烦,磁轨在铺设后容易出现氧化腐蚀现象,可靠性降低^[3];激光导航具有使用方便、计算快速的优点,但其导航定位精度受强光反射和雾霾等因素的影响,而且一旦应用场景发生变化便可能出现严重偏差,此外,激光导航的硬件成本较高^[4-5];参考道路交通采用标线视觉识别进行巡检机器人导航是解决上述问题的有效方法,但标线受到光照和天气影响,导致复杂环境下标线分割准确率低、识别效果差^[6]。文献[7]采用霍夫变换对导航标线的信息进行提取,分割精度高但存在分割耗时的问题,不满足巡检机器人的实时性要求;文献[8]采用色调-饱和度-明度(hue-saturation-value, HSV)颜色通道特征提取和朴素贝叶斯法融合导航线区域的颜色和边缘特征,解决了阴影光斑对导航线的影响,但曝光严重情况下的分割准确率低。

随着神经网络的发展,语义分割准确率不断提高。在文献[9]提出经典的全卷积神经网络用于图像语义分割后,越来越多的研究者进行了网络改进。文献[10]中的U-Net网络和文献[11]中的SegNet网络均采用编码器-解码器结构提取图像的细节信息,保留最大的特征值,提高了分割精度;文献[12]中的PSPNet网络和文献[13]中的DeepLab网络提出金字塔池化模块,融合全文上下文信息,提高了预测的准确性。语义分割替代传统图像分割进行导航线识别可提高准确率。

本文提出基于图像预处理和语义分割的视觉导航方法,针对非曝光和曝光情况对导航路径识别的影响,提出基于自适应伽马校正的图像增强和基于摄像头角度调整的曝光抑制方法,采用改进的DenseNet进行图像语义分割,得到导航路径的偏移量,使用模板匹配识别导航路径中的走向与分叉标志,解决复杂环境下传统图像处理方法不能准确识

别导航路径的问题。

1 复杂环境导航路径图像预处理

为了提高识别准确性并获取更多的导航线信息,巡检机器人的摄像头可视距离应该尽可能大,满足机器人快速运行需求。参考常用车道线颜色,导航线颜色选择与背景对比度较大的黄色,但在强光条件下会带来远处图像曝光的问题,严重影响识别准确率,针对强光、弱光和光照不均影响,本文提出改进的伽马校正方法进行图像增强。针对曝光情况提出基于入射光源角度和强度的摄像头角度调整方法以消除曝光。

1.1 基于自适应伽马校正的图像增强方法

在导航线识别过程中,由于白天自然光强度变化,以及夜晚设备照明灯、远处干扰灯光等光源的不均匀照射,使得导航线同时受光照角度和强度的干扰,如图1所示。

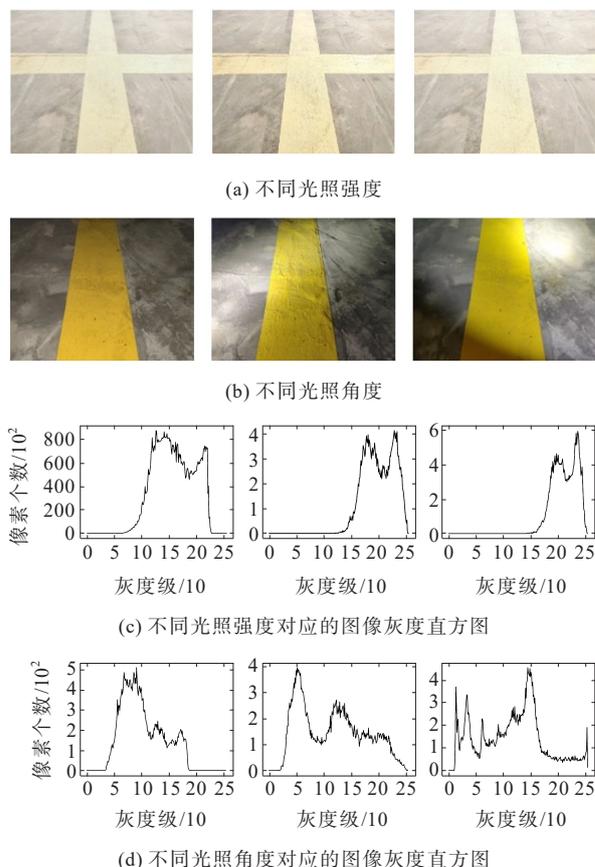


图1 不同光照干扰下的导航线图像及其灰度直方图

Figure 1 Navigation line images and corresponding grayscale histogram under different illumination interference

由图1(c)、(d)可以看出,直方图能直观地反映,光照强度变化时图像灰度值分布会发生整体均匀变化;光照角度变化时图像灰度值分布会发生不均匀变化。

根据生物特征,人眼对光线的感知跟光强呈非线性关系,而摄像头对光的识别跟光强呈线性关系^[14]。为了让图像更符合人眼观察特征,对摄像头采集的图像进行伽马校正,其原理是对图像中的像素值进行乘积运算,假设某个像素点处理前、后的归一化像素值分别为 r 、 s ,伽马校正因子为 γ ,则

$$s = cr^\gamma, r \in [0, 1] \quad (1)$$

其中, $\gamma < 1$ 时灰度值减小,图像整体变暗; $\gamma > 1$ 时灰度值增大,图像整体变亮;若 γ 的取值不变,则无法适用于所有光照条件,而且对光照不均图像的增强效果不佳。

导航线图像受光照影响主要体现在灰度均值方面,参考图像卷积和滤波原理,本文提出基于动态伽马因子的伽马校正方法。通过选取合适大小的卷积核对输入图像灰度图的像素点进行对应的相乘求和,得到像素点的局部灰度均值,代入 γ 因子的拟合函数确定伽马因子,对像素点进行伽马校正实现动态调节。

本文对像素灰度值和最佳伽马因子的数据集进行拟合,根据最小均方误差选定基于最小绝对残差的高斯函数为拟合函数,假设坐标为 (x, y) 的像素点局部灰度均值为 m ,局部均值函数和 γ 因子的拟合函数分别为

$$m = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N f(i, j) k(i, j) \quad (2)$$

$$\gamma(x, y) = a \cdot e^{-(m-b)/c\gamma} \quad (3)$$

式中, N^2 为卷积核大小; $f(i, j)$ 、 $k(i, j)$ 分别为输入图像和卷积核中第 i 行 j 列的像素点灰度值、卷积核因子; $a=16.85$ 、 $b=-356.1$ 、 $c=283.8$ 。

本文选取 7×7 卷积核的效果最佳,自适应伽马校正原理如图2所示;不同光照条件下图像对比度明显增加,处理前、后对比如图3所示;当图像出现严重曝光情况时,图像顶端像素与背景融为一体,其灰度值均为255,自适应伽马校正方法无法解决曝光对图像灰度值的影响,如图4所示。



图2 自适应伽马校正处理过程

Figure 2 Adaptive gamma correction process

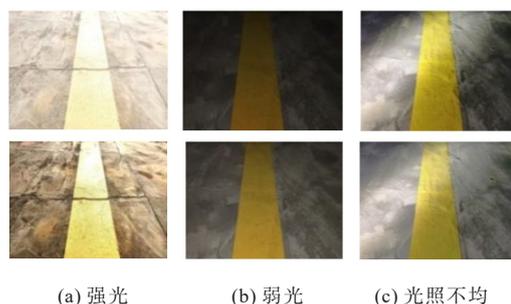


图3 不同光照条件下自适应伽马校正前、后对比

Figure 3 Comparison before and after adaptive gamma correction under different lighting conditions

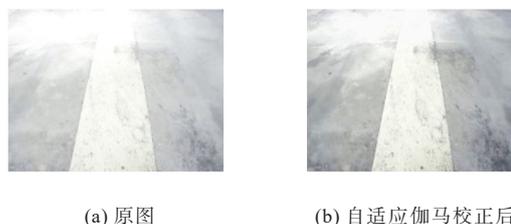


图4 曝光条件下自适应伽马校正前、后对比

Figure 4 Comparison of adaptive gamma correction before and after exposure conditions

1.2 基于摄像头角度调整的曝光抑制方法

在曝光情况下,自适应伽马校正方法无法适用,本文通过摄像头调整抑制曝光现象。当光照射在导航线上时,大部分光线通过反射被摄像头捕获,得到导航线图像,反射光的波长和强度直接影响导航线图像的色彩和亮度。根据Retinex理论,物体的颜色由物体对不同波长光线的不同反射作用形成^[15],其原理如图5所示。观察所得图像包含入射光线经过反射物体表面形成的漫反射和镜面反射,当镜面反射光线过高尤其是 $\alpha = \beta$ 时,会产生局部高光现象甚至导致图像曝光。

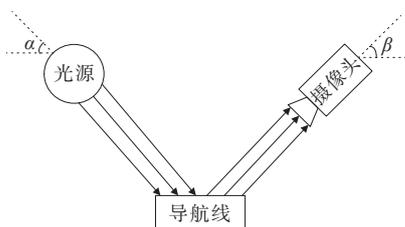


图5 导航线光照示意

Figure 5 Navigation line illumination diagram

图像 S 由 4 个因素决定,即入射光强度 L 、入射光角度 α 、导航线的反射率以及摄像头角度 β ,其中,由于导航线统一使用黄色热熔标线材料铺设,反射率可视为常数。入射光强度和角度非人为控制因素,不同摄像头角度得到的图像曝光情况不同。由于光照的复杂性,难以得到光照和最佳摄像头角度的非线性映射关系。考虑光照变化与时间有关,本文采用具有长时记忆功能的长短时记忆(long short-term memory, LSTM)神经网络,计算时间序列中不同特征值的依赖性,建立基于入射光强度和入射光角度的最佳摄像头角度的预测模型。

LSTM 神经网络由 4 层网络组成,即遗忘门、输入门、更新和输出层^[16],如图 6 所示, h_{t-1} 、 h_t 分别表示上一时刻和当前输出, x_t 表示当前输入, C_{t-1} 、 C_t 分别表示上一时刻和当前单元状态。

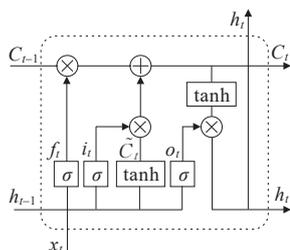


图6 LSTM网络结构

Figure 6 LSTM network structure

1) 遗忘门层。 h_{t-1} 、 x_t 经过 Sigmoid 函数(σ)作用后舍弃 C_{t-1} 中的部分信息。

$$f_t = \sigma(\mathbf{W}_f[h_{t-1}, x_t] + \mathbf{b}_f) \quad (4)$$

2) 输入门层。 h_{t-1} 、 x_t 经过 Sigmoid 和 tanh 函数共同作用后选择需要传入的信息。

$$i_t = \sigma(\mathbf{W}_i[h_{t-1}, x_t] + \mathbf{b}_i) \quad (5)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c[h_{t-1}, x_t] + \mathbf{b}_c) \quad (6)$$

3) 更新层。更新 C_t 传至下一模块,选择需要舍弃和增减的信息。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (7)$$

4) 输出门层。 h_{t-1} 、 x_t 经过 Sigmoid 函数作用后使用 tanh 函数和 o_t 选择输出的信息。

$$o_t = \sigma(\mathbf{W}_o[h_{t-1}, x_t] + \mathbf{b}_o) \quad (8)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (9)$$

$$y_t = \sigma(\mathbf{W}_y h_t + \mathbf{b}_y) \quad (10)$$

式(4)~(6)、(8)、(10)中, \mathbf{W} 表示权重矩阵, \mathbf{b} 表示偏置。Sigmoid 和 tanh 函数的表达式分别为

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (11)$$

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (12)$$

针对最佳摄像头角度预测问题,给定二维历史观测序列 $\mathbf{X} = (\mathbf{X}^1, \mathbf{X}^2)'$, 其中 $\mathbf{X}^n = (x_1^n, x_2^n, \dots, x_T^n)$ 表示第 n 维特征向量, \mathbf{X}^1 、 \mathbf{X}^2 分别表示入射光强度和入射光角度, $\mathbf{X}_t = (x_t^1, x_t^2)'$ 表示第 t 时刻的特征向量。对于历史观察值 $(X_1, X_2, \dots, X_{T-1})$, 通过 LSTM 网络训练之后得到最佳摄像头角度 y_T , 即 $y_T = F(X_1, X_2, \dots, X_{T-1})$ 。为保证摄像头的可视距离,摄像头与水平线的角度 β 设定为 $35^\circ \sim 50^\circ$, 图像曝光现象主要出现在 $\alpha < 50^\circ$ 的情况下。

为确定最佳摄像头角度,采用良好曝光度 L_{we} 评估图像的曝光程度^[17],其值越大表示图像曝光程度越合适,最大良好曝光度对应最佳摄像头角度,计算公式如下:

$$L_{we} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N e^{-\frac{(f(i,j) - 0.5)^2}{2\sigma^2}} \quad (13)$$

式中, $\sigma = 0.2$; $f(i, j)$ 为像素点的归一化灰度值; L_{we} 越接近 0 表示曝光越低,越接近 1 表示曝光越高,越接近 0.5 表示曝光越适宜。

为增强模型预测性能,本文采集湖北汉川电厂的 513 份入射光强度和入射光角度对应的最佳摄像头角度数据,其中 70% (359 份) 作为训练集, 30% (154 份) 作为验证集。采用决定系数 R^2 描述模型的预测性能,计算公式如下:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

式中, y_i 为 \bar{y} 的真实值,表示均值; \hat{y}_i 为预测值; R^2 越接近 1 说明预测效果越好。

真实值和预测值的比较如图 7 所示,训练集、验证集和全部数据集的决定系数分别为 0.996、0.992、0.998,真实值和预测值基本相等。

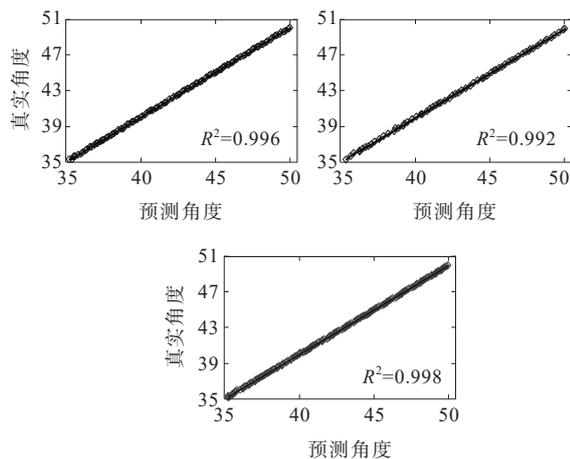


图7 最佳摄像头角度预测值和真实值的比较

Figure 7 Comparison between the predicted and actual values of the best camera angle

不同光源下摄像头调整前、后的对比如图8所示;摄像头角度调整前、后图像的良好曝光度如表1所示。由图8和表1可知,摄像头调整对图像的曝光情况有很大的改善。



(a) 44.26kLux,40.6° (b) 80.52kLux,37.1° (c) 98.34kLux,37.5°

图8 不同光源下摄像头角度调整前、后的图像

Figure 8 Images before and after adjusting camera angles under different light sources

表1 摄像头角度调整前、后图像的良好曝光度

Table 1 Well-exposureness of the image before and after the camera angle adjustment

光照强度及角度	状态	摄像头角度	良好曝光度
44.26 KLux, 40.6°	调整前	37.7°	0.573
	调整后	45.2°	0.932
80.52 KLux, 37.1°	调整前	35.4°	0.698
	调整后	43.9°	0.964
98.52 KLux, 37.5°	调整前	36.3°	0.631
	调整后	47.7°	0.947

2 基于改进的 DenseNet 的导航路径分割

经过图像预处理得到图像后需要对导航线进行分割提取。在传统的神经网络中,随着神经网络层数的增加,输入和梯度信息会随之消失,导致训练精度下降。由于巡检机器人的导航算法对实时性和准确性要求较高,故采用轻量级的 DenseNet 语义分割网络,并对其改进以提高识别准确率和精确率。

2.1 DenseNet 语义分割网络

DenseNet 是出现在 ResNet 之后的语义分割网络,分割网络由多个 Dense Block 连接而成,Dense Block 包含若干个由 Batch Normalization、ReLU 和 1×1 、 3×3 卷积组合而成的 BottleNeck 结构^[18]。DenseNet-121 经过一个卷积层和池化层之后,4 个 Dense Block 和 3 个 Transition Layer 穿插连接,最后连接包含池化层和全连接层的分类层,实现像素分类。

传统的卷积神经网络中只有相邻的神经网络层才会直接连接,缺点是梯度消失和模型退化的情况会随着网络层数的增加变得更严重。为了解决这一问题,DenseNet 在原来的网络基础上改进神经网络层之间的连接方式,网络中每一神经网络层都直接连接。假设 X_l 表示第 l 层的输出, H_l 表示第 l 层的非线性变换,则对于传统神经网络,比如 ResNet 来说, X_l 只与上一层输出有关:

$$X_l = H_l(X_{l-1}) + X_{l-1} \quad (15)$$

而对于 DenseNet, X_l 与之前的每一层都有关, $[X_0, X_1, \dots, X_{l-1}]$ 表示第 0 到 $l-1$ 层网络的输出特征合并结果:

$$X_l = H_l([X_0, X_1, \dots, X_{l-1}]) \quad (16)$$

2.2 激活函数

单独的 Dense Block 中每一层网络的特征大小一样,每一个 Dense Block 将所有输出的特征信息利用 Batch Normalization、ReLU 和 1×1 、 3×3 卷积进行非线性变换,最后一层实现下采样^[18]。激活函数 ReLU 的计算公式为

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (17)$$

$$\text{SeLU}(x) = \begin{cases} \lambda x, & x > 0 \\ \lambda a e^x - \lambda \alpha, & x \leq 0 \end{cases} \quad (18)$$

当梯度过大产生很多负数时,输出为 0,神经元无法激活,将导致梯度消失问题。本文将 BottleNeck 中的激活函数替换为 SeLU 函数,计算公式为

SeLU 函数在保证 ReLU 函数单边抑制作用的同时避免了梯度消失问题。改进激活函数的 DenseNet-121 网络深层结构解析如图 9 所示。

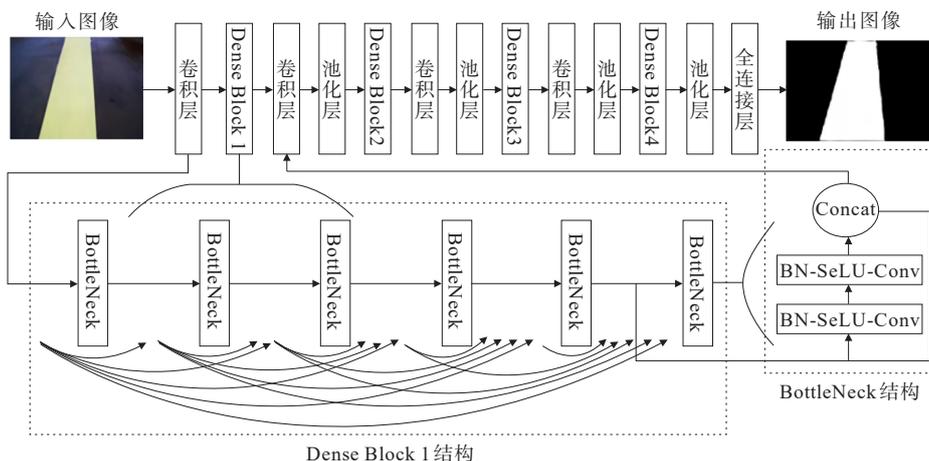


图 9 改进的 DenseNet-121 网络深层结构解析

Figure 9 Improved DenseNet-121 network deep structure analysis diagram

2.3 损失函数

在神经网络训练过程中,损失函数是描述真实值与预测值之间差异的度量参数,不同损失函数所反映的模型预测性能不同。DenseNet 网络采用交叉熵损失函数:

$$L_{CE} = -y \ln \hat{y} - (1 - y) \ln (1 - \hat{y}) \quad (19)$$

式中, y 为真实值; \hat{y} 为预测值。

Focal Loss^[19]在交叉熵的基础上进行修改,引入 α 因子使得比例不均匀的导航线正、负样本分布均衡化,并引入 λ 因子解决易分类样本和困难样本的问题,减少了易分类样本的损失,更关注于困难且错分的样本。由于导航线图像样本复杂,本文将交叉熵损失函数替换为 Focal Loss 损失函数,计算公式为

$$L_{FL} = -\alpha y (1 - \hat{y})^\lambda \ln \hat{y} - (1 - \alpha) (1 - y) \hat{y}^\lambda \ln (1 - \hat{y}) \quad (20)$$

其中, λ 因子实现了易分类样本权重的减小, $\lambda = 0$ 即为交叉熵损失函数。Focal Loss 损失函数降低了易分类负样本占比、提高了困难样本权重,使训练由正样本主导。

3 基于分割结果的机器人导航方法

为了提高巡检机器人后续的视频图像处理速度,将语义分割结果二值化处理转换成单通道图像。本文采用基于图像像素值分布的 Otsu 动态二值化算法,针对一幅图像不同区域的亮度计算出各个区域的最优阈值^[20]。在碰到十字或者丁字路口时,机器人需要采取行为调整,本文采用模板匹配方法对路口类别进行检测识别。如图 10 所示,从二值化图像中截取多个十字和丁字路口模板,采用遍历的方式对图像进行循环移动比对,计算待匹配图像 I 中与模板图像 T 大小相同样本的特征向量距离,通过归一化平方差匹配法找出与模板图像距离最小即相似度最高的样本。

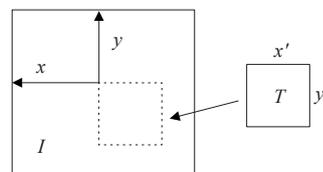


图 10 模板匹配示意

Figure 10 Template matching diagram

假设模板图像 T 的宽和高分别为 x', y' , 则二者的相关系数可表示为

$$R(x, y) = \frac{\sum_{x', y'} (T(x', y') - I(x + x', y + y'))^2}{\sqrt{\sum_{x', y'} T(x', y')^2 \cdot \sum_{x', y'} I(x + x', y + y')^2}} \quad (21)$$

其中, R 的取值范围为 $0 \sim 1$, 当 $R=0$ 时, 模板图像和灰度图像的匹配度最高。 R 越小匹配度越高, 本文设置 R 的阈值为 0.15 , 当整幅导航路径图像中与路口模板存在相关系数小于 0.15 的区域时, 可判定巡检机器人经过对应分叉路口。

采用最小二乘法对导航线每行的中心点进行直线拟合。如图 11 所示, 假设图像 $f(i, j)$ 的宽、高分别为 m, n , 图像中心点为 C_0 , L 为拟合直线, 第 j 行白色像素点的平均 X 坐标值为 \bar{X}_j , k 表示每一行非零像素点的个数, 则

$$\bar{X}_j = \sum_{i=0}^m i/k, f(i, j) \neq 0, j = 0, 1, \dots, n \quad (22)$$

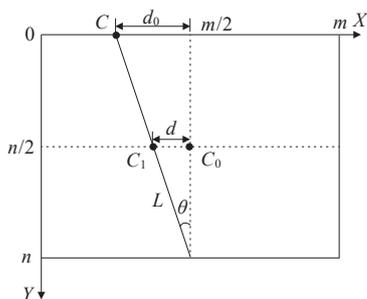


图 11 偏移量计算示意

Figure 11 Schematic diagram of offset calculation

由于距离摄像头更远的像素点参考价值更高, 故根据实际行驶情况, 定义每一行的权重系数为

$$\alpha_j = -\frac{1}{600} \times j + 1.2, j = 0, 1, \dots, n \quad (23)$$

则中心点 C_0 的偏移量为

$$d = \sum_{j=0}^n \frac{\alpha_j \cdot (\bar{X}_j - m/2)}{n} \quad (24)$$

取图 11 中 d_0 为导航路径的偏移量, θ 表示其偏移角度, 反映巡检机器人偏移的程度及方向, 根据图中几何关系可得:

$$d_0 = d + \frac{n}{2} \tan \theta, -\frac{m}{2} \leq d_0 \leq \frac{m}{2} \quad (25)$$

4 实验过程与结果

4.1 不同场景的图像预处理结果

4.1.1 不同光照的图像预处理结果

分别选取强光、弱光、人造光不均以及曝光条件下的图像进行实验, 将本文提出的基于像素点局部均值动态调整的伽马校正方法与改进前的伽马校正方法进行比较, 如图 12 所示, 从左至右分别表示原图、HSV 通道重组、伽马校正以及本文算法的处理结果, 基于像素点局部均值动态调整的伽马校正方法处理后的图像色彩饱和度更高、亮度更适宜。在曝光条件下, 摄像头会自动调整角度以缓解曝光问题, 曝光图像处理如图 13 所示。



(a) 强光



(b) 弱光



(c) 光照不均

图 12 不同光照条件下的原图、HSV 通道重组、伽马校正及本文算法的处理结果

Figure 12 Original image, HSV channel reorganization, gamma correction, our results under different lighting conditions



(a) 原图 (b) 摄像头调整后 (c) 自适应伽马校正

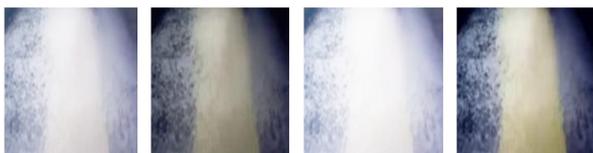
图 13 曝光图像处理结果

Figure 13 Processing result of exposed image

由图 13 可知,摄像头调整能有效减少曝光,但图像整体偏亮,经过自适应伽马校正之后图像清晰度和饱和度均有所提升,且亮度也调整至合适的范围。

4.1.2 恶劣天气的预处理结果

当地面出现厚雪覆盖情况时,机器人将随之出现轮胎打滑现象,磁轨、激光和视觉导航方法均无法适用。本文仅针对导航线有薄雪覆盖的情况,大部分颜色和边缘信息丢失,分割难度大。对不同干扰下图像的亮度、对比度及清晰度进行处理前、后的评估,采用各颜色通道平均灰度值的均方根描述亮度,薄雪覆盖图像处理结果如图 14 所示,可知改进后的伽马校正方法能有效调整亮度并提高对比度和清晰度。



(a) 原图 (b) HSV 通道重组 (c) 伽马校正 (d) 本文算法

图 14 薄雪覆盖图像处理结果

Figure 14 Processing result with thin snow covered

采用图像对比度和清晰度进行图像质量综合评估,图像对比度^[21]计算公式如下:

$$C = \sum_{\delta} \delta(i, j)^2 P_{\delta}(i, j) \quad (26)$$

式中, $\delta(i, j) = |i - j|$ 表示相邻像素间的灰度差; $P_{\delta}(i, j)$ 表示相邻像素间灰度差为 δ 的像素概率分布。

采用能够体现图像灰度值变化率的空间频率 (spatial frequency, SF) 描述清晰度^[22], 数值越大图像越清晰, 计算公式如下:

$$F_s = \sqrt{F_R^2 + F_C^2} \quad (27)$$

$$F_R = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=2}^N |f(i, j) - f(i, j-1)|^2} \quad (28)$$

$$F_C = \sqrt{\frac{1}{MN} \sum_{i=2}^M \sum_{j=1}^N |f(i, j) - f(i-1, j)|^2} \quad (29)$$

式(27)~(29)中, f 为像素点的灰度值; F_R 、 F_C 分别为图像的行、列频率。

对强光、弱光、光照不均以及薄雪覆盖情况的图像均采用 HSV 通道重组、伽马校正及自适应伽马校正处理,对曝光情况进行摄像头调整和自适应伽马校正,处理前、后的图像亮度、对比度以及清晰度如表 2 所示。根据图 12~14、表 2 可以看到,改进后的伽马校正方法能自适应地将图像亮度和对比度调整至合适的范围,并提升图像清晰度。

表 2 不同干扰下不同增强方法的图像亮度、对比度、清晰度

Table 2 Image brightness, contrast, and clarity of different enhancement methods under different interferences

干扰	预处理方法	亮度	对比度	清晰度
强光	原图	214.57	68.442	22.735 8
	HSV 通道重组	205.66	81.736	23.686 5
	伽马校正	234.40	66.247	19.436 0
	自适应伽马校正	137.49	216.834	30.658 9
弱光	原图	17.64	18.304	12.264 2
	HSV 通道重组	9.51	16.610	6.450 5
	伽马校正	97.83	124.415	10.429 2
	自适应伽马校正	106.46	135.646	10.759 2
光照不均	原图	129.54	236.905	16.407 5
	HSV 通道重组	115.88	240.445	17.572 3
	伽马校正	189.83	225.589	12.737 3
	自适应伽马校正	176.71	274.396	20.576 3
薄雪覆盖	原图	89.25	76.621	9.635 4
	HSV 通道重组	81.89	78.426	8.568 4
	伽马校正	142.19	54.951	7.549 6
	自适应伽马校正	109.15	132.816	12.564 1
曝光	原图	235.16	97.543	11.268 1
	摄像头调整	218.91	124.957	12.946 5
	自适应伽马校正	190.43	183.543	15.194 4

4.2 改进 DenseNet 的分割结果

数据采集过程中模拟巡检机器人在弱光照、正常天气、强光照以及雨雪天气下的情景,采集导航路径图像。为提高训练模型精度,本文采用数据增强的方法扩大数据集,对原始数据集和对应的标注结果进行相同的几何变换和色彩变换,增强后共产生 4 861 张图片,部分数据集如图 15 所示。



(a)增加饱和度 (b)增加亮度 (c)旋转 (d)降低饱和度

图15 部分数据集样本

Figure 15 Part of the data set sample

将准确率 A 和精确率 P 作为评价指标,其计算公式为

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (30)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (31)$$

式(30)、(31)中, N_{TP} 为正确的导航线被预测为正确的导航线像素点个数; N_{TN} 为正确的导航线被预测为错误的导航线像素点个数; N_{FP} 为错误的导航线被预测为正确的导航线像素点个数; N_{FN} 为错误的导航线被预测为错误的导航线像素点个数^[23]。

实验采用 Win10 的 64 位系统、Pytorch1.7.1 和 Python3.6 环境以及 NVIDIA GeForce RTX 2080Ti 显卡。迭代训练 300 个 epoch, batch_size 为 8, 学习率为 0.001。为了客观评估本文预处理算法和改进后的 DenseNet 网络对分割准确率和精确率的作用,对强光、弱光、光照不均、薄雪覆盖以及曝光条件下的图像进行传统方法和本文算法处理,其中传统方法采用 HSV 通道重组和 OTSU 二值化相结合,结果如图 16~20 所示。

不同分割方法对比实验结果如表 3 所示,相比原始的 DenseNet 网络,改进网络的准确率和精确率分别提升了 2.31% 和 2.09%,经过图像预处理后改进网络的准确率和精确率分别提升了 5.92% 和 5.07%。



(a)原图 (b)传统方法 (c)本文算法

图16 强光条件下不同分割方法的对比

Figure 16 Comparison of different segmentation methods under strong light conditions



(a)原图 (b)传统方法 (c)本文算法

图17 弱光条件下不同分割方法的对比

Figure 17 Comparison of different segmentation methods under weak light conditions



(a)原图 (b)传统方法 (c)本文算法

图18 光照不均条件下不同分割方法的对比

Figure 18 Comparison of different segmentation methods under uneven light conditions



(a)原图 (b)传统方法 (c)本文算法

图19 薄雪覆盖条件下不同分割方法的对比

Figure 19 Comparison of different segmentation methods under the condition of thin snow cover



(a)原图 (b)传统方法 (c)本文算法

图20 曝光条件下不同分割方法的对比

Figure 20 Comparison of different segmentation methods under exposure conditions

表3 不同分割方法对比实验结果

Table 3 Comparison of experimental results of different segmentation methods %

分割方法	准确率	精确率
传统方法	81.32	82.26
DenseNet	92.33	93.78
改进 DenseNet	94.64	95.87
预处理+改进 DenseNet	98.25	98.85

4.3 现场实验结果

巡检机器人在湖北汉川电厂进行了长达一年的现场实验,如图21所示。在本文算法进行实际应用之前,该电厂采用HSV通道重组的方法对黄色导航线进行像素特征提取,由于光照和雨雪天气的影响,平均识别准确率仅81.32%。本文经过图像预处理消除光照影响之后,用改进后的DenseNet网络分割出导航路径,平均识别准确率提高了16.93%。在此基础上,拟合机器人行驶过程中的中心线并计算偏移量。采用模板匹配的方法判断机器人是否经过走向、定位与分叉标志。结果表明,本文提出的复杂环境机器人视觉导航方法在Nvidia Jetson TX2模块上的处理速度为8~10帧/s,实时性和准确性能满足巡检机器人的实际工作需求。



图21 实验现场

Figure 21 Field experiment

5 结语

本文提出基于图像预处理和语义分割的电力巡检机器人视觉导航方法,经过不同条件下的实验得到以下结论:

1) 基于摄像头角度调整的曝光抑制有效解决了曝光情况对图像的干扰,基于自适应伽马校正的图像增强方法对不同非曝光条件下的图像对比度提升效果显著;

2) 改进后的DenseNet语义分割网络准确率和精确率大大提高,结合预处理方法的分割结果能满足电力机器人巡检的实际应用需求。

参考文献:

[1] 周展帆,严宇,邹德华,等.高压输电线路带电更换防振锤机器人的研制[J].电力科学与技术学报,2020,35(2):178-183.

- ZHOU Zhanfan, YAN Yu, ZOU Dehua, et al. Development of a robot for replacing anti-vibration hammers on high-voltage transmission lines[J]. Journal of Electric Power Science and Technology, 2020, 35(2): 178-183.
- [2] 樊志强,董朝轶,王启来,等.基于多传感器数据融合的巡检机器人测姿系统研究[J].自动化与仪器仪表,2021(3):77-82+86.
- FAN Zhiqiang, DONG Chaoyi, WANG Qilai, et al. Research on attitude measurement system of patrol inspection robot based on multi-sensor data fusion[J]. Automation & Instrumentation, 2021(3): 77-82+86.
- [3] CHAWLA V K, CHANDA A K, ANGRA S. Dispatching and scheduling of multi-load AGVs in FMS-A simulation study[J]. Materials Today: Proceedings, 2018, 5(11): 25358-25367.
- [4] YUSOF T S T, TOHA S F, YUSOF H M. Path planning for visually impaired people in an unfamiliar environment using particle swarm optimization[J]. Procedia Computer Science, 2015, 76: 80-86.
- [5] 董诗绘,牛彩雯,戴琨.基于深度强化学习的变电站巡检机器人自动化控制方法研究[J].高压电器,2021,57(2):172-177.
- DONG Shihui, NIU Caiwen, DAI Kun. Study on automatic control method of substation inspection robot based on deep reinforcement learning[J]. High Voltage Apparatus, 2021, 57(2): 172-177.
- [6] IRMISCH P, BAUMBACH D, ERNST I. Robust visual-inertial odometry in dynamic environments using semantic segmentation for feature selection[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 5(2): 435-442.
- [7] GUERRERO J M, GUIJARRO M, MONTALVO M, et al. Automatic expert system based on images for accuracy crop row detection in maize fields[J]. Expert Systems With Applications, 2013, 40(2): 656-664.
- [8] 薛阳,江天博,张晓宇.基于视觉的变电站巡检机器人导航线提取方法[J].广东电力,2015,28(12):13-18.
- XUE Yang, JIANG Tianbo, ZHANG Xiaoyu. Vision-based substation inspection robot navigation line extraction method[J]. Guangdong Electric Power, 2015, 28(12): 13-18.
- [9] 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.

- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 2015.
- [11] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [12] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//30th IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 2017.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [14] 朱铮涛, 萧达安. 基于非线性调整的伽马校正图像增强算法[J]. *计算机工程与设计*, 2018, 39(9): 2822-2826+2866.
ZHU Zhengtao, XIAO Daan. Gamma correction image enhancement algorithm based on nonlinear adjustment[J]. *Computer Engineering and Design*, 2018, 39(9): 2822-2826+2866.
- [15] ZHANG S, WANG T, DONG J, et al. Underwater image enhancement via extended multi-scale Retinex[J]. *Neurocomputing*, 2017, 245: 1-9.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [17] MERTENS T, KAUTZ J, VAN REETH F. Exposure fusion [C]//15th Pacific Conference on Computer Graphics and Applications, Maui, HI, USA, 2007.
- [18] RAFIEI S, JAFARI M H, KARIMI N, et al. Dense pooling layers in fully convolutional network for skin lesion segmentation[J]. *Computerized Medical Imaging and Graphics*, 2019, 78: 101658.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [20] 何志勇, 孙立宁, 陈立国. Otsu准则下分割阈值的快速计算[J]. *电子学报*, 2013, 41(2): 267-272.
HE Zhiyong, SUN Lining, CHEN Ligu. Fast computation of threshold based on otsu criterion[J]. *Acta Electronica Sinica*, 2013, 41(2): 267-272.
- [21] 刘国, 吕群波, 刘扬阳. 基于自适应暗原色的单幅图像去雾算法[J]. *光子学报*, 2018, 47(2): 179-186.
LIU Guo, LÜ Qunbo, LIU Yangyang. Single image defogging algorithm based on adaptive dark primary color [J]. *Acta Photonica Sinica*, 2018, 47(2): 179-186.
- [22] SHAH P, MERCHANT S N, DESAI U B. Multifocus and multispectral image fusion based on pixel significance using multiresolution decomposition[J]. *Signal, Image and Video Processing*, 2013, 7(1): 95-109.
- [23] POWERS D M W. Evaluation: from precision, recall and F-measure to ROC informedness, markedness and correlation[J]. *Journal of Machine Learning Technologies*, 2011, 2(1): 37-63.