

基于深度学习的巡检机器人避障轨迹 自动控制系统设计

乔道迹

(中北大学 计算机科学与技术学院, 太原 030051)

摘要: 为了提高巡检机器人在复杂环境下的避障能力, 使机器人能够安全地完成巡检任务, 设计基于深度学习的巡检机器人避障轨迹自动控制系统; 设计由 CCD 传感器、信号处理芯片等设备组成的工业智能视觉 CCD 相机, 基于 FPGA 和 USB2.0 的视频采集卡传输采集数据, 完成硬件部分的设计; 在软件设计中, 对采集的图像实施目标分割、双目目标匹配等预处理, 通过对摄像头实施双目视觉标定获取障碍物空间位置三维信息, 基于深度学习中的 CRNN 设计机器人自主避障规划网络模型, 并设计模糊轨迹控制器, 实现避障中的轨迹自动控制; 系统测试结果表明, 设计系统最终成功避开了 3 个动态障碍物, 最大轨迹控制误差的最大值为 1.45° , 最小轨迹控制误差的最大值为 0.62° , 动态避障巡检速度始终在 3.5 m/s 左右, 表现出了精准而稳定的轨迹控制效果。

关键词: 深度学习; 视频采集卡; 双目视觉标定; 巡检机器人避障; 轨迹控制

Design of Automatic Control System for Obstacle Avoidance Trajectory of Inspection Robot Based on Deep Learning

QIAO Daoji

(School of computer science and technology, North University of China, Taiyuan 030051, China)

Abstract: In order to improve the obstacle avoidance capability of inspection robots in complex environments and safely complete inspection tasks, an inspection robot obstacle avoidance trajectory automatic control system based on deep learning is designed. In the hardware design, the industrial intelligent vision CCD camera consists of CCD sensors, signal processing chips, the collected data is transmitted through the video acquisition card of FPGA and USB2.0. In the software design, the preprocessing techniques such as target segmentation and binocular object matching are applied to the captured images. The binocular visual calibration on the cameras is performed to obtain the three-dimensional spatial information of obstacles. Furthermore, an autonomous obstacle avoidance planning neural network model based on convolutional recurrent neural network (CRNN) is developed, and a fuzzy trajectory controller is designed to achieve automatic control of the trajectory during obstacle avoidance. The test results show that the system successfully avoids three dynamic obstacles, with a maximum trajectory control error of 1.45° and minimum trajectory control error of 0.62° . The dynamic obstacle avoidance inspection speed is always maintained at around 3.5 m/s , exhibiting the precise and stable trajectory control performance.

Keywords: deep learning; video capture card; binocular vision calibration; obstacle avoidance for inspection robots; trajectory control

0 引言

输电线路是全国经济发展、设施建设的基础条件。为避免输电线路发生故障影响整体电路系统与其他行业, 电力部门必须定期对线路进行巡检, 从而及时处理输电线路上的隐患与故障。通常, 输电线路走廊内会设置多个监测点, 通过实验、在线监测、线路巡检等方式对线路实施状态评估及监测^[1]。伴随着机器人的迅速发展, 在各个领域, 特种机器人得到了越来越广泛的应用, 其中巡检机器人就

为架空输电线路的巡检提供了新的方法, 不仅能够近距离实施巡检, 还能搭建有一定质量的维护设备, 实现线路的主动维护。然而, 巡检机器人在执行任务时需要穿越复杂的环境, 例如工业厂房、狭窄的通道或高风险区域。如果没有自动化的避障轨迹控制系统, 机器人可能会与障碍物碰撞或陷入危险的状况中, 导致安全隐患^[2]。自动控制系统可以根据传感器获得的环境信息和事先设定的规则, 及时调整机器人的运动轨迹, 以避免与障碍物发生碰撞, 从而提高机器人的安全性。为此, 需要设计一种巡检机器人

收稿日期: 2023-09-06; 修回日期: 2023-10-24。

作者简介: 乔道迹(1977-), 男, 硕士, 实验师。

引用格式: 乔道迹. 基于深度学习的巡检机器人避障轨迹自动控制系统设计[J]. 计算机测量与控制, 2024, 32(5): 129-136.

避障轨迹自动控制系统。

目前国内学者对于机器人避障控制问题进行了深入研究。其中文献 [3] 中提出了一种基于视觉的移动机器人避障控制系统，该系统主要是以 STM32F1 处理器作为核心，通过实验验证了该系统的避障功能。文献 [4] 中提出了一种输电线路巡线机器人避障控制系统，实验结果证明，相比传统控制系统，该系统投入使用后能够明显提升线路输电能力，解决了巡检机器人的定向控制问题。文献 [5] 设计了一种基于机器视觉的机器人仿生机械手避障轨迹控制系统，实验结果表明，该系统有着良好的应用效果。

以上方法在实际应用中存在控制不够稳定的问题，因此设计一种基于深度学习的巡检机器人避障轨迹自动控制系统。通过卷积循环神经网络 (CRNN, convolutional recurrent neural network) 机器人自主避障规划网络模型实现三维动态环境中的巡检机器人自主避障规划。将航向角误差变化率与航向角误差输入至模糊轨迹控制器中，实现避障中的轨迹自动控制。通过该模糊轨迹控制器能够实现更加稳定、精度度更高的避障轨迹自动控制。

1 巡检机器人自动控制系统设计

1.1 硬件设计

通过 CCD 传感器、信号处理芯片等设备组成工业智能视觉 CCD 相机，基于 FPGA 和 USB2.0 设计视频采集卡模块，完成硬件系统的设计，硬件系统的框架结构如图 1 所示。

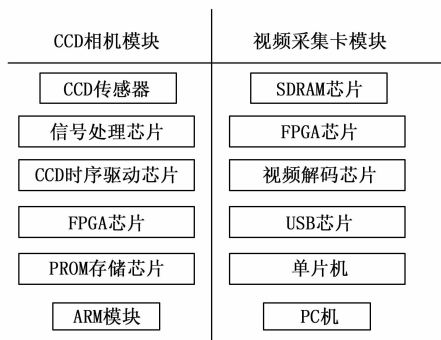


图 1 巡检机器人避障轨迹自动控制系统框架

1.1.1 CCD 相机模块设计

通过系统硬件实现环境图像的采集。主要通过安装两部 CCD 相机连接视频采集卡采集巡检机器人的双目视觉环境图像。在 CCD 相机模块中，通过 CCD 相机连续采集巡检机器人运行中的双目视觉环境图像，以获取障碍物空间位置。设计一种工业智能视觉 CCD 相机，其硬件结构如图 2 所示。

其中 CCD 传感器、信号处理芯片与 CCD 时序驱动芯片构成该工业智能视觉 CCD 相机的图像采集前端电路。其中 CCD 传感器选用的型号为 ICX204AL 传感器，共有 16 个引脚，通过 16pin-DIP 对该芯片进行封装。

信号处理芯片 AD9949 是一种 12 位的 CCD 信号处理器，通过信号处理芯片 AD9949 对该芯片进行封装，其像素速率

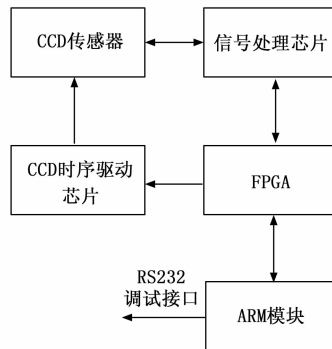


图 2 CCD 相机硬件结构

最高能够达到 36 Mhz^[6]。CCD 时序驱动芯片 CXD3400N 是一种 6 通道的时序驱动芯片，通过 20 pin-SSOP 对该芯片进行封装。三者构成的图像采集前端电路如图 3 所示。

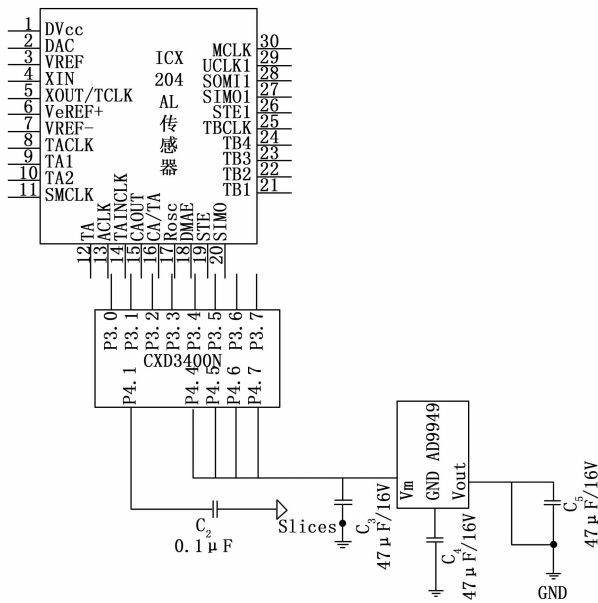


图 3 图像采集前端电路

选用的 FPGA 芯片为 XC3S50AN，并为其配置 PROM 存储芯片存储其程序。选用的 ARM 模块为 Mini2440 模块，通过 BGA 对其进行封装。

1.1.2 视频采集卡模块设计

设计一种基于 FPGA 和 USB2.0 的视频采集卡，该采集卡使用 3 层 PCB 板设计，其内层用做地层和电源层，主要芯片均集成于顶层。视频采集卡的作用是传输采集数据，处理双目视觉环境图像的采集信号以及显示最终采集结果等。设计的视频采集卡由 SDRAM 数据存储模块、FPGA 逻辑控制模块等构成，具体结构如图 4 所示。

其中在 SDRAM 数据存储模块中，采用的 SDRAM 芯片为 HY57V 641620HG，其容量为 64 Mb，将其作为 FPGA 的外部存储器来使用，存储 FPGA 有限存储容量下无法存储的那些逻辑控制数据。

在每次上电时，均需要对该芯片实施初始化操作，按

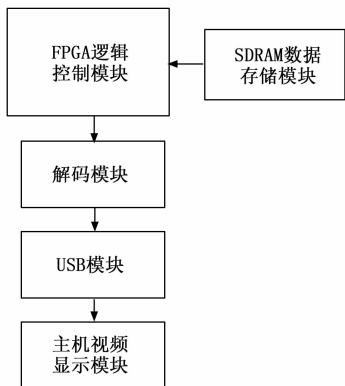


图 4 视频采集卡结构

照操作时序设计一个同步状态机操作程序实现其初始化操作，该程序的具体运行步骤如下。

- 1) 维持 102 μs 的稳定期；
- 2) 对全部 L-Bank 实施预充电；
- 3) 设置 8 个刷新周期；
- 4) 对模式寄存器进行设置，确定工作模式。

该程序的输入信号为 `sys_clk` 与 `sys_rst`，分别为时钟信号与复位信号，输入以上信号后即开始初始化操作。该程序的输出信号为 `sd_ini_dqm`、`sd_ini_add`、`sd_ini_we`、`sd_ini_cas` 和 `sd_ini_ras`，分别与 SDRAM 芯片的管脚 `dqm`、`add`、`we`、`cas`、`ras` 直接相连。

FPGA 逻辑控制模块的主要作用是处理采集中的数字信号，执行逻辑运算，根据实际应用需求可定制其功能，是一种低能耗、高性能的集成电路。

在 FPGA 逻辑控制模块中，选用的主控芯片为 EP1C6Q240C8，有着丰富的管脚资源，通过 Verilog HDL 设计该芯片的时序操作步骤^[7]，其时序操作步骤具体如图 5 所示。

在解码模块中，选用的视频解码芯片为 SAA7115，是一款多制式的视频解码器。使用该视频解码芯片时，用户能够自主决定输出视频窗口的大小^[8]。使用 USB 模块中的 CY7C68013 单片机配置 SAA7115 芯片内部的寄存器，分别连接 SAA7115 与 CY7C68013 单片机的 SDA 管脚与 SCL 管脚，使用单片机在寄存器中写入配置的数据。通过解码模块能够实现 CCD 相机采集视频的解码处理。

在 USB 模块中，选用的 USB 芯片型号为 CY7C68013，支持 USB2.0 协议。通过 CY7C68013 能够实现 PC 机与视频采集卡之间的信号传输。在主机视频显示模块中，选择一个 PC 机作为上位机，用于接收数据与图片显示。其中主要通过 CY7C68013 中的库函数实现上位机视频数据的接收。通过 OpenCV 实现图像的正确显示，选用的 PC 机型号为联想天逸 510 S，以此完成图像的采集工作。

1.2 软件设计

1.2.1 采集图像预处理

在采集图像处理模块中，对于硬件系统采集的各帧环

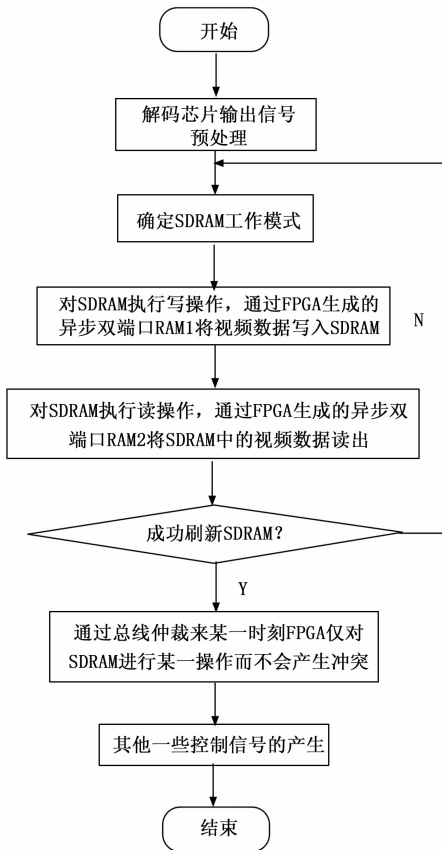


图 5 FPGA 芯片的时序操作步骤设计

境图像，分别对其实施图像分割、双目目标匹配等预处理，以完成障碍物的识别，具体步骤如下：

1) 在对采集的环境图像实施二值化处理之前，首先要对图像实施灰度化处理，并对图像分割阈值进行选择^[9]。选择阈值过大，会导致所需信息的丢失，而选择的阈值过小，则会导致多余部分被提取。使用判别分析法来确定最佳阈值，具体步骤如下：

(1) 分析图像内全部像素点的对应灰度分布信息，用 m 表示图像内的总像素数，用 m_i 表示直方分析获得的灰度值是 i 的像素数，则灰度级 l 的 0 阶矩灰度分布可以用下式来定义：

$$\varphi(l) = \sum_{i=1}^s \frac{m_i}{m} \quad (1)$$

式中， S 指的是灰度级的取值集合。灰度级 l 的 1 阶矩灰度分布可以用下式来定义：

$$\iota(l) = \sum_{i=1}^s \frac{im_i}{m} \quad (2)$$

(2) 根据灰度级 l 的 0 阶矩灰度分布与 1 阶矩灰度分布计算类间方差值。当类间方差达到最大值时，所对应的 l 值就是最佳分割点即最佳阈值^[10]。计算公式为：

$$l'' = [\varphi(l) - \iota(l)]^2 \quad (3)$$

2) 图像二值化处理：

通过二值化处理能够将图像背景信息去除，使目标信

息更加突出。在获得最佳分割阈值后，将全部像素点的灰度值与该值相比较，从而重新对该像素的灰度^[11]进行赋值，最终重绘整幅图像。具体赋值规则如下式所示：

$$T_f(a'', b'') = \begin{cases} 1 & s(a'', b'') \geq l'' \\ 0 & s(a'', b'') < l'' \end{cases} \quad (4)$$

式中， $s(a'', b'')$ 指的是原始像素灰度； $T_f(a'', b'')$ 是指处理后的图像像素灰度。

在双目目标匹配中，选择的处理方法为基于图像特征点的匹配方法。对于采集的双目图像，可以分别获得两个图像 SURF 特征点的描述子与位置。假设左图像中特征点数量为 M_L ，右图像中特征点数量为 M_R ，按照以下步骤匹配 M_L 与 M_R ：

- 1) 计算 M_L 与 M_R 之间的欧式距离；
- 2) 选择右图像中与左图像欧氏距离最近的两个点，将其作为待选择的匹配点，对二者实施欧式距离的相似性约束筛选，符合条件后，将二者作为初筛后的匹配点；
- 3) 由于此时仍然存在错误匹配情况，利用其它约束条件进一步实施筛选。分别对初筛后的匹配点实施极线约束检测、唯一性约束检测以及视差范围约束检测^[12]。按照以上步骤匹配特征点后，即可完成图像的双目目标匹配处理。

1.2.2 获取障碍物空间位置

在上述预处理后的图像中，获取障碍物空间位置。通过图像预处理中的图像分割及双目匹配等操作，可以有效提取和增强图像中的有用信息，以便更准确地获取障碍物的空间位置。通过对摄像头实施双目视觉标定，计算同名点深度获取障碍物空间位置三维信息。在摄像头的标定中，使用的标定工具为 MATLAB 标定工具箱 Camera Calibrato，选用的标定板为 8×6 棋盘格，其中小正方形的尺寸为 2.5×2.5 cm。该棋盘格为黑白棋盘格，角点和周边像素值有着较高的对比度，各点互相独立，分布均匀，能够降低标定板位旋旋转和光线变化带来的误差。

具体标定方法为固定棋盘格，移动相机，沿着不同的方向获得标定图像。在该过程中，为确保标定精度，需要采集 8 张以上图像。接着输入 cameraCalibrator，对相机标定工具箱进行调用，批量添加采集的图像，并输入各棋盘格子的边长，提取各图像中的角点。所提取的角点软件会自动用红色十字标记。提取角点后，剔除误差较大的图片，以获得更加精准的结果^[13]。通过 Calibration 函数依据角点信息实施标定计算，对相机的畸变参数与内部参数进行求解，依据多张图像的计算结果，通过极大似然估计算法实施参数优化，完成相机的标定。

在同名点深度计算中，采用的方法为使用两个摄像头，提前测量二者的相对位置，在两个角度同时拍摄某一时刻的两个画面，通过处理即可获得所需的计算信息。具体来说，首先将图像的左上角直接设置为原点，则由该点水平向右延伸即为 X 轴的正方向，垂直向下延伸即为 Y 轴的正方向，此时图像内的任一像素都拥有了唯一的坐标，目标

点也拥有了坐标，具体如图 6 所示。




图 6 图像坐标系

计算的第一步就是得到图像中同名点的坐标，分别用 $L_1(x_1, y_1)$ 、 $L_2(x_2, y_2)$ 表示。设 ω 为相对坐标系中物理点与像素点连线和光轴之间的夹角角度，并根据标定结果计算目标点的垂直角度 ν 与水平角度 $\bar{\omega}$ 。其中水平角度 $\bar{\omega}$ 的计算公式具体如下：

$$\bar{\omega} = \arctan \left(\frac{\left(x - \frac{Q}{2}\right) \cdot \omega}{u \cdot \alpha \cdot \beta} \right) \quad (5)$$

式中， u 指的是相机的标定焦距； Q 是指采集图像的宽度； x 指的是目标点的横坐标； α 是指相机的标定水平视角； β 指的是相机的标定垂直视角。

垂直角度 ν 的计算公式具体如下：

$$\nu = \arctan \left(\frac{\left(y - \frac{E}{2}\right) \cdot \omega}{u \cdot \alpha \cdot \beta} \right) \quad (6)$$

式中， y 指的是目标点的纵坐标； E 是指采集图像的高度^[14]。

根据两个像素点和物理点构成的三角关系，将预处理后的图像信息输入其中，获得最终的目标点相对坐标，具体如下式所示：

$$\begin{cases} z = \frac{T_f(a'', b'')N}{\tan\bar{\omega}_1 - \tan\bar{\omega}_2} \\ x' = z \tan\bar{\omega} - \frac{N}{2} \\ y' = z \tan\nu_1 \text{ or } \nu_2 \\ \nu = \nu_1 = \nu_2 \end{cases} \quad (7)$$

式中， N 指的是两台相机间的距离； $\bar{\omega}_1$ 是指 $L_1(x_1, y_1)$ 的水平角度； $\bar{\omega}_2$ 指的是 $L_2(x_2, y_2)$ 的水平角度； ν_1 是指 $L_1(x_1, y_1)$ 的垂直角度； ν_2 指的是 $L_2(x_2, y_2)$ 的垂直角度^[15]。将 $L_1(x_1, y_1)$ 、 $L_2(x_2, y_2)$ 代入该方程中既可以获得目标点的空间位置三维信息。

2 基于深度学习的自动控制方法

通过获取障碍物空间位置可以使机器人准确定位障碍物，确定障碍物的相对距离、方位角以及其大小、形状等特征，从而能够判断障碍物对机器人行进路径的影响程度，自动控制其避开障碍物。基于深度学习中的 CRNN 设计一种机器人自主避障规划网络模型，实现三维动态环境中的

巡检机器人自主避障规划。该机器人自主避障规划网络模型结合了 CNN 与 RNN 的特点, 能够处理三维空间中较多的网络参数, 对三维空间信息较为敏感。

该模型是一个由输入层、两个隐藏层、和输出层组成的网络模型, 相比传统的三层结构神经网络模型, 多了一个隐藏层。在其输入层中, 神经元按照三维来排列, 所对应的是获取的障碍物空间位置三维数据。选择的激活函数是 ReLU, 通过卷积连接的方式将第一层隐藏层与输入层相连。

该层为一个卷积层, 含有 32 个 $2 \times 2 \times 3$ 尺寸的卷积核, 使用全 0 填充, 卷积步长为 1, 基于 1.2.2 小节获取的目标点空间位置的三维坐标, 则输入层的前向传播过程可以用下式来表述:

$$b_1 = \text{ReLU}(r_1 \otimes b_0 + u_1)(z, x', y) \quad (8)$$

式中, b_0 指的是探测数据的填充矩阵; r_1 指的是输入层的权重矩阵; b_0 是指输入层获得的特征向量^[16]; u_1 是指输入层的偏置。

第一层隐藏层由一个整合层、池化层和卷积层构成, 能够实现障碍物空间位置三维数据的特征提取。同样选择 ReLU 作为其激活函数, 通过全连接的方式与第二层隐藏层相连接。

该层中的第一层为最大池化层, 池化步长为 2, 滤波器尺寸为 2×2 , 所获得的特征图尺寸是 $10 \times 20 \times 32$; 第二层是卷积层, 含有 16 个 $2 \times 3 \times 32$ 尺寸的卷积核, 通过该层对第一层获得的池化特征图实施卷积操作, 卷积步长为 1, 使用全 0 填充, 获得 $10 \times 20 \times 16$ 尺寸的特征图; 第三层同样是卷积层, 含有 8 个 $2 \times 3 \times 16$ 尺寸的卷积核, 卷积步长为 1, 得到的特征图的尺寸为 $10 \times 20 \times 8$; 第四层是最大池化层, 步长为 2, 池化滤波器尺寸为 2×2 , 所获得的池化特征图尺寸为 $5 \times 10 \times 8$; 第五层为整合层, 在该层中, 首先以池化特征图的维度 1 为样本维度, 并展开维度 2 与维度 3 共同作为同一维度, 接着取和维度 1 同样本数的纵倾角度、纵荡速度、目标相对巡检机器人的深度以及当前时刻目标方位角数据, 将展开后的特征向量与其相拼接, 获得新的特征向量^[17]。第一个隐藏层的前向传播过程可以用下式表述:

$$g_1 = b_1 \text{flatten}(q) \oplus \epsilon_g \oplus f_g \oplus o \oplus \lambda \quad (9)$$

式中, q 指的是第一个隐藏层的特征向量; $\text{flatten}(\cdot)$ 代表展开操作, 也就是展开矩阵最后二维向量, 使其成为一维向量; ϵ_g 是指当前时刻目标方位角; λ 是指纵倾角度; f_g 表示目标相对巡检机器人的深度; o 代表纵荡速度; \oplus 指的是矩阵拼接符号。

第二层隐藏层是一个循环网络层, 将第一层隐藏层的输出作为其部分输入, 并将巡检机器人下一时刻期望的纵倾角度、纵荡速度、目标相对巡检机器人的深度以及当前时刻目标方位角作为该层其他的输入部分。该层神经元的状态由前一刻的神经元与当前输入时刻的神经元构成, 通过全连接的方式与输出层相连^[18]。第二个隐藏层的前向

传播过程可以用下式来表述:

$$s_t = \varphi(M_x g_{t-1} + g_t + d_x) \quad (10)$$

式中, M_x 指的是循环网络层的特征向量; $\varphi(\cdot)$ 是指循环函数; g_{t-1} 指的是 $t-1$ 时刻的输出; d_x 是指循环网络层对应偏置。

输出层中有 3 个神经元, 对应的分别是避障机器人期望的转艏角速度、纵倾角速度以及纵荡加速度。将正切函数作为该层的激活函数。输出层为全连接层, 其前向传播过程可以用下式来表述:

$$z_t = s_t \tanh(M_t p^t + d_t) \quad (11)$$

式中, M_t 是指全连接层的特征向量; p^t 是指 t 时刻目标位置向量; d_t 指的是全连接层的对应偏置; z_t 是指 t 时刻机器人自主避障规划网络模型的输出。

在机器人自主避障规划网络模型的训练中, 将均方误差作为其损失函数, 具体如下式:

$$K = z_t \sum_{i=1}^t K_i = z_t \sum_{i=1}^t \frac{1}{2t} (\kappa_i - a^i)^2 \quad (12)$$

式中, K_i 指的是一组样本的损失; κ_i 是指该组样本的输出; a^i 指的是该组样本的训练误差。

将巡检机器人自主避障规划路线中的航向角误差变化率与航向角误差作为该模糊轨迹控制器的两个输入, 其输出是转向角, 首先设计输入与输出的模糊语言值, 具体如下: 航向角误差变化率: $\{NB, NM, NS, O, PS, PM, PB\}$;

航向角误差: $\{lb, lm, ls, zo, rs, rm, rb\}$;

输出转向角: $\{lb, lm, ls, zo, rs, rm, rb\}$ 。

其中 NB 代表正大, NM 表示正中, NS 代表正小, O 表示零, PS 、 PM 、 PB 分别表示负小、负中、负大; lb 代表左大, lm 表示左中, ls 代表左小, zo 表示零, rs 、 rm 、 rb 分别表示右小、右中、右大^[19]。采用的隶属度函数为三角形函数, 具体如下:

$$\eta_r(\vartheta) = \begin{cases} \frac{\vartheta - A}{B - A}, & \vartheta \geq A \& \vartheta \leq B \\ \frac{\vartheta - C}{B - C}, & \vartheta > B \& \vartheta \leq C \\ 0, & \text{else} \end{cases} \quad (13)$$

式中, $\eta_r(\vartheta)$ 代表各输入输出元素 ϑ 属于角度集合 F 的对应隶属度; A 、 B 、 C 是指各输入输出元素 ϑ 在角度集合 F 中的三角形分界点, 分别为左顶点、底边中点与右顶点。在航向角误差变化率与航向角误差这两个输入元素中, 角度集合 F 的取值范围为 $-180^\circ - 180^\circ$; 在输出转向角这个输出元素中, 角度集合 F 的取值范围为 $-40^\circ - 40^\circ$ 。在航向角误差变化率与航向角误差这两个输入元素中,

根据该三角形函数能够计算 3 种元素的交叠系数与模糊集中心点之间的距离, 多次对两个参数实施调节即可实现整个系统的最优化处理。其中交叠系数的计算公式具体如下:

$$\gamma = \frac{C_a - A_b}{C_a - B_a} \quad (14)$$

式中, C_a 指航向角误差变化率与航向角误差的 C 分界点; A_b

指出转向角的 A 分界点; B_a 指的是航向角误差变化率与航向角误差的 B 分界点^[20]。模糊集中心点之间的距离的计算公式具体如下:

$$d_d = B_b - B_a \quad (15)$$

式中, B_b 指的是输出转向角的 B 分界点。根据巡检机器人的运行经验获得该模糊轨迹控制器的模糊规则表, 即航向角误差变化率与航向角误差之间的模糊规则表, 依据模糊规则表求出二者之间的模糊关系。

使用加权平均法即重心法实施二者模糊关系的反模糊处理, 获取一个新的模糊规则表即控制规则表, 将控制规则表制成一个矩阵, 将其存储在计算机内存中。在巡检机器人的轨迹自动控制中, 以模糊规则表为依据, 在控制规则中至二级查找获得控制量的变化值, 将该变化值直接与比例因子相乘即可作为输出对巡检机器人的航向角进行控制, 以此实现巡检机器人避障轨迹自动控制系统设计, 公式为:

$$r = \frac{K\eta_F(\vartheta)}{\gamma d_d} \quad (16)$$

由上述内容可知, 自主避障规划神经网络模型是一种基于深度学习的技术, 用于巡检机器人在三维环境中自主规划路径。模型包括卷积和循环神经网络层, 能够处理大量网络参数和三维空间信息。基于该模型实现的深度学习自动控制系统, 采用均方误差作为损失函数训练, 输出机器人的转向角速度、倾斜角速度和加速度。同时, 模糊轨迹控制器利用模糊逻辑, 根据航向角误差变化率和航向角误差输入, 输出转向角控制量, 实现巡检机器人的自主避障功能。这些组件共同构建了一个全面的自主避障系统, 提高了巡检机器人的安全性和效率。

3 系统性能测试

3.1 实验环境设置

为了提高巡检机器人在实际环境中的安全性和效率, 设计基于深度学习的巡检机器人避障轨迹自动控制系统, 利用其对某地配电网中实际投入使用的巡检机器人实施避障轨迹控制, 测试系统的表现性能。

实验巡检机器人是一种轮式巡检机器人, 由驱动轮机构、随动轮机构、传感器系统、控制系统构成, 投入应用已经有一段时间。具体如图 7 所示。

在实验巡检机器人的日常巡检线路上增设 3 个动态障碍物, 实验场地如图 8 所示。

实验环境具体如表 1 所示。

在实验环境下测试设计系统的表现性能, 并搭建以下计算机环境: 软件: Visual Basic 编程、Windows10 操作系统; 硬件: CPU: Intel 奔腾 6 处理器, 外频 100 MHz, 主频 2.0 GHz, 内存: 512 M DDR。

3.2 实验过程

基于环境图像采集模块采集实验巡检机器人的双目视觉环境图像作为原始实验数据集。



图 7 巡检机器人

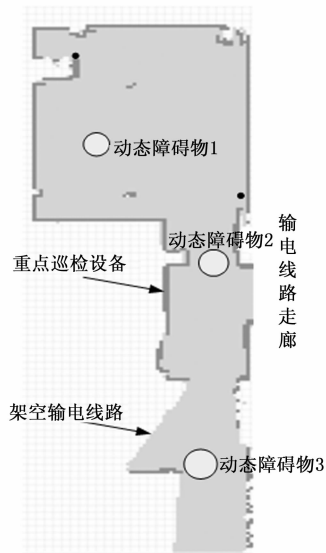


图 8 实验场地

表 1 实验环境

项目	亮实验巡检机器人	亮增设的障碍物 1	亮增设的障碍物 2	亮增设的障碍物 3
初始位置	亮(12 m, 72 m, 262 m)	亮(176 m, 124 m, 260 m)	亮(328 m, 422 m, 295 m)	亮(762 m, 546 m, 254 m)
目标位置	亮(1 892 m, 2 025 m, 2 242 m)	亮一	亮一	亮一
初始纵荡速度	亮 6 kn	亮 6 kn	亮 6 kn	亮 4 kn
初始纵倾角	亮 0°	亮 0°	亮 2°	亮 0°
初始艏向角	亮朝向目标	亮 120°	亮 100°	亮 0
半径	亮 1.5 m	亮 5 m	亮 8 m	亮 6 m

通过采集图像预处理对原始实验数据集实施图像分割、双目目标匹配等预处理, 完成设置的动态障碍物的识别。

采用障碍物空间位置获取摄像头实施双目视觉标定, 标定结果如下:

- 1) 相机的标定焦距 u : 1.58 cm;
- 2) 相机的标定水平视角 α : 23.68°;

3) 相机的标定垂直视角 β : 56.32° 。

并计算同名点深度, 获取 3 个动态障碍物的空间位置三维信息。

利用基于深度学习的自主避障规划方法实施实验巡检机器人的自主避障线路规划。其中在机器人自主避障规划网络模型的训练中, 利用小批量梯度下降反向传播法更新权重, 将批量大小设置为 10^4 , 使用 Adam 优化器实现损失函数的最小化, 并将最大迭代次数设置为 5 200 次。

在训练前, 需要对实验数据集实施以下预处理: 通过线性比例变换法实施数据集的归一化处理, 处理后的输入样本可以用下式来表示:

$$Y'^t = [\epsilon'_g, f'_g, o', \lambda', \Delta j'_{s1}, \Delta j'_{s2}, \Delta j'_{s3}] \quad (17)$$

式中, ϵ'_g 指的是归一化处理后的当前时刻目标方位角数据; λ' 是指归一化后的纵倾角度数据; o' 指的是归一化后的纵荡速度数据; f'_g 是指归一化后的目标相对实验巡检机器人的深度数据; $(\Delta j'_{s1}, \Delta j'_{s2}, \Delta j'_{s3})$ 指的是最终探测结果, 即距离最短的目标三维信息。处理后的样本对可以用下式来表示:

$$\tilde{w}^t = Y'^t [\tilde{q}^{t+1}, \tilde{v}^{t+1}, \tilde{f}^{t+1}] \quad (18)$$

式中, \tilde{w}^t 表示处理后样本对的标签; \tilde{q}^{t+1} 是指下一时刻实验巡检机器人期望的转舵角速度; \tilde{f}^{t+1} 指的是下一时刻实验巡检机器人期望的纵荡加速度; \tilde{v}^{t+1} 是指下一时刻实验巡检机器人期望的纵倾角速度。

训练中训练集的损失函数变化情况如下: 在初始阶段, 收敛速度最快, 随后收敛速度逐渐降低, 在结束训练时函数达到了收敛状态。获取规划的三维自主避障规划路线后, 利用系统的轨迹自动控制方法实现实验巡检机器人动态避障规划路线行走中的轨迹自动控制, 使其按照规划路线行走。

3.3 实验结果分析

设计系统最终的轨迹控制图如图 9 所示。




图 9 最终轨迹控制图

由图 9 可知, 设计系统最终实现了实验巡检机器人的避障轨迹自动控制, 成功避开了 3 个动态障碍物并对走廊中的架空输电线路与重点巡检设备进行了全面地巡检。

3.3.1 轨迹控制误差分析

测试设计系统最终轨迹控制图与规划的三维自主避障规划路线的误差。在测试中, 将基于视觉的工业机器人避障控制系统(文献 [3] 系统)、输电线路巡线机器人避障控制系统(文献 [4] 系统)以及基于机器视觉的机器人仿生机械手避障轨迹控制系统(文献 [5] 系统)作为对比系统, 实施对比测试, 并分别用系统 1、系统 2、系统 3 来表示以上 3 种对比系统, 以达到更加简洁的说明效果。其中, 系统 1 设定的角度论域范围为 $[-30^\circ, 30^\circ]$, 视角范围为 78° ; 系统 2 设置 RTL 电量指标的理想数值为 3.65, 实验时间为 50 min; 系统 3 搭载 LHE118-10 款芯片, 并设置数据传输速度为 156 MHz。最终三维自主避障规划路线的误差测试结果如表 2 所示。

表 2 轨迹控制误差测试结果

巡检路线长度/m	最大轨迹控制误差/ $^\circ$			最小轨迹控制误差/ $^\circ$				
	设计系统	系统 1	系统 2	系统 3	设计系统	系统 1	系统 2	系统 3
5	1.25	3.65	2.69	3.62	0.23	1.03	1.02	1.57
10	1.35	3.67	2.74	3.60	0.24	1.12	1.02	1.65
15	1.39	3.69	2.82	3.64	0.26	1.32	1.02	1.75
20	1.42	3.92	3.20	3.69	0.53	1.47	1.28	1.88
25	1.45	4.52	3.54	4.25	0.58	1.50	1.34	1.95
30	1.45	4.58	3.68	4.50	0.59	1.85	1.35	1.95
35	1.45	5.14	3.60	4.55	0.62	1.94	1.54	1.99

根据表 2 可知, 从最大轨迹控制误差测试结果来看, 设计系统最大轨迹控制误差的最大值为 1.45° , 系统 1、系统 2、系统 3 最大轨迹控制误差的最大值分别为 5.14° 、 3.60° 、 4.55° , 随着巡检路线长度逐渐增加, 系统 1、系统 2、系统 3 的最大轨迹控制误差一直在增加, 同时数值相比设计系统一直较大, 而设计系统的最大值在初始阶段呈现增长的趋势, 在后期却停止增长, 展现了稳定的控制性能。在 3 种对比系统中, 系统 1 的避障轨迹控制性能最差, 最大轨迹控制误差最大, 系统 2 的避障轨迹控制性能最好, 最大轨迹控制误差最小。

从最小轨迹控制误差测试结果来看, 设计系统最小轨迹控制误差的最大值仅为 0.62° , 最小值为 0.23° , 二者之间的差值为 0.39° , 说明随着巡检路线长度逐渐增加, 设计系统最小轨迹控制误差的增幅较低。而系统 1、系统 2、系统 3 最小轨迹控制误差的最大值分别为 1.94° 、 1.54° 、 1.99° , 最小值分别为 1.03° 、 1.02° 、 1.57° , 二者之间的差值分别为 0.91° 、 0.52° 、 0.47° , 说明随着巡检路线长度逐渐增加, 3 种系统最小轨迹控制误差的增幅均大于设计系统。同时, 整体来说, 设计系统的最小轨迹控制误差也是小于 3 种对比系统的, 同样验证了设计系统优异而稳定的避障轨迹控制性能。

3.3.2 动态避障巡检速度分析

为了进一步测试设计的巡检机器人避障轨迹自动控制系统的控制能力,设置4个动态障碍物进行干扰,对比4种系统的动态避障巡检速度,测试结果如图10所示。




图 10 动态避障巡检速度测试结果

由图10可知,在4个动态障碍物的干扰下,设计系统的动态避障巡检速度始终在3.5 m/s左右,同时整体较为稳定,巡检速度降幅较低,而3种对比系统明显降幅较高,说明设计系统在动态避障的同时能够保持较快的巡检速度。

4 结束语

为帮助巡检机器人实现更加智能化与全面化地巡检,设计一种基于深度学习的巡检机器人避障轨迹自动控制系统,通过两部 CCD 相机连接视频采集卡采集巡检机器人的双目视觉环境图像,通过同名点深度计算获取障碍物空间位置三维信息,利用深度学习中的 CRNN 模型实现三维动态环境中的巡检机器人自主避障规划,通过模糊轨迹控制器的设计最终实现了巡检机器人避障中的轨迹自动控制,并通过实验验证了其性能表现与控制精度,取得的研究成果能够帮助巡检机器人实现更加精准地巡检规划与控制。

参考文献:

[1] 赵小勇, 陈钦柱, 郑鸿彦, 等. 基于道路场景理解的巡检机器人避障方法研究与应用 [J]. 微电子学与计算机, 2022, 39 (4): 118-127.

[2] 徐显金, 陈浩达, 胡世超, 等. 风载下高压直流巡检机器人磁力矩平衡方法 [J]. 计算机仿真, 2021, 38 (3): 321-326.

[3] 李娟, 秦伟. 基于视觉的工业机器人避障控制系统设计 [J].

机床与液压, 2021, 49 (15): 24-28.

[4] 李海峰. 输电线路巡检机器人避障控制系统设计 [J]. 电子设计工程, 2021, 29 (14): 116-120.

[5] 张磊, 吴颖. 基于机器视觉的机器人仿生机械手避障轨迹控制系统 [J]. 机械与电子, 2022, 40 (10): 54-58.

[6] 徐伟锋. 煤矿巡检机器人自主导航轨迹纠偏控制研究 [J]. 煤炭技术, 2021, 40 (5): 170-173.

[7] 徐诗洋, 吴炳晖, 纪冬梅, 等. 电力隧道自动巡检机器人设计与运动仿真 [J]. 工程设计学报, 2023, 30 (1): 32-38.

[8] 金梅, 李清天, 张立国. 基于安全 A* (*) 与 DWA 算法融合的军队车场巡检机器人路径规划 [J]. 高技术通讯, 2022, 32 (11): 1202-1212.

[9] 侯正航, 何卫平. 基于数字孪生的飞机装配状态巡检机器人的建模与控制 [J]. 计算机集成制造系统, 2021, 27 (4): 981-989.

[10] 李小彭, 樊星, 李凯, 等. 考虑负载时变的线路巡检机器人动态性能分析 [J]. 东北大学学报 (自然科学版), 2022, 43 (5): 660-666.

[11] 任百峰. 基于 YOLO-V4 的矿用巡检机器人无标定视觉伺服控制系统 [J]. 煤炭技术, 2022, 41 (10): 216-218.

[12] 朱将勇, 李鹏, 李翔, 等. 城市轨道交通车辆智能巡检机器人定位系统 [J]. 铁道运输与经济, 2023, 45 (1): 130-136.

[13] 李二超, 王玉华. 改进人工势场法的移动机器人避障轨迹研究 [J]. 计算机工程与应用, 2022, 58 (6): 296-304.

[14] 张郭, 许艳英, 张亮. 基于动静安全场的机器人避障路径控制仿真研究 [J]. 中国工程机械学报, 2021, 19 (3): 232-237.

[15] 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.

[16] 李小伟. 基于嵌入式的自主行驶采摘机器人避障系统研究 [J]. 农机化研究, 2022, 44 (11): 201-205.

[17] 吴庆, 赵涛, 佃松宜, 等. 基于 FPSO 的电力巡检机器人的广义二型模糊逻辑控制 [J]. 自动化学报, 2022, 48 (6): 1482-1492.

[18] 张玉超, 蒋沅, 代冀阳. 三阶多机器人协同编队动态避障控制 [J]. 系统仿真学报, 2022, 34 (8): 1762-1774.

[19] 马飞越, 刘佳豪, 赵涛, 等. 电力巡检机器人运行姿态的终端滑模控制 [J]. 西南大学学报: 自然科学版, 2021, 43 (12): 172-179.

[20] 侯正航, 何卫平. 基于数字孪生的飞机装配状态巡检机器人的建模与控制 [J]. 计算机集成制造系统, 2021, 27 (4): 981-989.

(上接第 114 页)

[22] 余洪山, 郭丰, 郭林峰, 等. 融合改进 SuperPoint 网络的鲁棒单目视觉惯性 SLAM [J]. 仪器仪表学报, 2021, 42 (1): 116-126.

[23] 丛嘉艺, 李彬, 郭宪振, 等. 面向无人机中继通信平台的混合网络编码算法 [J]. 西安交通大学学报, 2022, 56 (4):

176-184.

[24] 胡诗婷, 刘小兰, 张文倩, 等. 基于监督机器学习的车载协作通信中继选择 [J]. 计算机应用, 2021, 41 (z1): 167-174.

[25] 周宸宇, 冯成, 王毅. 基于移动用户接入控制的 5G 通信基站需求响应 [J]. 中国电机工程学报, 2021, 41 (16): 5452-5461.