

基于 Transformer-LSTM 的路径跟踪控制策略设计

赵 珺^{1,2}

(1. 西安欧亚学院 信息工程学院, 西安 710065;

2. 西北工业大学 计算机学院, 西安 710072)

摘要: 针对现有可移动机器人路径跟踪控制算法存在的效率低、精度差、易出现路径偏差等问题, 设计了一种基于 transformer 注意力机制网络的跟踪算法; 先在可移动机器人前端位置部署双目视觉系统实时采集图像, 在自注意力机制基础上构建 transformer 训练模型, 并在模型的编码器和解码器中引入了 LSTM 结构以提升模型的二维图像数据训练能力; transformer 网络中的计算资源权重分配会影响到模型复杂程度, 为此引入了 CS 群智能优化算法与 transformer 相结合, 在全局范围内寻找最佳的权重分配参数, 通过自适应步长的调整不断修正学习率, 以实现更精确的可移动机器人路径跟踪; 10 组测试实验的结果显示: 提出算法完成路径跟踪任务的平均耗时仅为 9.2 s, 采样点的路径偏差方差为 0.015, 优于现有的机器人路径跟踪算法。

关键词: transformer; 注意力机制; 编码器; 解码器; 自适应步长

Design of Path Tracking Control Strategies Based on Transformer-LSTM

ZHAO Jun^{1,2}

(1. School of Information Engineering, Xi'an Eurasia University, Xi'an 710065, China;

2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Aiming at issues such as low efficiency, poor accuracy and path deviation in existing path tracking control algorithms for mobile robots, a tracking algorithm based on the transformer attention mechanism network (ACN) is designed. Firstly, a binocular vision system is deployed at the front end of the mobile robot to collect images in real time, a transformer training model based on a self-attention mechanism is constructed, and a long short-term memory (LSTM) structure is introduced into the model's encoder and decoder to improve its two-dimensional image data training ability. The weight allocation of computing resources in the transformer network will determine the complexity of the model. Therefore, the CS group intelligent optimization algorithm is combined with the transformer to find the best weight allocation parameters in the global scope, and constantly modify the learning rate by adjusting the adaptive step size, enabling more accurate path tracking for mobile robots. Experimental results from 10 groups show that the proposed algorithm only requires an average time of 9.2 s for the path tracking, with a path deviation variance of 0.015 at the sampling point, which is better than the existing robot path tracking algorithm.

Keywords: transformer; attention mechanism; encoder; decoder; adaptive step size

0 引言

伴随着计算机科学技术、自动化控制技术、人工智能技术、无线通信技术等多类技术同步发展, 可移动机器人已经被广泛地应用到工业生产线上、物流仓储与运输管理、各类服务业、野外救援等诸多领域^[1-4]。近些年, 人工智能和机器学习领域的研究不断获得突破^[5], 因此

基于计算机视觉的移动机器人路径跟踪与控制受到越来越多的关注^[6-7]。在机器人的运动过程中, 通过实时采集前进路径上的视觉图像信息, 并对图像进行实时处理和判断, 以实现路径上避障及最优路径的选择^[8]。通过视觉图像采集、处理和分析来实现对机器人路径跟踪方法, 相对于基于位移传感器、GPS、激光传感器等方法, 具有较为明显的优势, 因为通过视觉图像获取到的

收稿日期:2025-07-03; 修回日期:2025-09-08。

作者简介:赵珺(1984-),女,硕士,副教授。

引用格式:赵珺. 基于 Transformer-LSTM 的路径跟踪控制策略设计[J]. 计算机测量与控制, 2026, 34(7):99-107.

信息更加真实、完整、直观和具体,因此有助于实现对机器人行进路径偏差的高精度控制。但视觉图像数据集的处理难度较大,依赖于更强大的软硬件和机器学习控制算法^[9]。基于计算机视觉的机器人路径跟踪技术,依赖于计算机视觉技术、定位导航技术、数字图像实时采集、分割、融合处理和特征提取能力,同时对于各种硬件设备也有较高的要求。国外关于基于计算机视觉的机器人控制与路径跟踪控制系统或控制算法的研究起步较早,例如,美国斯坦福大学在 20 世纪 80 年代已经开始了关于立体视觉的机器人控制,但此时的机器人视觉图像控制仍需要结合传感器辅助,以便于实现最新计算机视觉研究成果开发和应用,计算机视觉技术的引入使 2D 图像能够完成向 3D 场景重建和转换。国内关于机器人视觉控制研究的起步较晚但发展较快,尤其是近些年我国机器人控制研究领域发展迅速,取得多项科研成果而且受到了来自于世界各国的关注。

现有国内外关于机器人视觉控制与路径跟踪的相关研究,主要集中于双目立体视觉图像采集并辅助深度神经网络图像处理。例如,文献 [10] 提出一种基于径向基神经网络的图像处理技术,径向基神经网络是一种具有强映射能力的深度神经网络,其结构较为简洁运算复杂度低且训练能力较强,能够实时处理机器人采集到的图像信息。径向基网络是一种使用径向基函数作为激活函数的人工神经网络,径向基函数网络的输出是输入的径向基函数和神经元参数的线性组合,并通过梯度下降来对网络中的 3 种参数都进行监督训练优化。代价函数是网络输出和期望输出的均方误差。但基于径向基网络的路径跟踪算法受限于模型的结构和图像处理能力,很难应对较为复杂和较大规模的图像集,进而对移动机器人的运行速度和效率均造成影响;文献 [11] 提出一种基于 CNN (卷积神经网络) 的可移动机器人路径跟踪与控制算法。CNN 在海量图像数据集处理方面具有较为明显的优势,能够实现对机器人前进路径图像的实时采集和处理。CNN 网络的结构包括输入层、卷积层、池化层和全连接层的层级结构,通过数据训练自适应提取输入数据的局部特征,并同步压缩信息,减少冗余数据对特征结果的影响,池化层科研提升泛化能力。相比传统的全连接网络,CNN 在处理高维数据时具有更少的参数和更强的表现力,既可用于监督学习,也可用于非监督学习。但 CNN 只能通过增加模型复杂度的方式来应对大规模数据集,当模型结构复杂到一定程度时 CNN 网络隐含层会出现明显的性能衰减和梯度问题,显著影响到对可移动机器人的路径跟踪与控制的精度;文献 [12] 提出一种基于视觉 SLAM 的机器人路径跟踪算法,视觉 SLAM 算法是当前计算机视觉技术和图像视频处理技术的高速发展的结果。目前,视觉 SLAM

已经从单目视觉发展到了双目视觉阶段,视觉图像在特征采集和提取方面具有较大的优势,但视觉 SLAM 算法的硬件匹配度较高,但数据处理的环节较为冗长且复杂度高,包括数据集建模、后端优化、回环检测等,导致对可移动机器人控制与跟踪检测效率较低,代价较高。

针对现有与视觉和传感器控制相关可移动机器人路径跟踪各个算法存在的不足,本文设计了一种基于 transformer 注意力机制网络的控制方案。transformer 网络是一种基于自注意力机制的人工智能算法,具有强大的图像处理能力和二维图像数据分析能力,本文设计的 transformer 注意力机制网络编码器和解码器中引入了 LSTM (长短时记忆) 模块结构,相对于传统的前馈型神经网络模块,具有更强的图像数据训练能力和特征提取能力,且能够实现更精确的赋权。在注意力机制权重分配方面,本文融合了 CS (布谷鸟) 优化算法和可自适应调整步长设计,进一步提升了 transformer 模型的全局寻优能力和图像数据实时处理能力,强化对可移动机器人的控制并实现更精确的路径跟踪。本文的主要贡献在于将 Transformer 与 LSTM 结合以解决梯度问题,并通过 CS 优化算法实现全局参数寻优,进而有效降低了机器人运动中的路径跟踪偏差

1 基于 Transformer 注意力网络视觉—运动学耦合建模

基于计算机双目视觉的机器人路径跟踪^[13-14],相对于传统的 GPS 跟踪或传感器跟踪在路径跟踪精度控制方面具有较为明显的优势,因为通过图像采集和处理获取到的现场路径数据更加直观和精确,有助于更好地实现路径修正、纠偏和障碍物躲避。基于双目视觉和 transformer 注意力机制网络模型的机器人路径跟踪算法技术路径如图 1 所示。

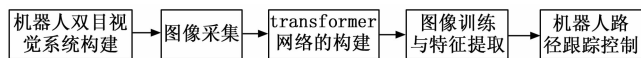


图 1 本文计算路径跟踪算法的总体技术路径

1.1 双目视觉的位姿估计与运动学基础

本文构建了机器人路径跟踪 transformer 注意力机制网络模型,是要通过 transformer 注意力机制网络强大的图像分析处理能力和无监督学习能力^[15],以更快捷地实现在线处理可移动机器人的相关图像数据。基于双目视觉的图像采集系统实时提取机器人运行路径上的相关信息,并将形成的二维图像数据集输入 transformer 注意力机制网络模型训练,根据实际输出结果与期望之间的偏差实时调整机器人的行进路径。在世界坐标系 XOY 下,以机器人重心为坐标原点观测基于 Transformer 注意力机制网络机器人的路径跟踪过程,如图 2

所示。




图 2 可移动机器人的路径跟踪平面坐标图

图 2 中六轮式可移动机器人的重心为 O' ，可移动机器人的航向角为 α ，轴距为 d ，机器人的转弯半径为 R ，当前 t 时刻的行进速度为 v_t ，此刻转向角速度 ω_t 表示如下：

$$\omega_t = \frac{v_t}{R} \tag{1}$$

由于可移动机器人前轮转向，定义两排后轮的虚拟转向角为 θ_1 和 θ_2 ，则可移动机器人的转弯半径为 R 和轴距 d 之间的关系可以表示如下：

$$d = R\{\lambda \tan \theta_1 + [(1 - \lambda) \tan \theta_2]\} \tag{2}$$

式中， λ 为第二排机器人车轮转弯半径的权重比例，取值在 $0 \sim 1$ 之间。虚拟转向角 θ_1 、 θ_2 与航向角为 α 之间的关系如下：

$$\lambda \theta_1 + (1 - \lambda) \theta_2 = \arctan\left(\frac{d\alpha}{v_t}\right) \tag{3}$$

可移动机器人在直行过程中通过双目视觉系统采集前进路径的障碍物图像并实时调整路径规避障碍物，转向过程中通过控制机器人行进速度转向角度，保持机器人的稳定性，先在可移动机器人适当位置部署双目视觉系统，如图 3 所示。



图 3 可移动机器人双目视觉图像采集系统

视觉图像采集系统采用思特威 SC233HGS (2.3 MP) 型的 CMOS，感光尺寸为 $1/2.7$ 、工作电压 5 V 、焦距 2.9 mm 、像素尺寸为 $3\text{ }\mu\text{m} \times 3\text{ }\mu\text{m}$ 。视觉传感器的每个像素点捕捉光信号并将其转换为电信号。可移动机器人双目视觉系统有一个长度合适的基线距离，双摄像头光轴与基线的夹角可自适应调整，也可以认为设置合适的图像画幅。可移动机器人内置的 STM32F103C8T6 型单片机和临时存储器，并可以与后台上位机保持实时通信，接收上位机的指令并传递处理完成的二维图像数据。

1.2 视觉图像数据的预处理

双目视觉图像采集的优势在于，可以基于视差原理并利用成像设备从不同的位置获取被测物体不同角度的两幅图像，通过计算图像对应点间的位置偏差，来获取物体三维几何信息^[16]，并更精确地判断出机器人当前的位置信息。针对采集到的视觉图像会包含系统噪声和环境噪声，影响对前进路径和避障的判断，若采集到的图像表示为 $I(p, q)$ ，高斯模糊预处理过程如下：

$$I'(p, q) = G(p, q, \sigma) \otimes I(p, q) \tag{4}$$

式中， $I'(p, q)$ 表示高斯模糊处理后的图像， p 为行像素， q 为列像素， G 为高斯函数， σ 表示模糊尺度参数，值大于零且值越大表示数字图像的模糊程度越高，根据图像集的规模确定不同大小的尺度参数，并形成高斯卷积金字塔。

2 Transformer-LSTM 模型设计

对双目视觉系统采集到的二维图像在线处理难度较大，随着二维图像数据集规模的增大，包括 CNN 卷积神经网络和 RNN 循环神经网络在内的很多深度学习模型^[17-18]，都会面临由于输入数据集规模增大隐含层复杂程度提升，而导致的模型“记忆”数据激增问题，进而引发模型隐含层梯度弥散或膨胀^[19]，增加计算代价，且容易导致深度学习模型的数据训练性能下降。注意力机制是一种模拟人眼视觉的关注重点算法，在深度模型计算资源有限的前提下，引入注意力机制的意义在于赋予不同重要性程度的数据以不同的权重，以达到合理分配深度网络模型资源和降低模型复杂度的目标。以对机器人运动过程中视觉图像的跟踪为例，注意力机制算法模拟人体视觉并根据具体图像特征将机器视觉的注意力集中于感兴趣的区域，在具体执行过程中通过代码编码模拟视觉感知，并赋予不同图像区域以差异化的权重比例。

2.1 自注意力机制驱动的动态特征提取

Transformer 网络模型的构建基于一种特殊的注意力机制：“自注意力机制”^[20]，可以在权重分配中确定输入数据序列之间的关联程度，输入数据被分为“查询 Q”、“键 K”、“值 V”，不同类型的数据之间关系用权重来表示。注意力机制的原理如图 4 所示。




图 4 注意力机制图

先计算查询于键之间的相似度 s_{QK} ：

$$s_{QK_j} = \eta(Q_i, K_j) \quad (5)$$

式中, η 表示一种点积模型函数, Q_i 表示与输入数据 i 对应的查询向量, K_j 表示与第 j 个数据相对应的键向量。基于 softmax 函数对 s_{QK} 进行归一化处理得到与 Q_i 、 K_j 相关的注意力分数 τ_{ij} ：

$$\tau_{ij} = \text{softmax}(s_{QK}) \quad (6)$$

计算与 Q_i 、 K_j 相关的注意力函数值：

$$A(Q_i, K_j) = \sum_{i=1, j=1}^n \tau_{ij} V_j \quad (7)$$

式中, V_j 是与键向量 K_j 对应的值向量。自注意力机制模型的实现过程通常要与编码器—解码器的结构配合使用, 用于处理输入集中各种不同长度的序列。结合自注意力机制的编码器—解码器在性能上得到优化, 即可以处理不同长度的输入数据序列, 并根据数据处理的实际需求动态显示当前序列的长度信息和位置信息。自注意力机制模型在解码的每个步骤同时赋予一个独立的权重向量, 并根据计算后的权重值输出结果。注意力机制模型显著提升了深度学习和深度神经网络模型的泛化能力, 解决了处理大规模数据集时模型过于复杂和模型梯度过度膨胀或梯度弥散等问题。与传统的循环神经网络相比, transformer 利用注意力机制提取输入数据序列的信息, 具体方法是采用编码器模型对当前数据信息的位置进行编码, 编码后数据的长度和维度与嵌入层的序列保持一致。由于三角函数是一种周期性的函数, 更容易进行拆分, 因此通过三角函数获取输入图像数据的绝对位置编码, 其中奇数点上的编码 P_{2k+1} 和偶数点上编码 P_{2k} 分别表示如下：

$$P_{2k+1} = \cos\left(\frac{l}{10000}\right)^{2k/m} \quad (8)$$

$$P_{2k} = \sin\left(\frac{l}{10000}\right)^{(2k+1)/m} \quad (9)$$

其中: l 表示对应的编码位置, m 表示对应向量的维度。绝对位置编码的优势在于可以实现更简化的相对位置描述, 若 x_k 和 x_q 输入分别为位于 transformer 模型 k 位置和 q 位置的输入数据, 利用三角函数描述不同位置之间数据线性变换和相关关系：

$$\begin{cases} \sin(x_k + x_q) = \sin x_k \cos x_q + \cos x_k \sin x_q \\ \cos(x_k + x_q) = \cos x_k \cos x_q - \sin x_k \sin x_q \end{cases} \quad (10)$$

在 Transformer 模型的 LSTM 单元中除了残差门结构还包括一个全连接层, 该层的激活函数选用了 ReLU 函数, 在 t 时刻经过全连接层后得到的输出数据 y_t 表示如下：

$$y_t = \max(x_t w_t + b_t) \quad (11)$$

式中, x_t 和 b_t 分别为全连接层中 t 时刻对应的权重和偏置。在 transformer 模型注意力机制的实际数据训练中,

采用非线性变换可以获得更好的效果, 且与实际的数据训练更加相符, 因此公式 (11) 中 t 时刻的输出结果可能由多组参数共同决定：

$$y_t = F[x_t(w_{t_1}, w_{t_2}, \dots, w_{t_N}) + (b_{t_1}, b_{t_2}, \dots, b_{t_N})] \quad (12)$$

式中, F 为 transformer 模型的非线性映射函数, 最终的输出结果有 N 个权重值和 N 个偏置项共同决定。

2.2 LSTM 增强的时序控制能力

Transformer 模型结构是在自注意力机制基础上发展和演化而来的, 在处理实时的图像数据时输入二维数据被分割为不同的部分, 为更好适应 transformer 的输入格式, 二维数据被拉伸降维转换成一维向量。基于 transformer 结构的处理的每个子块都利用位置编码提供具体的位置信息, 并通过自注意力机制 softmax 函数赋权, 基于权重视角评估每个输入数据子块的重要性程度。transformer 模型结构包含多个编码层, 每个编码层又由一个 ReLU 函数激活层和两个隐含层组成, 用于提取输入数据的特征。第 i 个编码层的输出是第 $i+1$ 个编码层的输入; 而对于解码器而言其结构和编码层类似但增加了自注意力机制层和 softmax 函数层。transformer 模型的基本结构及采用了 tanh 激活函数的 LSTM 结构分别如图 5 和图 6 所示。




图 5 Transformer-LSTM 模型整体结构

本文设计的 transformer 结构在编码器设计方面包括了自注意力机制模块和 LSTM（长短时记忆网络）模块, 用相对更复杂且性能更强的 LSTM 模块替代了传统的前馈型神经网络, 进一步提升了编码器二维图像数据的训练能力。由于前馈型神经网络依然存在隐含层过于发展而导致的模型性能降低等问题, 而 LSTM 模型采用了门控结构设计, 能够更好地控制图像数据信息的流动进而降低了过于复杂隐含层梯度消失和梯度弥散的




图 6 LSTM 模块的结构设计

风险。如图 5 所示，在 transformer 编码器和解码器的结构中，自注意力模块与 LSTM 模块采用串联的方式连接，多头注意力机制的头数与 LSTM 模块的数量，归一化模块的数量相等，且模块的数量与输入数据集的规模和复杂度相关。

在图 6 中 LSTM 的门控结构具体分为了输入门、输出门和遗忘门，对于不同类型的激活函数，从 $t-1$ 时刻到 t 时刻再到 $t+1$ 时刻，利用残差门的结构能够更好地与 transformer 注意力机制的编码器功能相匹配，以达到强化训练的目标。为了有效防止编码器网络产生退化趋势，每个模块完成后需进行归一化处理，用 y_t 表示当前 t 时刻 LSTM 模块的输出结果：

$$y_t = \sigma_3[x_t + L(x_t)] \quad (13)$$

式中， σ_3 表示输出门对应的激活函数， L 表示 LSTM 模块函数。与编码器模块相比，解码器的复杂度更高包括了 3 个部分，即增加了一组 LSTM 模块和归一化模块，对第一次归一化处理后的结果掩盖屏蔽，处理后计算更为完整和全面。

2.3 CS 优化算法与自适应步长的联合参数整定

非线性映射深度网络在数据训练中的权重分配依赖于自适应权重模块，在 transformer 编码器和解码器模型中，LSTM 单元用于对数据的训练且该单元内置了自适应权重模块，卷积核的尺寸为 1×1 ，若 y_{t+1} 为第 $t+1$ 时刻自适应权重模块的输出项，则有：

$$y_{t+1} = \text{Conv}[F(y_t)] \quad (14)$$

式中， Conv 表示卷积核尺寸为 1×1 卷积函数，在 transformer 注意力机制网络中包含了若干个自适应权重模块，并采用随机的方式堆叠。采用 1×1 尺寸的卷积核目的在确保二维图像数据输入前后的通道数量和数据输出特征保持一致。在 transformer 注意力机制网络编码器和解码器的 LSTM 模块中均采用了均方误差函数 χ 作为损失函数，以确定实际输出数据和期望输出数据之间的差距：

$$\chi = n \sum_{i=1}^n (y'_i - \hat{y}'_i) \quad (15)$$

式中， $\hat{y}'_i$ 表示 t 时刻期望的输出值，真实输出值 y'_i 与期望输出值 $\hat{y}'_i$ 之间的差距越小，证明均方误差函数 χ 值越

小，模型的训练能力和特征提取能力越强。transformer 注意力机制网络非线性变换涉及到多组权重、偏置参数的全局寻优，为了获取到最佳的参数组合本文引入了 CS（布谷鸟）搜索算法用于 transformer 注意力机制网络最优参数组合的筛选。CS 搜索算法的基本流程如下：




图 7 CS 搜索算法的流程图

1) 确定布谷鸟算法种群的规模和宿主鸟窝的总数量。

2) 确定布谷鸟个体的当前位置，待布谷鸟选择的宿主鸟窝总数量固定为 N ，与解码器输出结果的权重值总数量一致。

3) 布谷鸟个体 x_i 与编码器的输入数据 i 相对应，当前 t 时刻最优鸟窝位置 L_t ，会对下一代的最优位置 L_{t+1} 选择产生影响。

4) 布谷鸟个体 x_i 的最优鸟窝位置 L_{t+1} 相当于与 x_i 匹配的最优权重 w_{t+1} ：

$$L_{t+1} = L_t + \tau \oplus \eta(x_i) \quad (16)$$

式中， τ 表示步长因子， $\oplus$ 为异或运算符， η 为莱维随机搜索函数。步长因子初始值设置为 0.025，在算法局部的初始阶段，步长因子值加速减少，而在全局寻优阶段步长因子值加速显著降低，具体的优化过程如下所示：

$$\tau = \zeta(L_{t+1} - L_{t+1}) \quad (17)$$

式中， ζ 表示 CS 算法的学习率，学习率取值通常为 0.01。布谷鸟个体最优路径检索过程中，短步长的比重要远高于长步长的比重，莱维随机搜索函数的数值分布总体上服从正态分布。为进一步提升 CS 算法的检索精度，本文采用了自适应步长的优化方法提升种群的寻优能力，即步长因素会随着迭代次数的调整而自适应进行调整，学习率 ζ 也会随着迭代次数的变化而同步变化，自适应步长算法下学习率 ζ 的变化过程如图 8 所示（设定 CS 算法的最大迭代次数为 200 次）。

在自适应步长算法下，学习率会根据 CS 算法的迭代次数进行微调，以更好地适应模型全局寻优的需求。在初始阶段，通常会选择较低的学习率以适应强化




图 8 自适应步长下学习率变化与收敛时间变化

局部检索的需求,提升局部检索的精度;而随着迭代次数的增加,学习率会出现非线性的提高以更好地适应全局检索的要求,避免陷入局部的最优解,而在学习率调整过程中算法的收敛时间未受到影响。通过 transformer 注意力机制的位置编码和参数寻优,能够匹配到最佳的权重参数并合理分配计算资源以更好地达到二维图像数据训练的目标,强化对机器人运动轨迹的跟踪与控制。

3 基于 Transformer-LSTM 的控制策略设计

经过 LSTM 模块和 CS 算法优化后的 transformer 注意力机制网络具有更强的图像数据训练能力和全局寻优能力,并对实时采集到的机器人运动图像进行分析与处理。继而对可移动机器人转向差速运动中位姿进行描述,机器人运动中的位姿控制不仅会影响到图像的采集,还会影响到机器人运行稳定性。相对于图 1 中的全局坐标系,以机器人重心 O' 为坐标原点构建局部坐标系并分析机器人转向过程中的差速驱动模型,局部模型下的坐标转换关系如下:

$$\begin{cases} x_{p'} = x_p \cos \alpha + y_p \sin \alpha \\ y_{p'} = x_p \sin \alpha + y_p \cos \alpha \end{cases} \quad (18)$$

式中, α 为机器人的航向角,点 $(x_{p'}, y_{p'})$ 为局部坐标系中任一点, (x_p, y_p) 是全局坐标系中的对应的点。两个坐标系的转换矩阵 A 表示如下:

$$A = \begin{bmatrix} \cos \alpha & \sin \alpha & 0 \\ -\sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (19)$$

通过可移动机器人重心点坐标和航向角定位机器人在 t 时刻的位姿状态向量 s_t :

$$s_t = [x_{O'} \quad y_{O'} \quad \alpha_t]^T \quad (20)$$

用 s_t 向量中各部分的一阶导数更精确地描述机器人的位置状态:

$$\begin{cases} \dot{x}_{O'} = v_t \cos \alpha_t \\ \dot{y}_{O'} = v_t \sin \alpha_t \\ \dot{\alpha}_t = v_t \tan \alpha_t \cdot d \end{cases} \quad (21)$$

机器人通过 transformer 注意力机制网络模型获取到的行进指令实时调整航向角,使实际行进路径与理论路径之间的偏差最小。可移动机器人利用双目视觉系统

采集到的实时的图像集,将其作为 transformer 注意力机制网络模型的输入数据,经过对图像集的处理和图像特征提取得到路径跟踪和偏差修正的指令,以实现可对移动机器人的路径跟踪精确控制。鉴于机器人稳定控制将对路径跟踪的重要影响,在机器人运动状态空间建模的基础上引入 PID 控制器提升控制精度。首先定义 t 时刻的跟踪误差 μ_t :

$$\mu_t = \begin{bmatrix} \mu_{v_t} \\ \mu_{\omega_t} \end{bmatrix} \quad (21)$$

式中, μ_{v_t} 和 μ_{ω_t} 分别表示线速度误差和角速度误差,针对线速度和角速度的误差控制过程如下:

$$\begin{cases} \mu_{v_t} = K_P v_t + K_I \int v_t dt + K_D \frac{dv_t}{dt} \\ \mu_{\omega_t} = K_P \omega_t + K_I \int \omega_t dt + K_D \frac{d\omega_t}{dt} \end{cases} \quad (22)$$

引入 PID 控制器可以降低机器人转向过程中的误差量,具体包括系统误差和稳态误差,可移动机器人转向过程越稳定,图像采集和精度越高 transformer 输出结果控制精度就越高,使路径跟踪的精度趋近于理论值。最后对本文提出的机器人路径跟踪算法收敛性能进行验证,若机器人跟踪运动过程中存在 M 种路径,用 $A_1, A_2, \dots, A_M$ 表示路径分割点独立事件,则独立事件的概率表示如下:

$$P(A_1, A_2, \dots, A_M) = \prod P(A_q) = \int P(A_1)^M \quad (23)$$

根据马尔科夫链定理可知,路径分割点的数量越少则最后路径的收敛概率就越大,根据 CS 算法搜索情况当布谷鸟个体 x_i 寻找到最优位置后,机器人跟踪运动过程中存在的跟踪路径数量会越来越少,直到迭代完成寻找到最优的路径。

本文提出的控制策略是基于 Transformer 注意力机制网络的路径跟踪控制。该策略通过双目视觉系统实时采集机器人运动路径的图像信息,利用 Transformer 网络中的自注意力机制和 LSTM 模块对图像进行特征提取与动态分析,生成路径跟踪指令。指令通过 PID 控制器调整机器人的线速度和角速度,以最小化实际路径与理论路径的偏差。同时,引入 CS 优化算法与自适应步长机制,动态优化 Transformer 模型的权重分配和学习率,提升模型对环境的适应性,控制策略如图 9 所示。

4 实验结果与分析

4.1 实验平台与多算法对比设计

本文设计的可移动机器人路径跟踪测试在实验室自然光照环境下进行,机器人配备双目视觉传感器(思特威 SC233HGS (2.3 MP) 型的 CMOS)。可移动机器人的外形尺寸为 $0.3 \text{ m} \times 0.3 \text{ m} \times 1.2 \text{ m}$,重量为 55 kg,




图 9 控制策略

可移动机器人前轮转向且内置了 STM32F103C8T6 型单片机和 256 GB 的临时存储器，可移动机器人实物及实验测试路径环境具体如图 10 所示。




图 10 基于 transformer 注意力机制网络模型可移动机器人

可移动机器人的测试路线总长度为 20 m，具体包括直路、弯路和障碍物（ $0.3\times0.3\times0.3$ 的正方体，障碍物位于机器人行进路径中心偏左），分别利用本文设计了 transformer 注意力机制网络模型，和传统的径向基网络算法模型、CNN 网络算法模型、SLAM 算法模型，分别测试相同的路况，观测各算法路径跟踪的效果。各算法的关键参数设定如表 1 所示。

表 1 各算法的参数设定

序号	参数	参数值
1	神经网络最大迭代次数	200
2	隐含层数量	5
3	学习率范围	0.005~0.025
4	学习率固定值	0.01
5	激活函数	ReLU
6	CS 算法可用鸟窝数量	100
7	莱维指数	2
8	莱维飞行步长	5
9	多头注意力机制头数	10
10	缩放因子取值	0.53

径向基网络算法模型、CNN 网络算法模型的神经网络参数设置与 transformer 注意力机制网络模型的参数配置相同，SLAM 算法模型的视觉传感器配置和

transformer 注意力机制网络模型的视觉传感器配置相同，以确保实验测试的公平性，双目视觉系统采集了 1 000 帧图像，包含直道、弯道及障碍物场景。实验中分别引入本文设计的路径跟踪算法和 3 种传统的路径跟踪算法，在相同的实验场景下进行同类测试，以验证各算法对于机器人路径跟踪的控制能力。具体的实验测试指标选择：1）可移动机器人完成整个路径的耗时；2）轨迹路径的偏差。

4.2 路径跟踪效率与动态避障能力测试

测试的线路长 20 m，包括了直线路径、弯道路径且机器人行进路径上还有障碍物，可移动机器人跟踪控制需要尽可能地提升运行速度和效率并成功躲避行进路径上的障碍物。共进行了 10 组实验，观测各路径跟踪算法完成耗时，如表 2 所示。

表 2 各算法完成测试路径的耗时统计

测试	路径跟踪算法/s			
	本文算法	径向基网络	CNN 网络	SLAM 算法
1	9.5	11.2	10.7	12.2
2	9.0	12.1	10.5	12.1
3	9.2	12.0	12.0	13.2
4	10.1	11.4	12.0	11.8
5	9.1	10.8	10.7	11.9
6	8.8	11.8	10.6	12.5
7	8.9	11.4	11.5	12.4
8	9.1	12.3	11.4	11.9
9	9.2	10.8	11.8	12.0
10	9.3	10.7	12.5	12.2
均值	9.2	11.5	11.4	12.2

从对实际的测试结果分析可知，本文基于 Transformer 注意力机制网络模型的 10 次测试均值耗时为 9.2 s，优于 3 种传统算法的 11.5 s，11.4 s 和 12.2 s。各算法的测试中指令延迟测量结果（人为加入噪声前后对比），如表 3 所示。

表 3 各算法完成测试路径平均延迟

测试	路径跟踪算法/s			
	本文算法	径向基网络	CNN 网络	SLAM 算法
无噪声延迟均值	0.15	0.52	0.64	0.55
有噪声延迟均值	0.16	0.93	1.02	0.89

表 3 中的延迟结果显示，本文算法的指令延迟最低均值为 0.15 s，人为加入噪声后延迟并未出现显著增长，表明本文路径跟踪算法的抗干扰能力较强。为验证在低照度条件下的路径延迟情况，将室内照明的 LUX 值从 100 降低到 10，观测各算法完成测试路径的平均延迟情况，如表 4 所示。

在 10 LUX 低照度条件下，本文算法未出现较为明显的延迟，而其他传统算法出现了较为明显的路径延迟

情况。

表 4 低照度条件下各算法完成测试路径平均延迟

测试	路径跟踪算法/s			
	本文算法	径向基网络	CNN 网络	SLAM 算法
无噪声延迟均值	0.15	0.75	0.83	0.77
有噪声延迟均值	0.17	1.15	1.34	1.21

由于 SLAM 算法未采用视觉方案而是采用了传感器的路径跟踪方法，导致其路径跟踪效率最低。测试中各算法与障碍物的碰撞次数，如表 5 所示。

表 5 各算法与障碍物的碰撞次数统计

测试	路径跟踪算法/s			
	本文算法	径向基网络	CNN 网络	SLAM 算法
1	0	0	0	0
2	0	0	0	1
3	0	0	0	0
4	0	1	0	0
5	0	0	0	0
6	0	0	0	0
7	0	0	1	0
8	0	0	0	1
9	0	0	0	0
10	0	0	0	0

数据统计结果显示：transformer 注意力机制网络模型控制下，机器人并未与障碍物发生碰撞，而 3 种传统方法的碰撞次数分别为 1 次、1 次和 2 次。路径轨迹偏差指可移动机器人行进中偏离了预先设定的理论轨迹路线，如果偏差过大不仅增加了与障碍物碰撞的风险，还会增加机器人完成测量任务的耗时。在行进路径上随机采集了 10 个采样点，观测这 10 个采样点与理论值的偏差，统计结果如图 11 所示。




图 11 各算法采样点与理论值的偏差值

图 10 中的在本文算法下各采样点的偏差最小，而其他 3 种路径跟踪算法均出现了一定程度偏差，计算各算法下 10 个采样点的方差值和 P 值，如表 5 所示。

由方差值的计算结果可知，本文 transformer 注意力机制网络模型下的各采样点偏差的方差值仅为 0.015，

表 5 采样点方差值统计

	路径跟踪算法/s			
	本文算法	径向基网络	CNN 网络	SLAM 算法
方差值	0.015	0.256	0.247	0.297
Sig.	0.000	0.105	0.125	0.133

P 值统计维 0.000，显著低于 3 种传统方法，证明了本文路径跟踪算法下的行进路径更接近于理论路径。

4.3 消融实验

通过消融实验验证本文 transformer 注意力机制网络算法模型的稳定性及多次模型优化的效果，本文模型分别通过对 transformer 结构中的训练单元、CS 权重优化算法和自适应步长，进行了 3 次优化，第一次优化后定义为模型 A、第二次优化定义为模型 B，第三次优化定义为模型 C（模型 C 为各对比实验中实际应用的本文算法模型），以表 2 中的耗时统计为基础，具体的数据统计结果如表 6 所示。

表 6 消融实验测试路径的耗时统计

测试	路径跟踪算法/s			
	原未优化模型	模型 A	模型 B	模型 C
1	10.3	10.2	9.8	9.5
2	10.4	10.0	9.7	9.0
3	9.8	9.5	9.3	9.2
4	11.5	11.1	10.7	10.1
5	9.7	9.4	9.2	9.1
6	9.9	9.5	8.9	8.8
7	10.2	10.1	9.6	8.9
8	11.4	11.1	10.6	9.1
9	10.3	10.0	9.4	9.2
10	10.5	9.7	9.5	9.3
均值	10.4	10.1	9.7	9.2

原始未进行优化的 transformer 下的完成路径的耗时为 10.4 s，经过模型 A，模型 B 和模型 C 的三次优化完成路径的耗时分别有了不同程度的改差，经过每次优化 transformer 网络模型的性能均有所增强，且模型的稳定性也未受到影响，经过多次优化可移动机器人路径跟踪模型能够达到一个相对最佳的状态。从原始未优化模型到模型 A，模型 B 和模型 C，跟踪算法的耗时分别降低了 2.9%，4.0% 和 5.2%，通过 CS 算法优化和自适应步长优化，其累计的贡献度达到了 9.2%，表面通过参数优化能够显著提升跟踪控制的效果。经过模型 A，模型 B 和模型 C 的三次优化后对方差值影响结果如表 7 所示。

表 7 消融实验方差值统计

测试	路径跟踪算法/s			
	原未优化模型	模型 A	模型 B	模型 C
方差值	0.153	0.095	0.032	0.015

从原有未优化模型到模型 C, 测试方差分别降低了 0.058、0.063 和 0.017, 由此可知三次优化的贡献度排序为 CS 权重优化算法、自适应步长和 transformer 结构中的训练单元的优化。经过各模块的多次优化, 采样点的方差值变化有明显的降低趋势, 表明经过优化 transformer 网络模型的路径跟踪控制效果良好, 趋近于理论路径的轨迹。

5 结束语

随着人工智能、机器学习、自动化控制等技术的不断进步, 可移动机器人的应用场景逐渐增多, 各领域的用户对可移动机器人的工作效率和稳定性要求也同步提升。现有的可移动机器人路径跟踪控制算法多采用视觉图像采集方案或传感器定位方案, 进而对实时采集到的图像进行识别和特征提取。但图像数据集的处理难度较高对深度神经网络模型的图像训练能力有较高的要求, 但训练模型的数据实时处理能力不足时, 容易导致机器人的路径跟踪出现偏差或与障碍物发生碰撞。为此本文提出一种基于 transformer 结构的深度网络算法模型, 本文的创新点在于通过在编码器、解码器中引入了 LSTM 结构, 解决了模型的梯度问题, 引入 CS 算法和自适应步长对 transformer 模型进行多次优化, 以更好地提升模型的数据训练能力、特征提取能力并避免了模型由于隐含层的增加而出现性能降低的情况。实际的测试结果显示在 transformer 注意力机制网络算法模型下, 可移动机器人完成任务的耗时最短, 且并未出现与障碍物的碰撞现象。transformer 注意力机制网络既是一种高效的和有发展前景的深度神经网络模型, 同时也是 AI 大模型的核心工具, 借助 transformer 注意力机制网络能够基于视觉实现对可移动机器人的精确控制和路径跟踪。但 transformer 注意力机制网络依然存在复杂度较高等问题, 因此在未来可通过进一步引入全新启发式算法或群智能算法, 来解决神经网络的固有梯度问题和硬件投入过高的问题。

参考文献:

- [1] 王洪斌, 刘德垚, 郑 维, 等. 异构多目标差分-动态窗口算法及其在移动机器人中的应用 [J]. 控制与决策, 2023, 38 (12): 3390-3398.
- [2] 陆亚红, 马 灵, 杨婉茹, 等. 智能图书盘点机器人技术的实践与应用研究——以上海交通大学图书馆为例 [J]. 大学图书馆学报, 2023, 41 (1): 44-51.
- [3] 马 天, 席润韬, 吕佳豪, 等. 基于深度强化学习的移动机器人三维路径规划方法 [J]. 计算机应用, 2024, 44 (7): 2055-2064.
- [4] 邢文芳, 冯寄东, 徐 元, 等. 双程 UFIR 滤波算法及其在 INS/双目视觉机器人组合导航的应用 [J]. 传感技术学报, 2023, 36 (7): 1073-1078.
- [5] 姜 伟, 王 挺, 邵沛瑶, 等. 一种轮腿复合型机器人的步态研究与越障性能分析 [J]. 兵工学报, 2023, 44 (1): 247-259.
- [6] 吴雄伟, 周云成, 刘峻淳, 等. 面向温室移动机器人的无监督视觉里程估计方法 [J]. 农业工程学报, 2023, 39 (10): 163-174.
- [7] 张兆威, 侯 宇, 蒋 林, 等. 基于单目视觉和轮式编码器的室内移动机器人松耦合定位方法 [J]. 武汉科技大学学报, 2023, 46 (4): 303-310.
- [8] 林叶贵, 戴志坚, 何德峰, 等. 具有速度突变抑制的全向移动机器人视觉伺服预测控制 [J]. 计算机科学, 2024, 51 (11A): 3-6.
- [9] 杨 彪, 王 狄, 沈绍博, 等. 基于深度测距的移动机器人自适应跟随 [J]. 计算机工程与设计, 2024, 45 (3): 896-903.
- [10] 刘 鑫, 陈昌忠, 罗 淇, 等. 基于 HJI 理论的移动机器人神经网络自适应控制 [J]. 计算机仿真, 2023, 40 (9): 437-442.
- [11] 韩竺秦, 张丽娜, 伍炜东. 基于 CNN 的移动机器人局部路径激光雷达辅助规划方法 [J]. 激光杂志, 2023, 44 (6): 225-229.
- [12] 张 凤, 孙 健, 袁 帅. 基于强跟踪的移动机器人 CQKF-SLAM 方法 [J]. 计算机工程与设计, 2024, 45 (6): 1872-1879.
- [13] 余 涛, 熊盛武. 农业场景下移动机器人的双目视觉定位与地图构建方法 [J]. 计算机科学, 2023, 50 (12): 185-191.
- [14] 邢文芳, 冯寄东, 徐 元, 等. 双程 UFIR 滤波算法及其在 INS/双目视觉机器人组合导航的应用 [J]. 传感技术学报, 2023, 36 (7): 1073-1078.
- [15] 陈明方, 黄良恩, 王 森, 等. 移动机器人视觉里程计技术研究综述 [J]. 农业机械学报, 2024, 55 (3): 1-20.
- [16] 符 强, 孔健明, 纪元法, 等. 双目视觉图像边缘区域处理的精确立体匹配 [J]. 计算机仿真, 2023, 40 (12): 226-231.
- [17] 张润宁, 余 鹏, 谭 宁. 基于变参递归网络和递归最小二乘的连续体机器人控制 [J]. 自动化学报, 2025, 51 (1): 90-103.
- [18] 翁 顺, 雷奥琦, 陈志丹, 等. 基于模型嵌入循环神经网络的损伤识别方法 [J]. 湖南大学学报 (自然科学版), 2024, 51 (7): 21-29.
- [19] 南敬昌, 孙雯雯, 杜有益, 等. 一维卷积神经网络超宽带天线建模方法 [J]. 电子测量与仪器学报, 2023 (2): 204-210.
- [20] 齐美彬, 李亚斌, 项厚宏, 等. 基于自注意力机制的雷达弱目标检测 [J]. 雷达科学与技术, 2023, 21 (4): 431-439.