



基于改进神经网络的机器人逆解与轨迹精度提高方法

王涛¹, 张恩政¹, 刘翠苹², 陈晓², 陈刚³

(1. 浙江理工大学精密测量实验室, 杭州 310018; 2. 杭州新松机器人自动化有限公司, 杭州 311225;
3. 杭州市质量技术监督检测院机器人实验室, 杭州 310019)

摘要: 为了提高工业机器人的逆解精度与运动轨迹精度, 提出了一种基于改进神经网络的机器人逆解与轨迹精度提高方法。首先通过改进遗传算法的交叉和变异概率优化 BP 神经网络来提高机器人的逆解精度; 然后采用改进 Sigmoid 函数的神经网络 PID 控制方法实现机器人的运动轨迹控制, 进而提高机器人的运动轨迹精度。构建了机器人轨迹精度测试实验系统, 进行仿真与系统实验研究。仿真结果表明, 改进遗传算法优化 BP 神经网络可有效提高机器人的逆解精度和速度; 圆弧与直线轨迹的系统实验结果显示, SR4C 型工业机器人运动轨迹精度提升效果均优于 60%。该方法可有效提高机器人的运动轨迹精度, 满足工业生产、智能制造等领域对机器人运动轨迹精度的需求。

关键词: 工业机器人; 轨迹精度; 神经网络; 遗传算法; Sigmoid 函数

中图分类号: TP242.2

文献标志码: A

文章编号: 1673-3851(2021)09-0624-09

Inverse solution and trajectory accuracy improvement method of robot based on improved neural network

WANG Tao¹, ZHANG Enzheng¹, LIU Cuiping², CHEN Xiao², CHEN Gang³

(1. Precision Measurement Laboratory, Zhejiang Sci-Tech University, Hangzhou 310018, China;
2. Hangzhou SIASUN Robot & Automation Co., Ltd., Hangzhou 311225, China; 3. Robotics Laboratory, Quality and Technical Supervision and Testing Institute of Hangzhou, Hangzhou 310019, China)

Abstract: In order to improve the accuracy of inverse solution and trajectory of industrial robots, a method based on improved neural network was proposed to improve the accuracy of inverse solution and trajectory of the robot. BP neural network was optimized by improving the crossover and mutation probability of genetic algorithm to strengthen the accuracy of inverse solution of the robot. Then, the motion trajectory control of the robot was realized by improving the neural network PID control method of Sigmoid function, thereby improving the motion trajectory accuracy of the robot. The test experiment system of robot trajectory precision was built for simulation and system experiment research. The simulation results showed that the BP neural network optimized by the improved genetic algorithm could effectively improve the robot's inverse kinematics accuracy and speed. The experimental results of the circular and linear trajectory system showed that the trajectory precision improvement effect of SR4C industrial robot was better than 60%. This method can effectively improve the trajectory accuracy of the robot, and meet the requirements for the trajectory accuracy of the robot in industrial production and intelligent manufacturing.

Key words: industrial robot; trajectory accuracy; neural networks; genetic algorithm; Sigmoid function

0 引言

工业机器人具有高效灵活、重复定位精度高、稳定性好等特点,在工业生产、智能制造等领域得到了广泛应用^[1]。目前工业机器人一般具有较高的重复定位精度,但绝对定位精度偏低,不能有效保证机器人末端的运动轨迹精度,因而难以满足某些作业任务对机器人运动轨迹的高精度应用需求,例如精密激光焊接、激光切割等应用^[2-3]。

为了提高工业机器人的运动轨迹精度,国内外学者开展了相关研究工作,这些研究主要集中在机器人逆运动学和运动控制两个方面。机器人逆运动学提高轨迹精度的基本思想,是通过逆运动学将笛卡尔空间的目标值逆解得到准确关节角度值,进而通过驱动器控制各个关节运动来提高机器人末端轨迹精度^[4]。逆解方法主要包括解析法、数值法和智能算法。解析法的特点是求解速度快,但使用时需要提前对机器人的型号与结构进行分析,通用性较差^[5]。数值法具有通用性高、求解精度较低的特点,可通过改进数值法来提高求解精度,如:改进牛顿迭代数值法用于机器人逆解可有效提高逆解精度^[6];对偶四元数作为算子的混合逆运动学求解方法,不仅提高了精度还可减少计算量^[7]。近年来,随着智能算法研究的深入,其优势愈发凸显,并被应用于机器人的逆解补偿中,如:通过反向传播神经网络求解逆运动学模型对末端位姿进行迭代补偿,解决机器人实时控制中对精度的要求^[8];对人工神经网络、自适应等算法综合分析提出的网络误差最小化的方法被用于提高逆解精度^[9-10],而对神经网络各环节中的参数进行合理选择和设置是机器人应用中提高神经网络效能的重要方式^[11]。机器人运动控制方法包括PID控制、自适应控制以及神经网络控制等。其中,PID控制由于算法简单易于实现等优点得到了广泛的应用^[12],但常规的PID控制难以保证复杂的非线性机器人的轨迹精度,因而结合智能算法的PID控制方法成为研究热点,如:直接模糊PID控制和自适应神经网络PID控制方法被分别用于提高机器人轨迹精度^[13-14];结合前馈和传统PID控制理论提出的自适应迭代学习控制算法被用来改善轨迹精度^[15-16]。综上所述,关于机器人逆解与轨迹精度提高方法研究,相比于传统方法,神经网络算法以其较强的学习和优化能力已被用来提高机器人逆解和轨迹精度,但神经网络容易陷入局部最优且迭代时间较长,因此如何优化神经网络提高机器人逆解

与轨迹精度是目前研究的重点。

本文提出一种基于改进神经网络的机器人逆解与轨迹精度提高方法。首先通过改进遗传算法的交叉和变异概率来优化神经网络,以提高机器人逆解精度;然后通过关节误差对轨迹精度的影响分析,采用比例位移因子改进 Sigmoid 函数 PID 控制方法,以实时减小机器人关节误差,提高工业机器人运动轨迹的精度。

1 机器人逆解精度提高方法

1.1 BP神经网络逆运动学求解

BP神经网络逆运动学求解中的神经网络结构如图1所示,包含了输入层 I 、隐含层 H 、输出层 O 三层网络结构。输入层和输出层的神经元个数均为6个。神经网络的输入矩阵 $(x, y, z, \alpha, \beta, \gamma)$ 中, (x, y, z) 为机器人末端的位置, (α, β, γ) 为机器人末端的姿态。输出矩阵 $(\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6)$ 中, $\theta_i (i = 1, 2, \dots, 6)$ 分别对应于机器人的六个关节角。隐含层作为网络中重要环节,关键是设置合适的神经元个数,隐含层神经元个数 m 可由 Kolmogorov 公式求得:

$$m = \sqrt{u + v} + l \quad (1)$$

其中: u 表示输入层神经元个数; v 为输出层神经元个数; l 为 $[1, 10]$ 之间的随机数。

根据式(1)计算出网络隐含层神经元个数 m 在 5~13 之间,为了提高网络学习速率和降低网络结构的复杂性,隐含层神经元个数取 $m = 5$ 。网络的学习率通常保持不变,学习率选取过大可能导致网络不能收敛,过小可能导致网络收敛速度慢,本次训练学习率设为 0.05;网络最大迭代次数设为 1000,作为网络训练迭代次数的最大取值,当网络训练达到 1000 次时无论是否收敛均停止训练。训练样本数据采用蒙特卡罗法在机器人工作空间中生成 2000 组关节角作为输出样本数据,并通过机器人正运动学来获得它们在空间中对应的位姿作为输入样本数据。




图1 逆运动学求解神经网络结构示意图

1.2 遗传算法交叉与变异概率的改进

在基于神经网络的机器人逆运动学求解中,针对传统遗传算法优化 BP 神经网络存在容易陷入局部极值的问题,本文提出了改进的遗传算法的交叉和变异概率,通过提高遗传算法的全局寻优能力来提高机器人的逆解精度。

机器人神经网络逆运动学求解数据种群的多样性取决于交叉和变异概率,在改进遗传算法优化 BP 神经网络逆运动学求解中,将神经网络预测的关节角和期望关节角之间的偏差关系进行处理,形成误差函数 e :

$$e = \sqrt{\sum_{i=1}^6 (\theta_{pi} - \theta_{ai})^2} \quad (2)$$

其中: $i=1, 2, \dots, 6$; θ_{pi} 为神经网络预测的关节角, rad; θ_{ai} 为期望的关节角, rad。

个体适应度值 f 通过误差函数 e 的导数定义:

$$f = \frac{1}{e} \quad (3)$$

遗传算法中交叉概率 P_c 一般取 0.25~1.00 之间的固定值,在整个算法运行过程中该值都不改变。固定值存在的缺点是:若选取的交叉概率值偏小,则遗传算法全局搜索能力与收敛速度将下降;若选取的交叉概率值偏大,则遗传算法全局搜索能力增强导致破坏染色体结构。

针对以上不足,本文改进了交叉概率 P_c ,根据当前个体的适应度值和网络迭代次数来不断调整交叉概率。当个体适应度值小于平均适应度值时且处于网络迭代的前期,采用较大的交叉概率来增强遗传算法的全局搜索能力,随着网络迭代的次数不断增加,不断减小交叉概率;当个体适应度值大于平均适应度值时且处于网络迭代的后期,采用较小的交叉概率来降低遗传算法的全局搜索能力,随着网络迭代次数的不断增加,不断增大交叉概率。因此改进后的交叉概率 P_c 可用式(4)表示:

$$P_c = \begin{cases} P_{cmax} - \frac{n}{n_{max}}(P_{cmax} - P_{cmin}), & f_{max} \leq f_p; \\ P_{cmin} + \frac{n_{max} - n}{n_{max}}(P_{cmax} - P_{cmin}), & f_{max} > f_p \end{cases} \quad (4)$$

其中: P_{cmin} 表示最小交叉概率,设为 0.25; P_{cmax} 表示最大交叉概率,设为 1.00; f_{max} 表示交叉个体的最大适应度值; f_p 表示种群个体的平均适应度值; n_{max} 表示最大迭代次数; n 表示当前迭代次数。

遗传算法中的变异概率 P_m 一般取 0.001~

0.100 之间的固定值,针对固定值的不足提出改进变异概率 P_m ,根据当前个体的适应度值和网络迭代次数来不断调整变异概率。当个体适应度值小于平均适应度值时且处于网络迭代的前期,采用较小的变异概率来保存染色体中的重要基因,随着网络迭代次数的增加不断增大变异概率;当个体适应度值大于平均适应度值时且处于网络迭代的后期,采用较大的变异概率来增加遗传算法的全局搜索能力,随着网络迭代次数的增加不断减小交叉概率。因此改进后的变异概率 P_m 可用式(5)表示:

$$P_m = \begin{cases} P_{mmin} + \frac{n}{n_{max}}(P_{mmax} - P_{mmin}), & f \leq f_p; \\ P_{mmax} - \frac{n_{max} - n}{n_{max}}(P_{mmax} - P_{mmin}), & f > f_p \end{cases} \quad (5)$$

其中: P_{mmin} 表示最小变异概率,设为 0.001; P_{mmax} 表示最大变异概率,设为 0.100; f 表示种群中父代染色体的适应度值; f_p 表示种群个体的平均适应度值; n_{max} 表示最大迭代次数; n 表示当前的迭代次数。

1.3 改进遗传优化神经网络逆解方法

本文改进了遗传算法优化 BP 神经网络,以提高机器人逆运动学求解的精度,该方法的流程图如图 2 所示。该方法主要包括初始化操作、改进遗传算法交叉与变异概率操作以及神经网络操作。首先在改进遗传算法交叉与变异概率操作中,通过判断个体适应度值和当前迭代次数来进行合适的选择调整;然后在神经网络操作中,通过改进遗传算法得到最优个体,并对网络初始权值和阈值进行赋值,通过判断误差 e 是否满足预设值 ϵ 来输出预测结果;最后使用改进遗传算法找到 BP 神经网络最优权值和阈值,以提高机器人的逆解精度。

2 机器人轨迹精度提高方法

2.1 关节误差对轨迹精度影响分析

在机器人运动学分析中,通过 D-H 变换关系将相邻连杆位姿矩阵依次相乘,得到机器人末端理论位姿矩阵 T^P :

$$T^P = \prod_{j=1}^6 {}^jT_{j-1} = \begin{bmatrix} n_x & o_x & a_x & p_x \\ n_y & o_y & a_y & p_y \\ n_z & o_z & a_z & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (6)$$

其中:机器人连杆编号 $j=1, 2, \dots, 6$; (n_x, n_y, n_z) 表示法线向量; (o_x, o_y, o_z) 表示方向向量; $(a_x, a_y,$

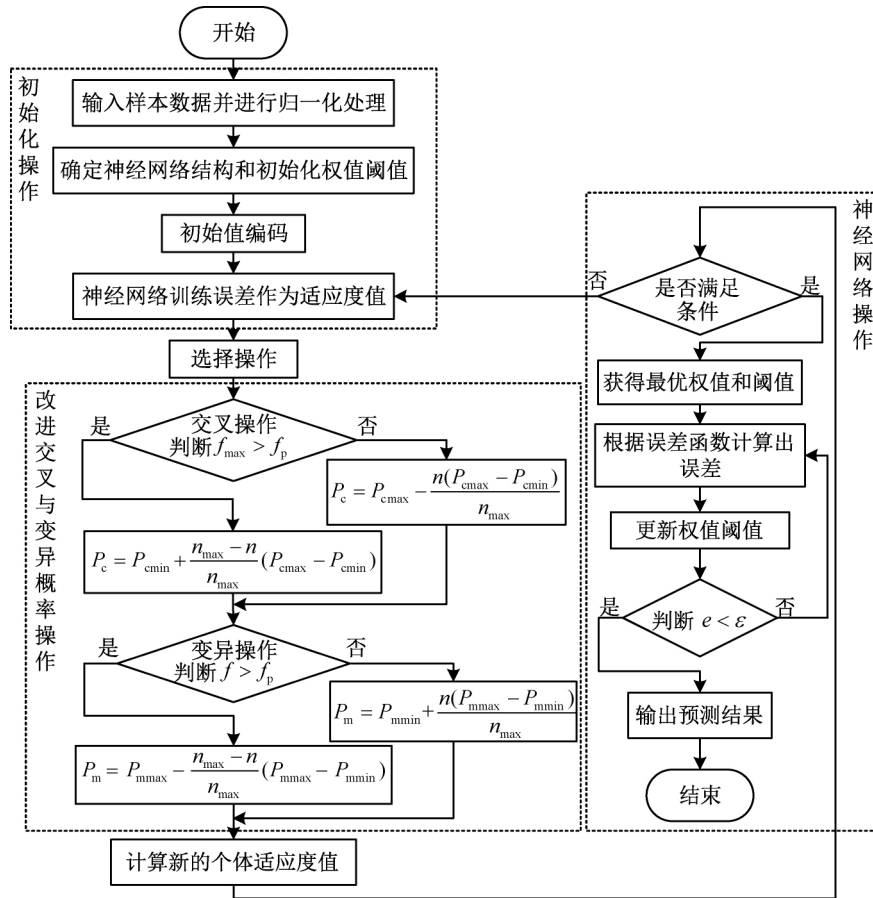


图 2 逆运动学求解中改进遗传算法优化 BP 神经网络流程图

a_z) 表示接近向量; (p_x, p_y, p_z) 表示位置向量。

将理论位姿矩阵 T^P 与位姿误差矩阵 T^E 相加后可得实际位姿矩阵 T^S :

$$T^S = T^P + T^E \quad (7)$$

由式(6)和式(7)可得机器人末端位姿误差矩阵 T^E 的表达式, 为:

$$T^E = (T^S)^{-1} \cdot T^P = (T^P + T^E)^{-1} \cdot T^P = \begin{bmatrix} 0 & -\delta_z & \delta_y & d_x \\ \delta_z & 0 & -\delta_x & d_y \\ -\delta_y & \delta_x & 0 & d_z \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (8)$$

其中: $\delta_x, \delta_y, \delta_z$ 表示微分旋转量; d_x, d_y, d_z 表示微分平移量。

结合式(6)和式(8)可将机器人末端位姿误差归结为函数误差的研究, 则对机器人末端位姿误差进行微分处理:

$$dT^E \approx \sum_{j=1}^6 \left(\frac{\partial T^E}{\partial \theta_j} \right) \delta \theta_j + \sum_{j=1}^6 \left(\frac{\partial T^E}{\partial d_j} \right) \delta d_j + \sum_{j=1}^6 \left(\frac{\partial T^E}{\partial a_j} \right) \delta a_j + \sum_{j=1}^6 \left(\frac{\partial T^E}{\partial \alpha_j} \right) \delta \alpha_j \quad (9)$$

其中: δ 表示微分算子; a_j 表示连杆长度, mm; α_j 表

示连杆扭角, ($^\circ$); d_j 表示关节偏距, mm; θ_j 表示关节转角, ($^\circ$)。

由于本方法重点研究关节角 θ_j 参数对求解出的机器人末端实际位姿的误差影响, 这里暂不考虑关节偏距 d_j 、连杆长度 a_j 、连杆扭角 α_j 对末端位姿的误差影响, 则式(9)可进一步变形为:

$$dT^E \approx \sum_{j=1}^6 \left(\frac{\partial T^E}{\partial \theta_j} \right) \delta \theta_j \quad (10)$$

由于机器人关节误差的存在, 使得机器人在实际运动过程中会产生轨迹误差, 实际运动轨迹 L' 与理论运动轨迹 L 之间产生的轨迹误差 ΔL 可表示为:

$$\Delta L = f(T^P + T^E) - f(T^P) = f(d\theta) \quad (11)$$

其中: f 为机器人关于关节角误差的函数。

由上述推导可知, 机器人关节误差对末端轨迹精度的影响, 所以可通过减小关节误差达到提高轨迹精度的效果。

2.2 改进 Sigmoid 函数的 PID 控制方法

在机器人 PID 控制中, 本文将关节偏差按照比例、积分和微分的线性组合关系对机器人各关节进行控制, 而针对神经网络优化 PID 存在收敛精度低、速度慢等问题, 本文通过改进 Sigmoid 函数的比例

位移因子来优化神经网络 PID 控制,以达到提高机器人运动轨迹精度的效果。

改进 Sigmoid 函数的神经网络 PID 控制的输入为:

$$X(t) = \begin{cases} x_1(t) = \theta(t) - \theta'(t) = e(t), \\ x_2(t) = e(t) - e(t-1), \\ x_3(t) = e(t) - 2e(t-1) + e(t-2), \\ x_4(t) = \tau_d(t-1) \end{cases} \quad (12)$$

其中: $x_1(t)$ 表示 t 时刻关节轨迹偏差, rad; $\theta(t)$ 表示关节实际位置, rad; $\theta'(t)$ 表示关节期望位置, rad; $e(t)$ 表示 t 时刻的关节轨迹偏差, rad; $x_2(t)$ 表示 t 时刻与 $t-1$ 时刻关节轨迹偏差, rad; $x_3(t)$ 表示 t 时刻与 $t-1$ 、 $t-2$ 时刻的轨迹偏差, rad; $x_4(t)$ 表示 $t-1$ 时刻计算出的关节力矩, N/mm。

结合 $X(t)$ 输入推导出的机器人神经网络 PID 控制公式为:

$$\tau_d(t) = K_P x_1(t) + K_I x_2(t) + K_D x_3(t) + x_4(t) \quad (13)$$

其中: τ_d 为计算出的补偿力矩, N/mm; K_P 为比例系数; K_I 为积分系数; K_D 为微分系数。

改进 Sigmoid 函数 PID 控制框图如图 3 所示, 本文通过改进 Sigmoid 函数的神经网络来实现 PID 反馈控制的参数调节, 从而实现 PID 控制的机器人关节误差不断减小, 达到提高机器人末端轨迹精度的效果。图 3 中 $x_1 \sim x_4$ 为输入层的输入; net_i 为隐含层的输入, O_i 为隐含层的输出, w_{ij} 为隐含层的权值 $i=1, 2, \dots, n$, n 为隐含层神经元个数; net_l 为输出层的输入, K_P, K_I, K_D 为输出层的输出, w_{li} 为输出层的权值, $l=1, 2, 3$; f 与 g 分别表示隐含层和输出层的变换函数。

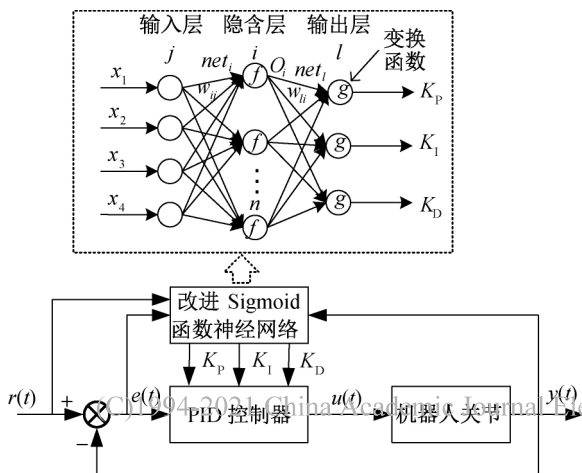


图3 改进 Sigmoid 函数 PID 控制框图

由于 K_P, K_I, K_D 不能为负值, 所以输出层的变换函数 g 取为非负的标准 Sigmoid 函数, $g(net_l)$ 可表示为:

$$g(net_l) = \frac{1}{1 + e^{-net_l}} \quad (14)$$

由标准 Sigmoid 函数表达式可知, 在输入趋向无穷的地方函数值变化很小, 且当输入值波动较大时, 输出值落在平坦区域, 导致计算结果误差较大, 容易使网络出现收敛速度慢甚至不收敛的问题。针对以上这些问题, 引入比例位移参数因子来改进 Sigmoid 函数。改进后表达式为:

$$g_s(net_l) = \frac{1}{1 + e^{-[\alpha(net_l - \beta)]}} \quad (15)$$

其中: α 为比例因子, 取值范围为 $(0, 1)$; β 为位移因子, 取值范围为 $(-1, 1)$ 。

标准和改进的 Sigmoid 函数曲线如图 4 所示, 由图 4 可知: 改进 Sigmoid 函数较标准 Sigmoid 函数的曲线更平坦, 函数值变化分布较均匀, 不容易缺失梯度。在同一台计算机的 Matlab 中进行三种控制方法的性能对比仿真, 计算机的环境参数配置为 i5-7500CPU 和 8 GB 内存, 三种控制方法的性能对比仿真结果分别如图 5 和表 1 所示。从图 5 可以看出, 改进 Sigmoid 的 PID 控制的超调量、调节时间和稳态误差均小于传统 PID 控制和神经网络 PID 控制。由表 1 可知, 改进 Sigmoid 的 PID 控制方法超调量比神经网络 PID 控制下降了 7.312%, 调节时间减小了 0.256 s, 稳态误差减小了 0.322%, 这表明改进 Sigmoid 的 PID 控制效果要优于神经网络 PID 控制。




图4 标准的和改进的 Sigmoid 函数曲线

表1 三种控制方法性能对比数据

控制方法	性能指标		
	超调量/%	调节时间/s	稳态误差/%
PID	22.447	0.813	0.927
神经网络 PID	17.353	0.487	0.561
改进 Sigmoid 的 PID	10.041	0.231	0.239




图 5 控制系统输出响应对比曲线

3 仿真与实验

3.1 改进遗传优化神经网络逆解仿真

基于以上改进遗传算法优化 BP 神经网络逆运

动学求解理论进行了神经网络训练仿真，并通过检测网络模型预测值和真实值之间的均方误差 e_{MS} 和迭代次数 s 来反映网络的预测效果。仿真结果如图 6 所示，BP 神经网络测试后均方误差为 2.34×10^{-5} rad，迭代次数为 100 次；遗传算法优化 BP 神经网络测试后均方误差为 9.73×10^{-8} rad，迭代次数为 35 次；改进遗传算法优化 BP 神经网络测试后均方误差为 9.11×10^{-8} rad，迭代次数为 19 次。仿真结果显示改进遗传优化神经网络相较于遗传优化神经网络其逆解速度提高了 46%，相较于 BP 神经网络其逆解速度提高了 81%。仿真结果验证了改进遗传算法优化 BP 神经网络在机器人逆运动学求解中的可行性与有效性。




图 6 逆运动学求解的仿真结果均方误差曲线

在机器人工作空间选取 10 组位姿数据分别采用数值法、BP 神经网络法、改进遗传优化 BP 神经网络法三种方法进行逆运动学求解，将求得的结果进行运动学正解解析，得到机器人末端位置坐标，将末端位置坐标与理论位置坐标作差得到各

组数据点对应的位置误差，结果如图 7 所示，不同算法求得的位置误差见表 2。由表 2 对三种方法求空间位置坐标误差比较可知，基于改进遗传优化 BP 神经网络法求解位置坐标误差最小，求解效果最好。




图 7 不同算法下的位置误差曲线

表 2 不同算法求得的位置误差

算法	平均位置误差/mm		
	x 方向	y 方向	z 方向
数值法	0.0347	0.0457	0.0418
BP 神经网络	0.0132	0.0206	0.0207
改进 BP 网络	0.0072	0.0061	0.0066

3.2 实验系统构建

本文为验证基于改进神经网络的机器人逆解与轨迹精度提高方法的有效性，参考文献[2]构建了实验系统，如图 8 所示。该系统主要包括新松 SR4C 型工业机器人样机、Leica AT960 激光跟踪仪，以及上位机控制软件。机器人重复定位精度为 0.03 mm，工作

范围为半径为 672.80 mm 的球体;跟踪仪测量精度为 $10\ \mu\text{m}$,数据采集速率为每秒 1000 个点。基于构建的系统分别进行了位置误差对比实验和轨迹精度测量实验。




图8 实验系统照片

3.3 位置误差对比实验

该实验的目的是验证改进遗传算法优化 BP 神经网络的逆解效果的有效性。在机器人工作空间随机选取 50 个位姿点,分别采用数值法、BP 神经网络法以及改进遗传优化 BP 神经网络法对 50 个位姿点求逆解,将求得的 50 组关节角依次输入机器人控制器中,控制机器人运动,同时利用跟踪仪测量并读取这 50 组关节角的实际位置。计算出实际位置与理论位置之间的误差,根据位置误差的大小来反映不同方法逆解的效果。

位置误差对比实验结果如图 9 所示,图中显示:数值法逆解后机器人空间 50 个点的平均位置误差为 1.414 mm,BP 神经网络法逆解后平均位置误差为 0.451 mm,改进遗传优化 BP 神经网络法逆解后平均位置误差为 0.178 mm。这表明改进遗传算法优化 BP 神经网络提高机器人逆解精度的有效性。




图9 不同算法下机器人末端位置误差曲线

3.4 轨迹精度提高方法实验

本文为验证所提出的改进 Sigmoid 函数的神经

网络 PID 控制方法在提高机器人轨迹精度的可行性与有效性,在改进遗传优化神经网络的逆解基础上,进行了两种控制方法下机器人运动轨迹精度对比实验。具体实验步骤如下:

a) 在轨迹规划中规划出以下两种轨迹:一种是使机器人从起点位置 $(500.00, 30.00, 60.00)\text{ mm}$ 到终点位置 $(500.00, -58.00, 60.00)\text{ mm}$,过中间路径点 1 $(556.56, -50.00, 716.56)\text{ mm}$ 和路径点 2 $(443.45, -50.00, 603.45)\text{ mm}$ 做圆弧轨迹运动;另一种是使机器人从点 $(580.00, 30.00, 740.00)\text{ mm}$ 到点 $(420.00, -130.00, 80.00)\text{ mm}$ 做直线轨迹运动。

b) 机器人主控制器采用了基于 X86 架构的 Linux 操作系统,实现了对机器人的实时控制。在机器人运动过程中根据系统设置的采样周期,实时采集各关节电机的编码值,并通过 EtherCAT 总线通信协议保存到机器人控制软件中进行数据处理。

c) 将控制器中 PID 参数设为 $K_P=10, K_I=0, K_D=5$ 。让机器人沿期望轨迹运动,再根据反馈的位置偏差数据进行改进 Sigmoid 函数 PID 参数优化,将优化后的控制参数更改到控制器中,让机器人继续沿着期望轨迹运动。

d) 采用不同的控制参数控制机器人沿期望圆弧和直线轨迹循环运动 10 次,速度均保持 50 mm/s,运动过程中由激光跟踪仪实时动态采集测量机器人末端位置坐标,并按照《工业机器人 性能规范及其试验方法》(GB/T 12642—2013)中关于工业机器人轨迹精度的评定方式,通过计算理论轨迹点与实际轨迹集群的中心线之间的距离最大偏差作为轨迹准确度 P_{AT} ,以对比迭代补偿前后对机器人圆弧与直线轨迹精度提高的效果。

将改进 Sigmoid 函数神经网络 PID 控制方法用于 SR4C 机器人各关节控制,得到的圆弧轨迹运动各关节误差曲线如图 10 所示,运动中各关节最大误差如表 2 所示。实验结果表明,采用改进 Sigmoid 函数 PID 控制后各关节最大误差值小于 PID 控制,各关节误差减小效果均优于 $2.05 \times 10^{-2}\text{ rad}$ 。

利用跟踪仪测得的圆弧和直线轨迹精度实验结果分别如图 11 和图 12 所示,从图中可以看出:采用改进 Sigmoid 函数 PID 控制后机器人的圆弧轨迹准确度由 5.75 mm 提高至 2.29 mm,直线轨迹准确度由 5.32 mm 提高至 1.65 mm。这表明提出的改进 Sigmoid 函数 PID 控制方法相较于传统 PID 控制方法可有效提高机器人运动轨迹精度。

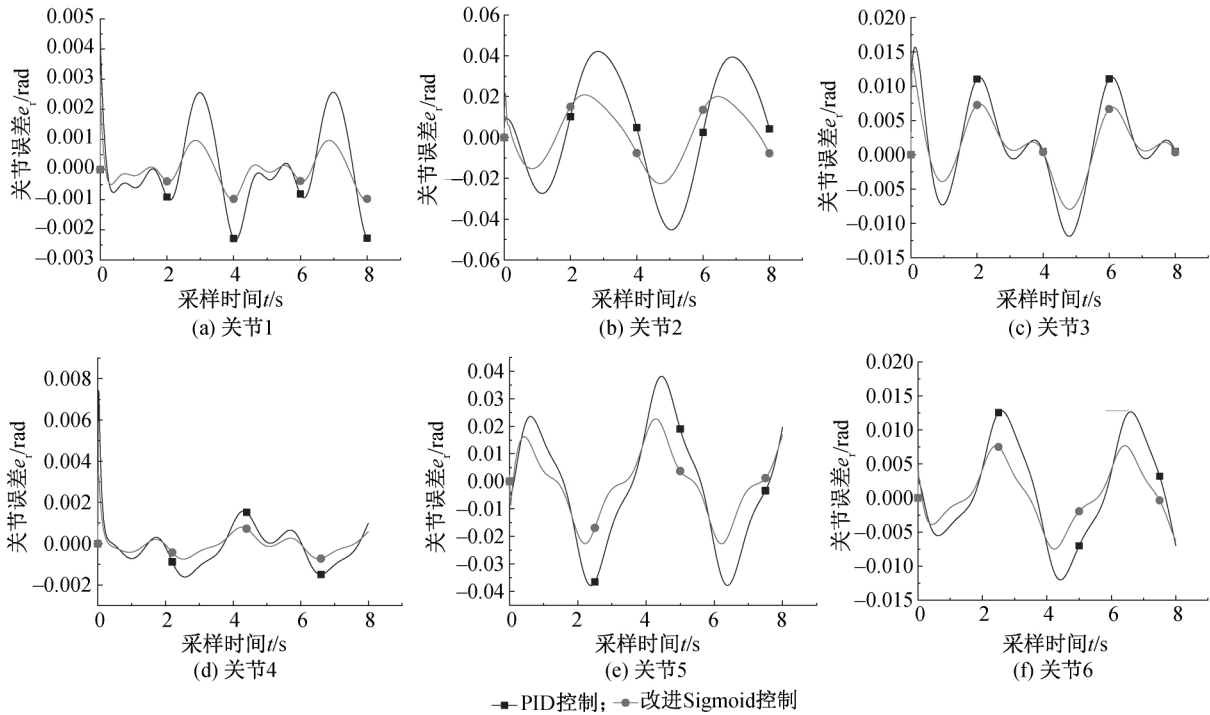


图 10 各关节轨迹误差曲线

表 2 各关节最大误差 rad

关节编号	PID 控制	改进 Sigmoid 控制
1	0.0042	0.0031
2	0.0421	0.0216
3	0.0157	0.0135
4	0.0074	0.0034
5	0.0381	0.0227
6	0.0128	0.0077




图 12 直线轨迹精度对比实验结果




图 11 圆弧轨迹精度对比实验结果

4 结 论

本文提出了基于改进神经网络的机器人逆解与轨迹精度提高方法,通过改进遗传算法优化 BP 神经网络来提高机器人逆解精度,并采用改进 Sigmoid 函数的神经网络 PID 控制方法来提高机器人运动轨迹精度。基于构建的实验系统,分别进行了机器人末端位置误差对比与运动轨迹精度提高方法的实验,实验结果显示:提出的逆解和控制方法可使得机器人位置误差减小 1.236 mm,圆弧和直线

轨迹精度分别提高了61%和68%。研究结果表明,本文提出的方法可有效提高SR4C型机器人逆解的精度和运动轨迹的精度,为工业机器人相关领域提供理论和方法参考。

参考文献:

- [1] 吴锦辉,陶友瑞.工业机器人定位精度可靠性研究现状综述[J].中国机械工程,2020,31(18):2180-2188.
- [2] 唐尧,张恩政,陈本永,等.基于运动学分析的工业机器人轨迹精度补偿方法[J].仪器仪表学报,2020,41(3):175-183.
- [3] Fu J X, Gao F, Chen W X, et al. Kinematic accuracy research of a novel six-degree-of-freedom parallel robot with three legs[J]. Mechanism and Machine Theory, 2016, 102: 86-102.
- [4] 王琨,骆敏舟,曹毅,等.基于多变量预测补偿的机械臂精度提升方法[J].电子测量与仪器学报,2014,28(11):1213-1221.
- [5] 于凌涛,王文杰,王正雨,等.一类不满足Pieper准则的机器人逆运动学解析解获取方法[J].机器人,2016,38(4):486-494.
- [6] 韩磊,刁燕,张希斌,等.基于改进牛顿迭代法的手腕偏置型六自由度关节机器人逆解算法[J].机械传动,2017,41(1):127-130.
- [7] de Oliveira A S, de Pieri E R, Moreno U F, et al. A new approach to singularity-free inverse kinematics using dual-quaternionic error chains in the Davies method[J]. Robotica, 2016, 34(4): 942-956.
- [8] 葛开友,程希为,张建法,等.基于神经网络的踝关节康复并联机器人的逆运动学的精确求解[J].中国医疗设备,2020,35(3):33-36.
- [9] El-Sherbiny A, Elhosseini M A, Haikal A Y. A comparative study of soft computing methods to solve inverse kinematics problem[J]. Ain Shams Engineering Journal, 2018, 9(4): 2535-2548.
- [10] Karkalos N E, Markopoulos A P, Dossis M F. Optimal model parameters of inverse kinematics solution of a 3R robotic manipulator using ANN models[J]. International Journal of Manufacturing, Materials, and Mechanical Engineering, 2017, 7(3): 20-40.
- [11] 刘世平,曹俊峰,孙涛,等.基于BP神经网络的冗余机械臂逆运动学分析[J].中国机械工程,2019,30(24):2974-2977.
- [12] Knospe C. PID control[J]. IEEE Control Systems Magazine, 2006, 26(1): 30-31.
- [13] Garcia-Martínez J R, Cruz-Miguel E E, Carrillo-Serrano R V, et al. A PID-type fuzzy logic controller-based approach for motion control applications[J]. Sensors, 2020, 20(18): 5323.
- [14] Yen V T, Nan W Y, Van Cuong P, et al. Robust adaptive sliding mode control for industrial robot manipulator using fuzzy wavelet neural networks[J]. International Journal of Control, Automation and Systems, 2017, 15(6): 2930-2941.
- [15] 张铁,李昌达,覃彬彬,等. SCARA 机器人的自适应迭代学习轨迹跟踪控制[J].中国机械工程,2018,29(14):1724-1729.
- [16] 李昌达. 工业机器人的运动轨迹规划和轨迹跟踪控制[D]. 广州:华南理工大学,2018:49-65.

(责任编辑:康 锋)