

DOI:10.19344/j.cnki.issn1671-5276.2026.02.021

# 基于改进 YOLOv8 关键点检测的托盘位姿估计方法研究

孙鹏<sup>1,2</sup>, 连明昌<sup>2,3</sup>, 丁伟<sup>2,3</sup>, 陈松航<sup>2,3</sup>, 陈豪<sup>2,3,4</sup>

(1. 福州大学 先进制造学院, 福建 泉州 362251;

2. 中国科学院 海西研究院泉州装备制造研究中心, 福建 泉州 362216;

3. 福建省复杂动态系统智能辨识与控制重点实验室, 福建 泉州 362200;

4. 中国科学院 福建物质结构研究所, 福建 福州 350108)

**摘要:** 无人叉车的主要工作为叉取承载货物的托盘, 如何拾取因人工干预或设备精度误差导致位姿偏移的托盘是无人叉车作业中需要攻克的难点。提出一种基于改进 YOLOv8 以及 EPnP 算法相结合的托盘位姿估计方法, 使用 YOLOv8 进行 EPnP 算法所需的关键点提取, 通过在骨干网络上添加注意力模块(Shuffle), 并使用 Hungarian 改进损失函数提高托盘角点的定位精度。在获取到托盘的关键点后, 根据托盘先验信息使用 EPnP 算法计算出相机与托盘的相对位姿, 以此得到托盘与车体的相对距离以及托盘相对于无人叉车的偏转角度, 得到的托盘航向角偏差低于 5°, 同时深度距离信息误差小于 8 cm 以及左右误差小于 4 cm, 能够满足无人叉车进行托盘的叉取。

**关键词:** 无人叉车; 托盘识别; 位姿估计; 单目视觉; YOLOv8; EPnP; Hungarian 损失函数; Shuffle 注意力机制

**中图分类号:** TP391.4    **文献标志码:** A    **文章编号:** 1671-5276(2026)02-0108-06

## Reserch on Pallet Pose Estimation Based on Improved YOLOv8 Keypoints Detection

SUN Peng<sup>1,2</sup>, LIAN Mingchang<sup>2,3</sup>, DING Wei<sup>2,3</sup>, CHEN Songhang<sup>2,3</sup>, CHEN Hao<sup>2,3,4</sup>

(1. College of Advanced Manufacturing, Fuzhou University, Quanzhou 362251, China;

2. Quanzhou Institute of Equipment Manufacturing Haixi Institutes, Chinese Academy of Sciences, Quanzhou 362216, China;

3. Fujian Provincial Key Laboratory of Intelligent Identification and Control of Complex Dynamic System, Quanzhou 362200, China;

4. Fujian Institute of Research on the Structure of Matter, Chinese Academy of Sciences, Fuzhou 350108, China)

**Abstract:** The primary task of an unmanned forklift is to lift pallets, and how to pick up displaced pallets caused by manual intervention or equipment precision errors is a big hurdle in unmanned forklift operation. This article proposes a method for pallet pose estimation based on combination of improved YOLOv8 and EPnP algorithms. YOLOv8 is employed for keypoint extraction required by the EPnP algorithm. The method enhances the backbone network by incorporating an attention module (Shuffle) and utilizes a Hungarian loss function to enhance the localization accuracy of pallet corners. Upon obtaining the pallet's key points, the EPnP algorithm is utilized based on prior information to compute the relative pose between the camera and the pallet, thereby the relative distance between the pallet and the forklift as well as the pallet's deviation angle concerning the unmanned forklift is obtained. The pallet heading angle deviation is below 5°, the depth distance information error less than 8 cm and the lateral error less than 4 cm, which enable the unmanned forklift to operate pallet picking-up.

**Keywords:** unmanned forklift; pallet recognition; pose estimation; monocular vision; YOLOv8; EPnP; Hungarian loss; Shuffle Attention

## 0 引言

目前, 随着移动机器人的不断普及, 智能物流也逐渐走向自动化及智能化, 智能物流要求生产物流高效配送与生产的各个环节自动化无缝对接。为了构建现代工厂智慧物流系统, 提高物流搬运效率, 无

人叉车获得越来越多的关注<sup>[1]</sup>。在生产物流配送中, 无人叉车的主要任务为叉取承载货物的托盘。但是, 在日常的生产作业过程中, 托盘会因人工干预和设备精度误差导致位姿偏移, 这极大地影响了无人叉车工作效率以及推广使用。因此, 如何获取托盘因操作偏移的位姿成为了研究重点<sup>[2]</sup>。

**基金项目:** 福建省科技计划项目-中央引导地方发展专项(2021L3047); 福建省科技计划项目(2023T3030)

**第一作者简介:** 孙鹏(1999—), 男, 福建福州人, 硕士研究生, 研究方向为机器视觉、智能物流, 1439725073@qq.com。

**通信作者简介:** 陈豪(1984—), 男, 湖南邵阳人, 研究员, 博导, 博士, 研究方向为工业大数据、人工智能, chen hao@fjirsm.ac.cn。

托盘位姿检测方法主要分为基于图像处理以及基于深度学习的方法。图像处理的方法主要是通过获取特征点信息,通过 SIFT (scale invariant feature transform)、SURF (speeded up robust features) 完成特征点匹配确立特征点二维—三维对应关系,后续通过  $n$  点透视 (perspective— $n$ —points, PnP) 问题来完成相机相对位姿参数的计算。但是该方法需要人工进行二维与三维对应点的匹配,同时只能针对单一托盘进行位姿匹配,无法进行多个托盘位姿估计。

近年来随着深度学习的不断发展,深度学习算法在计算机视觉、图像处理等领域得到广泛应用<sup>[3]</sup>。基于深度学习的方法主要是通过回归的方式来分割图像内托盘并进行计算。但是只能得到分割图像,无法获取确切的点位信息以及托盘的深度信息和偏转角度<sup>[4]</sup>。针对传统方法在托盘特征点提取泛化能力不足以及基于深度学习的算法无法获取托盘确切位姿的问题<sup>[5]</sup>,本文提出一种基于改进 YOLOv8 关键点检测的托盘位姿计算方法。为获得托盘的位姿状态信息,需要进行托盘 6D 位姿估计,为更好地适应实际情况,本文将托盘位姿估计转化为求解相机相对位姿。在特征提取方面通过 YOLOv8 单阶段目标检测模型进行托盘 8 个角点的关键点提取,建立二维—三维的对应关系,通过 EPnP (efficient—perspective— $n$ —point) 算法完成相机相对位姿的计算。

## 1 托盘单目视觉估计原理

托盘位姿主要包括托盘与无人叉车的相对距离以及托盘相对于无人叉车的偏转角度,本文采用的单目视觉位姿测量方法是通过 EPnP 算法获取相机的相对位姿。EPnP 算法所需二维、三维关键点是结合托盘先验信息与 YOLOv8 单阶段目标检测模型检测到的托盘关键点信息进行二维、三维对应点匹配来完成。

### 1.1 YOLOv8 目标检测算法

YOLOv8 提供两种分辨率的目标检测网络 (P5 640 和 P6 1280) 以及基于 YOLACT 的实例分割模型,同时为满足不同场景的应用需求,YOLOv8 也提供 N/S/M/L/X 等拥有不同缩放系数的网络模型。YOLOv8 主要网络结构为输入端 Input,主干网络 Backbone,检测头 Neck&Head 以及损失函数 4 个部分。损失函数模块仅仅预测分类和回归<sup>[6]</sup>。

### 1) 主干网络改进

由于需要对托盘角点进行检测,主要针对的是托盘边缘进行检测,而空间注意力机制对于边缘的特征检测能够取得较好的效果。Shuffle 注意力机制按照通道维度分组为子特征,然后进行并行处理,对于每个子特征 SA 利用 Shuffle Units 描述空间和通道维度上的特征依赖关系<sup>[7]</sup>。然后对所有子特征进行聚合,利用 channel shuffle 算子实现不同子特征间的信息通信<sup>[8]</sup>。Shuffle 注意力机制结构如图 1 所示。




图 1 Shuffle 注意力机制结构示意图

Shuffle Attention 在引入通道注意力机制时为了更加轻量化,提出使用全局平均池化 (GAP) 嵌入全局信息,生成通道统计数据<sup>[9]</sup>,即  $s \in R^{C \times 1 \times 1}$ ,如式(1)所示:

$$s = F_{sp}(X_{k1}) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{k1}(i, j) \quad (1)$$

然后,通过一个门控机制与 sigmoid 激活函数,生成紧凑特征,如式(2)所示<sup>[10]</sup>:

$$X'_{k1} = \sigma(F_c(s)) \cdot X_{k1} = \sigma(W_1 s + b_1) \cdot X_{k1} \quad (2)$$

式中  $W_1, b_1 \in R^{C \times 1 \times 1}$ ,用于缩放和移动参数。空间注意力与通道注意力互补,因此使用  $X_{k2}$  通过组归一化 GN 获得空间统计数据,然后采用  $F_g(\cdot)$  增强  $X_{k2}$ ,空间注意的最终输出如式(3)所示:

$$X'_{k2} = \sigma(W_2 \cdot GN(X_{k2}) + b_2) \cdot X_{k2} \quad (3)$$

式中:  $W_2, b_2 \in R^{C \times 1 \times 1}$ ,然后将两个分支连接,使得通道数等于输入数,即  $X'_k = [X'_{k1}, X'_{k2}] \in R^{C \times H \times W}$ 。

### 2) 损失函数改进

最后在损失函数部分,YOLOv8 的损失主要包括 3 大部分:类别损失、位置损失和关键点损失。YOLOv8 的关键点损失采用欧氏距离来进行计算,为更好实现关键点检测以及位姿估计,本文将关键点表述为一个集合预测问题<sup>[11]</sup>。为便于比较真实集和预测集,本文使用二分法来寻找预测元素的排列。本文采用 Hungarian 损失函数对关键点损失函数进行改进,如式(4)所示<sup>[12]</sup>:

$$L_{\text{keypoints}}(K_i, \hat{K}_{\sigma(i)}) = \gamma \|K_i - \hat{K}_{\sigma(i)}\|_1 + \delta L_{CR} \quad (4)$$

式中:  $K_i$  为关键点真实值;  $\hat{K}_{g(i)}$  为模型输出的关键点预测值;  $\gamma$  和  $\delta$  为超参数; 第 1 部分为  $l_1$  损失函数; 第 2 部分为  $L_{CR}$  融合交比来实现关键点检测中交比一致性, 如式 (5) 所示<sup>[13]</sup>:

$$L_{CR} = \text{Smooth}l_1 \left( CR^2 - \frac{\|c-a\|^2 \|d-b\|^2}{\|c-b\|^2 \|d-a\|^2} \right) \quad (5)$$

$$\text{Smooth}l_1(x) = \begin{cases} 0.5x^2/\beta, & |x| < \beta \\ |x| - 0.5\beta, & |x| \geq \beta \end{cases} \quad (6)$$

式中  $\beta$  通常为 1。

这种损失是通过保持每条线的交叉比为 4/3 来自我监督的。原因是三维边界框在图像平面上的摄像机投影后, 每 4 个共线点的交叉比保持不变。给定 4 个共线点  $A, B, C, D$  及其预测的二维投影  $a, b, c, d$ , 将地面真交比  $CR$  定义为式 (7) 所示<sup>[14]</sup>:

$$CR = \frac{\|C-A\| \|D-B\|}{\|C-B\| \|D-A\|} = \frac{4}{3} \quad (7)$$

改进后 YOLOv8 模型结构如图 2 所示。




图 2 改进后的 YOLOv8-pose 模型结构示意图

## 1.2 EPnP 位姿估计算法

### 1) PnP 问题转换

在获取到托盘规格参数之后, 托盘的位姿估计问题可以近似转换为一个 PnP 问题。PnP 问题可以利用  $n$  个空间点的三维坐标以及和它们对应的二维图像坐标, 计算出世界坐标系和相机坐标系的相对位姿关系<sup>[15]</sup>。

本文采用的 EPnP 算法是由 LEPETIE 和 MOREN 在 2009 年提出的高精度快速位姿估计算法被认为是目前最高效的相机位姿估计算法之一<sup>[16]</sup>。该算法无需迭代求解, 时间复杂度为  $O(n)$ , 抗干扰能力强, 在共面的情况下只需要 3 对 3D-2D 匹配点, 非共面的情况下需要 4 对匹配点来得到精确的位姿<sup>[17]</sup>。

### 2) EPnP 算法原理

EPnP 算法原理是利用 4 个虚拟控制点线性加权的表示托盘上的点位在相机坐标系中的坐标<sup>[18]</sup>, 具体详见图 3。




图 3 EPnP 算法图解示意图

图 3 中设托盘中  $n$  个特征点的世界坐标为  $P_i^w (i=1, 2, 3, \dots, n)$ , 对应相机坐标系坐标为  $P_i^c (i=1, 2, 3, \dots, n)$ ; 并设置 4 个控制点的世界坐标  $C_j^w (j=1, 2, 3, 4)$ , 其对应相机坐标系坐标为  $C_j^c (j=1, 2, 3, 4)$ , 则如式 (8) 所示<sup>[19]</sup>。

$$\begin{cases} P_i^w = \sum_{j=1}^4 a_{ij} C_j^w & (i=1, 2, 3, \dots, n) \\ P_i^c = \sum_{j=1}^4 a_{ij} C_j^c & (i=1, 2, 3, \dots, n) \end{cases} \quad (8)$$

式中: 每个标志点对应 4 个加权系数  $a_{ij} (j=1, 2, 3, 4)$ , 且和为 1。设  $P_i^w = (x_i^w, y_i^w, z_i^w)$  对应像素坐标为  $(u_i, v_i)$ , 就能得到托盘特征点  $P_i^w$  在以虚拟控制点  $C_j^w = (x_j^w, y_j^w, z_j^w) (j=1, 2, 3, 4)$  为基的欧氏空间中的坐标, 第  $j (j=1, 2, 3, 4)$  个虚拟控制点  $C_j^c$  的相机坐标系坐标为  $(x_j^c, y_j^c, z_j^c)$ , 结合像素坐标与相机坐标转化关系根据相机坐标系下的特征点以及像素点之间的对应关系如式 (9) 所示:

$$\begin{cases} \sum_{j=1}^4 a_{ij} f_x x_j^c + (u_x - u_i) z_j^c = 0 \\ \sum_{j=1}^4 a_{ij} f_y y_j^c + (v_y - v_i) z_j^c = 0 \end{cases} \quad (9)$$

当有  $n$  对空间参考点与像素坐标点对应时, 可得  $2n$  个方程。通常选择 1~4 组零特征值对应的特征向量来求解方程。进而转化为绝对定位问题来获得相机的位姿参数<sup>[20]</sup>。

## 2 实验

为了验证本文算法的可行性, 需要进行基于 YOLOv8 的托盘关键点检测和 EPnP 位姿估计算法的准确性的实验验证。

## 2.1 消融实验

为了验证改进后的 YOLOv8 模型的合理性,开展消融实验,通过在 YOLOv8 原有模型基础上增加 Shuffle 注意力机制以及损失函数得改进,来验证每个改进点是否有效,消融实验如表 1 所示,其中“√”表示在模型中运用改模块,“—”表示未在模型中使用该模块<sup>[21]</sup>。

表 1 改进模块消融实验检测精度

| Shuffle<br>e | Hungarian<br>n | 准确率<br>P/% | 召回率<br>R/% | 平均精度均<br>值 mAP50/% |
|--------------|----------------|------------|------------|--------------------|
| —            | —              | 80.3       | 79.3       | 75.3               |
| √            | —              | 82.8       | 82.6       | 77.6               |
| —            | √              | 81.0       | 81.1       | 75.7               |
| √            | √              | 83.3       | 83.0       | 79.0               |

从表 1 中可以看出,单独引入 Shuffle 注意力机制时,准确率提高 2.5 个百分点,召回率提高 2.3 个百分点,平均精度上升 2.3 个百分点,但是当单独引入 Hungarian 损失函数时 YOLOV8-pose 模型的准确率,召回率以及平均精度均值提升较小。分析认为 Shuffle 注意力机制通过空间注意力机制提高模型对托盘边缘的检测精度,使得效果提升明显,而 Hungarian 损失函数使得预测框更加快

速地收敛,并且得到更高的回归定位精度,因此提升幅度小。

## 2.2 不同种类托盘检测精度实验

YOLOv8 检测模型在进行关键点检测之前,会先进行托盘的分类,这样能够缩小后续关键点检测范围,同时提高关键点的检测精度。如图 4 所示,本文的实现方法在进行关键点检测时会对角点进行分类,不同位置的角点在图像上会对应不同的颜色的点,无需再进行人工匹配。(本刊为黑白印刷,相关疑问请咨询作者)




图 4 托盘关键点提取,角点按颜色进行分类,顺时针开始上方角点角点

本文改进的网络模型与原模型对不同托盘的检测精度如表 2 所示。

表 2 不同种类托盘的检测精度

单位: %

| 托盘类别 | YOLOv8-pose |      |        | 本文改进的模型 |      |        |
|------|-------------|------|--------|---------|------|--------|
|      | 准确率         | 召回率  | mAP 50 | 准确率     | 召回率  | mAP 50 |
| 木制   | 82.3        | 78.8 | 75.9   | 84.2    | 82.7 | 78     |
| 塑料 1 | 88.5        | 88.6 | 88.7   | 93.1    | 93.2 | 90.3   |
| 塑料 2 | 79.6        | 80.2 | 70.8   | 81.2    | 81.3 | 75.4   |

## 2.3 关键点检测误差精度实验

本次实验通过检测托盘的 8 个角点来进行位姿估计,定义检测角点与托盘的真实像素角点的欧式距离为绝对误差( $E_A$ ),检测的绝对误差与像素点到原点的距离的比值为相对误差( $E_R$ )。

$E_A$  如式(10)所示:

$$E_A = \sum_{i=1}^n \sqrt{(x'_i - x_i)^2 + (y'_i - y_i)^2} \quad (10)$$

式中第  $i$  个角点的检测坐标为  $(x'_i, y'_i)$ , 第  $i$  个角点的真实像素坐标为  $(x_i, y_i)$ 。

$E_R$  如式(11)所示:

$$E_R = (E_A/d) \times 100\% \quad (11)$$

式中  $d$  表示像素点到原点的距离。

实验误差如表 3 所示。

表 3 关键点检测误差精度

| 类别       | 点 1       | 点 2       | 点 3       | 点 4       | $E_A$ | $E_R$ |
|----------|-----------|-----------|-----------|-----------|-------|-------|
| 真实值      | (362,308) | (357,665) | (395,612) | (397,337) | —     | —     |
| YOLOv8-s | (359,312) | (365,669) | (390,618) | (390,340) | 7.32  | 1.17  |
| 本文方法     | (356,308) | (362,665) | (388,615) | (392,336) | 5.92  | 0.95  |

## 2.4 EPnP 位姿检测精度实验

PnP 算法的位姿检测精度实验,以物体放置在 150 cm、200 cm、250 cm、300 cm、350 cm、400 cm 距离情况下,每个距离拍摄 10 幅图片,计算 10 次深度估计的均值并与真实值进行比较。

深度距离检测的精度主要取决于角点检测的误差,因此在近距离时托盘图像较大,角点的偏差值较大,会导致深度误差增加。因为在日常的生产作业中,无人叉车的叉臂长度一般情况下不会少于 1 m,而在叉取托盘前进行托盘位姿估计时,无人叉车叉臂不能触碰到托盘,因此从 1.5 m 开始进行增加。

为了更好地描述托盘相对于无人叉车的位姿状态,采用欧拉角的方式来表示托盘旋转的状态,绕  $x$  轴、 $y$  轴、 $z$  轴旋转分别是滚转角、仰俯角以及偏航角。托盘在日常生产中是平放在地面上且托盘本身可以近似为一个长方体,所以托盘相对于无人叉车的滚转角以及仰俯角都为  $0^\circ$ ,只需要考虑托盘的偏航角即可。所以在进行实验时增加一定的托盘旋转角度为  $10^\circ$ 、 $20^\circ$ 、 $30^\circ$ 。

位姿估计检测精度见表 4。

表 4 位姿估计检测精度

| 实验 | 深度<br>距离/<br>cm | 本文方法<br>估计<br>距离/cm | 左右<br>距离/<br>cm | 本文方法<br>估计左右<br>距离/cm | 偏航<br>角/<br>( $^\circ$ ) | 实验<br>角度/<br>( $^\circ$ ) |
|----|-----------------|---------------------|-----------------|-----------------------|--------------------------|---------------------------|
| 1  | 150             | 158.656             | 85              | 81.729                | -10                      | -13.54                    |
| 2  | 200             | 206.308             | 82              | 79.859                | -20                      | -22.53                    |
| 3  | 250             | 255.498             | 86              | 83.955                | -30                      | -31.80                    |
| 4  | 300             | 295.888             | 87              | 84.979                | 10                       | 11.20                     |
| 5  | 350             | 354.839             | 87              | 89.532                | 20                       | 20.73                     |
| 6  | 400             | 405.856             | 89              | 92.815                | 30                       | 31.09                     |

由表 4 可看出,托盘在 6 个不同距离的情况下偏航角的误差都保持  $3^\circ$  以下,同时随着距离的拉远精度会有明显提高,但是随着距离的不断提高精度又会有所下降。深度距离的估计误差基本保持在 8 cm 以内,左右偏差距离基本保持在 4 cm 以内,基本都是随着距离的远离,关键点提取的像素点偏差变小而提高了检测距离的精度。

## 2.5 无人叉车托盘拾取实验

为了方便叉车叉取,托盘孔会预留一定的空间,而且在日常作业中托盘的偏转角度不会超过  $20^\circ$ 。为了进一步验证在叉车情况下能否进行托

盘位姿识别,将相机安装在无人叉车前方挡板上,进行托盘位姿识别。结果发现能够满足无人叉车日常的托盘位姿检测要求。

## 3 结语

本文提出一种改进的 YOLOv8 关键点检测算法,在识别托盘的角点时相对于原有的关键点检测模型在准确率、召回率、平均精度均值上分别有 3%、3.7%、3.7% 的提升。同时提出一种新的托盘位姿估计方法,因为相机固定安装在无人叉车上,所以将无人叉车与托盘的相对位姿转化为相机与托盘的相对位姿,通过 EPnP 算法计算出相机的相对位姿。本文方法相对于传统的关键点匹配方法能够进行多个托盘的识别,同时能够完成对不同型号托盘的检测,模型泛化性更好。对比基于深度学习的方法能够获取托盘的偏转角度以及深度信息,本文方法所获取的托盘位姿能够满足无人叉车进行托盘的叉取。

## 参考文献:

- [1] 王超. 无人叉车系统关键技术研究[D]. 浙江:浙江大学,2022.
- [2] ZHENG Y Q, KUANG Y B, SUGIMOTO S, et al. Revisiting the PnP problem: A fast, general and optimal solution[C]//2013 IEEE International Conference on Computer Vision. Sydney, NSW, Australia. IEEE, 2013: 2344-2351.
- [3] 赵天裔. 基于深度相机的托盘识别和定位系统设计[D]. 成都:电子科技大学,2023.
- [4] 詹燕,陈志慧,朱宝昌,等. 基于自适应颜色快速点特征直方图的托盘识别方法[J]. 上海交通大学学报, 2023, 57(3): 297-308.
- [5] 肖施睿,刁云峰,程文明,等. 基于 YOLOv5 的物流托盘实时检测方法研究[J]. 制造业自动化, 2023, 45(2): 17-21.
- [6] El Kaid A, Baïna K. A systematic review of recent deep learning approaches for 3D human pose estimation[J]. Journal of Imaging, 2023, 9(12): 275.
- [7] MANURUNG P, RUSMIN P H, YUSUF R. Custom pallet detection using YOLOv5 deep learning architecture[C]//2022 International Symposium on Electronics and Smart Devices (ISESD). Bandung, Indonesia. IEEE, 2022: 1-6.
- [8] 贾威,迟书凯,葛宪威. 基于单目视觉的水下目标检测与位姿估计[J]. 海洋技术学报, 2022, 41(3): 43-55.
- [9] 马斌,彭光宇. 基于单目视觉的钻杆位姿识别技术研究[J]. 煤田地质与勘探, 2022, 50(10): 171-178.
- [10] 张俊宁,毕泽洋,闫英,等. 基于注意力机制与改进 YOLO 的温室番茄快速识别[J]. 农业机械学报,

- 收稿日期: 2024-01-22

\_\_\_\_\_

- [8] 柳贵福. 光学陀螺输入输出特性建模及补偿技术研究[D]. 哈尔滨:哈尔滨工程大学,2002.
- [9] 魏代芹. 转台控制系统设计与实现及基于神经网络的参数优化[D]. 哈尔滨:哈尔滨工业大学,2017.
- [10] 王清源,王晓燕,张晓明,等. 基于转台实验的 MEMS 陀螺仪自动化标定软件设计[J]. 舰船电子工程, 2024,44(6):53-56.
- [11] KOKUYAMA W, WATANABE T, NOZATO H, et al. Angular velocity calibration system with a self-calibratable rotary encoder [J]. Measurement, 2016, 82:246-253.
- [12] FENG Y, XU Q J. Application of PID control algorithm based on improved BP neural network to turntable system [J]. Advanced Materials Research, 2012, 490/491/492/493/494/495:191-194.
- [13] JUNG J W, LEU V Q, DO T D, et al. Adaptive PID speed control design for permanent magnet synchronous motor drives [J]. IEEE Transactions on Power Electronics, 2015, 30(2):900-908.
- [14] 李醇铎. 三轴电控转台的自适应控制[D]. 哈尔滨:哈尔滨工业大学,2006.

- 收稿日期:2024-02-01