

# 基于ISSA-LSSVR的6-DoF机器人 定位精度补偿研究

于华宇<sup>1</sup>, 朱文福<sup>2</sup>, 辛博<sup>1</sup>, 孙俊峰<sup>1</sup>

(1. 东北大学 机械工程与自动化学院, 辽宁 沈阳 110819; 2. 沈阳飞机工业(集团)有限公司, 辽宁 沈阳 110000)

**摘要:** 为提高6自由度(6-DoF)机器人的定位精度, 提出一种6-DoF机器人定位误差预测和精度补偿方法. 介绍了在机器人的高频工作区内的分层逐行采样方法, 并建立累积测量误差修正公式提高测量的准确性. 实测证明机器人工作位置直接影响绝对误差. 为此, 提出了基于改进麻雀搜索算法优化最小二乘支持向量回归(ISSA-LSSVR)算法的误差补偿模型, 预测和修正机器人自身定位误差. 结果表明, 相较于支持向量回归(SVR)、最小二乘支持向量回归(LSSVR)和麻雀搜索算法优化最小二乘支持向量回归(SSA-LSSVR)算法, 基于ISSA-LSSVR算法的误差补偿效果最好, 机器人的绝对误差降低了65.68%, 最大误差降低了68.95%.

**关键词:** 6自由度机器人; 误差测量; 累积测量误差; ISSA-LSSVR算法; 误差补偿

**中图分类号:** TP 242.2; TP 391 **文献标志码:** A **文章编号:** 1005-3026(2025)12-0048-09

## Research on Positioning Accuracy Compensation of 6-DoF Robots Based on ISSA-LSSVR

YU Hua-yu<sup>1</sup>, ZHU Wen-fu<sup>2</sup>, XIN Bo<sup>1</sup>, SUN Jun-feng<sup>1</sup>

(1. School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China; 2. Shenyang Aircraft Industry (Group) Co., Ltd., Shenyang 110000, China. Corresponding author: XIN Bo, E-mail: xinbo@me.neu.edu.cn)

**Abstract:** To enhance the positioning accuracy of six-degree-of-freedom (6-DoF) robots, a method for predicting and compensating for positioning errors of the 6-DoF robot was proposed. A hierarchical line-by-line sampling strategy in the high-frequency workspace of the robot was introduced, and a cumulative measurement error correction formula was established to improve measurement accuracy. Experimental results demonstrate that the robot's working position significantly affects absolute errors. To address this issue, an error compensation model based on an improved sparrow search algorithm-optimized least squares support vector regression (ISSA-LSSVR) was developed to predict and correct the robot's inherent positioning errors. The results indicate that, relative to the support vector regression (SVR) algorithm, least squares support vector regression (LSSVR) algorithm, and sparrow search algorithm-optimized LSSVR (SSA-LSSVR), the ISSA-LSSVR algorithm achieves superior compensation performance. Specifically, the absolute error is reduced by 65.68%, and the maximum error is decreased by 68.95%.

**Key words:** 6-DoF robot; error measurement; cumulative measurement error; ISSA-LSSVR algorithm; error compensation

6-DoF机器人因其良好的加工柔性和可控性被广泛应用于智能制造场景中,但由于机械结

构刚度、关节角偏差、连杆偏移误差、控制系统误差等因素的影响,致使机器人的实际运动精度难

收稿日期: 2024-06-18

基金项目: 辽宁省自然科学基金资助项目(2023-MS-085).

作者简介: 于华宇(1999—),男,江西上饶人,东北大学硕士研究生;朱文福(1982—),男,辽宁大连人,沈阳飞机工业(集团)有限公司正高级工程师;辛博(1988—),男,吉林通化人,东北大学副教授,博士生导师.

以达到精密加工的设计要求,限制了机器人的应用,亟待提高机器人的绝对定位精度<sup>[1-3]</sup>。

目前提高6-DoF机器人绝对定位精度的方法主要分为在线和离线误差补偿方式。其中,在线误差补偿是通过在机器人工具末端安装传感器实时监测并矫正机器人误差<sup>[4-5]</sup>,这种补偿方式能大幅提高机器人定位精度,但整套系统的搭建造价昂贵,且传感器的安装增加了机器人末端的复杂性。离线误差补偿的过程主要包括误差测量分析、误差矫正补偿两步。针对误差测量分析,现有研究中普遍使用激光跟踪仪对机器人空间位置进行测量标定分析<sup>[6-7]</sup>,但激光跟踪仪在连续测量过程中会产生累积测量误差,从而对测量精度造成不利影响。在误差矫正补偿方面,Gao等<sup>[8]</sup>使用粒子群优化的BP神经网络预测补偿机器人运动学参数,有效提高了机器人精度,但该方法在小样本问题中容易出现过拟合现象;王龙飞等<sup>[9]</sup>使用极限学习机(ELM)算法对机器人误差进行预测补偿,该方法补偿速度快且具有良好的泛化性能,但对异常值敏感,不适用于动态环境,且ELM算法缺乏解释性,以致提出至今仍存在争议。相较之下,支持向量回归(SVR)算法基于其统计学理论基础,且在处理小样本回归预测问题中具有很强的泛化能力<sup>[10]</sup>,薛祥儒等<sup>[11]</sup>使用粒子群优化支持向量回归(PSO-SVR)算法对机器人分级标定补偿,该方法具有坚实的理论基础且适合于解决小样本回归预测问题,但粒子群算法在面对大规模样本时容易陷入局部最优解。

近年来,国内外在6-DoF机器人定位误差补偿方面的研究主要集中于误差建模、补偿方法构建与算法优化3个方向。在误差建模方面,普遍采用激光跟踪仪进行空间测量并建立误差模型,但连续测量过程中的累积误差常被忽略,影响模型精度。在误差预测与补偿方法方面,BP神经网络、极限学习机(ELM)等方法应用较多,具有一定拟合能力,但对小样本与噪声数据敏感,泛化能力较弱。支持向量回归(SVR)及其改进形式最小二乘支持向量回归(LSSVR)因具备较强的理论基础和良好的泛化性能,逐步成为主流选择。近年来,研究者尝试将参数优化算法与回归模型结合,如粒子群优化(PSO)、遗传算法(GA)、麻雀搜索算法(SSA)等,用以提升模型的预测精度与鲁棒性,但多数优化算法存在搜索效率低、易陷入局部最优的问题,难以在复杂高维空间中获得全

局最优解。此外,现有研究多关注回归算法本身,较少考虑测量数据质量对模型训练的影响,尤其当存在测量漂移或系统性误差时,补偿模型容易产生偏移或失效。综上所述,当前误差补偿仍面临测量精度控制不足、回归模型稳定性较差、参数寻优能力有限等问题。

针对以上问题,本文提出一种离线误差补偿方法。首先,建立累积测量误差修正公式,提高误差测量分析的准确性。之后,建立基于改进麻雀搜索优化最小二乘支持向量回归(ISSA-LSSVR)算法的机器人定位误差预测模型,用于补偿机器人的定位误差。最后通过机器人误差补偿对比实验,验证本文所提方法的有效性。

## 1 机器人误差测量分析

### 1.1 机器人误差测量系统和采样点规划

机器人误差测量系统(图1)由机器人(KUKA KR 210 R2700)、机器人控制柜(KUKA KR C4)、激光跟踪仪(Leica AT403)、测量标记靶点组成。激光跟踪仪测量精度为0.006 mm。测量标记靶点安装在机器人第6轴法兰盘端面几何中心点,机器人按轨迹运行时采用间距标记法连续测量靶点空间坐标,设定机器人基坐标系为测量坐标系,坐标系原点为机器人第一轴几何中心点。运动采样点的工作空间范围设定于机器人臂展包络的扇面区内,并截取出长( $Y$ 轴)、宽( $X$ 轴)、高( $Z$ 轴)分别为1 800, 700, 1 000 mm的立方体测量区(图2),模拟机器人实际工作的高频使用空间范围。此工作区域的外部空间在实际工作中较少使用,避免机器人关节转角接近极限角度引起的形变量增大,因此不作采样。为了确保采样的有效性,对采样区域进行分层处理,并逐层划分立体网格,采样点的路径规划顺序为:以点 $P_1$ 为起点,采用光栅式往复扫描法自底向上逐层、逐行等间距采样,采样间距 $D$ 、行距 $L$ 、高度 $H$ 分别为50, 50, 100 mm。

### 1.2 累积测量误差修正

为提高机器人离线补偿的测量基础精度,需先对采样数据中可能存在的系统误差进行评估与修正。在高频作业区域中,采用激光跟踪仪对机器人运行轨迹进行连续测量时,会受到光束偏移、传感器稳定性及插补路径差异等因素的影响,产生累积误差,尤其在远距离直线段或快速往复运行阶段更明显。因此,在建立补偿模型前,

必须首先对这些潜在的系统误差进行分析和修正,确保训练数据具备稳定性和可靠性.

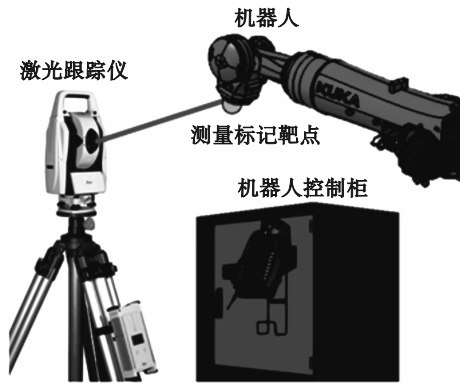


图 1 机器人误差测量系统

Fig. 1 Robot error measurement system




图 2 采样点规划

Fig. 2 Sampling point planning

通过激光跟踪仪测量机器人的定位精度,获得理论采样点与实测点的轨迹对比(图3),发现激光跟踪仪在Y轴方向累积测量误差较高,导致机器人往复运动的各拐点处出现明显偏差(最大偏差接近20 mm).这是由于机器人在点到点的直线运动中存在系统性偏差(直线插补引起),致使激光跟踪仪靶点测量的累积距离高于采样间距 $D$ ,进而导致机器人位置的提前标定.为提高测量结果的准确性,建立累积误差修正公式:设第 $n$ 个采样点实际位置为 $C_n(x_n, y_n, z_n)$ ,理论位置为 $P_n(x'_n, y'_n, z'_n)$ .根据图4可知,机器人从首个采样点 $C_1$ 到第2个采样点 $C_2$ 产生的测量误差可表示为

$$d_1 = D - (y_2 - y_1). \quad (1)$$

随着采样点数的增加,机器人从第 $n$ 个采样点 $C_n$ 到第 $n+1$ 个采样点 $C_{n+1}$ 产生的累积测量误差为

$$d_n = nD - \sum_{i=1}^n (y_{i+1} - y_i) = nD - (y_n - y_1). \quad (2)$$

进而获得修正后采样点的Y轴坐标为 $y'_n - d_n$ ,降低拐点处的测量偏差.




图 3 理论采样点与实测点的轨迹对比

Fig. 3 Comparison of trajectory between theoretical sampling points and measured points




图 4 测量误差的产生和累积

Fig. 4 Generation and accumulation of measurement errors

### 1.3 误差变化规律分析

根据式(1),式(2)求解沿Z轴正方向分为11层排列、沿X轴正方向分为15行排列的6 017个测量点样本,每组样本间通过向量形式可以将误差表示为

$$e_n = C_n - P_n = (x_n - x'_n, y_n - y'_n, z_n - z'_n). \quad (3)$$

令 $\Delta x_n = x'_n - x_n$ ,  $\Delta y_n = y'_n - y_n$ ,  $\Delta z_n = z'_n - z_n$ ,则每组样本间的绝对误差为

$$E_n = \sqrt{(\Delta x_n^2 + \Delta y_n^2 + \Delta z_n^2)}. \quad (4)$$

计算测量后得到机器人绝对误差的极值和均值分别为(0.008~0.472) mm, 0.172 mm.为了分析绝对误差变化规律,将所有测量点样本按测量样本序号排列(图5),即6 017组数据随样本序号由低到高被分成11层,随着层数的上升,绝对误差整体呈增大趋势.此外,除去第1~3层误差变化不太明显外,其余每层误差变化规律基本相同,即随着样本序号的增加,绝对误差呈增大趋势.如图6所示,抽取2层(第4、第6层),每一层都是长(Y轴)、宽(X轴)分别为1 800 mm, 700 mm的区域,采样间距 $D$ 、行距 $L$ 分别是50,

50 mm, 故共有  $\left(\frac{1800}{50} + 1\right) \times \left(\frac{700}{50} + 1\right) = 555$  组数据, 即图 6 的横坐标. 从图 2 可以看出, 这些样本序号在沿 X 轴方向是递增的, 而在沿 Y 轴方向是先递增后递减往复进行的. 所以在图 6 中以 X 轴方向划分区域, 划分成  $\frac{700}{50} + 1 = 15$  个区域, 即

为图 6 中用虚线分开的若干区域, 每一个区域都是一条沿 Y 轴方向上的采样点系列 (是一条由  $\frac{1800}{50} + 1 = 37$  个点组成的直线). 在这 15 个区域中可分析 Y 轴坐标对绝对误差的影响规律, 测量点样本沿 Y 轴正、负方向均呈先增后减的趋势, 且在 Y=0 处达到最大值.




图 5 测量点样本的绝对误差

Fig. 5 Absolute error of measured point samples




图 6 第 4、第 6 层测量点样本的绝对误差

Fig. 6 Absolute error of measured point samples in the 4th and 6th layers

(a) — 第 4 层测量点样本; (b) — 第 6 层测量点样本.

由于已求解的采样点绝对误差属于无方向的标量, 还需要进一步分析机器人 X, Y, Z 轴方向的矢量误差. 将测量点样本 X, Y, Z 轴方向误差的

概率密度函数进行分布拟合, 如图 7 所示, 发现符合正态分布, 满足机器学习回归预测条件.




图 7 误差概率密度分布拟合结果

Fig. 7 Distribution fitting results of error probability density

(a) — X 轴方向误差正态分布拟合; (b) — Y 轴方向误差正态分布拟合; (c) — Z 轴方向误差正态分布拟合.

## 2 基于改进 SSA-LSSVR 算法的机器人误差补偿方法

### 2.1 基于 LSSVR 算法的回归模型建立

SVR 算法是一种支持向量机(SVM)的回归方法,机器人误差的非线性变化规律可通过 SVR 算法回归预测.与传统线性回归方法不同,SVR 算法采用非线性的核技巧和在不敏感损失函数,通过寻找最优的超平面使得训练样本在边界内部尽可能地接近给定的误差范围<sup>[12]</sup>.但传统 SVR 算法在面对大规模数据集时,算法性能会随着数据集的增大而下降,易受样本异常点干扰<sup>[13-14]</sup>.在机器人定位精度补偿问题中,由于采样点数据可能受到测量误差或系统性误差的影响,SVR 算法在处理这些带有噪声的数据时,容易出现预测精度下降的问题.此外,SVR 算法在处理高维数据时计算复杂度较高,导致训练时间显著增加.为确保模型预测的稳定性,采用鲁棒性更优的 LSSVR 算法分析异常样本点,具体地,以测量点理论位置  $P_n(x'_n, y'_n, z'_n)$  作为特征输入自变量  $x$ ,分别以机器人  $X, Y, Z$  方向的误差  $\Delta x_n, \Delta y_n, \Delta z_n$  作为输出量,构建出输出量分别为  $\Delta x_n, \Delta y_n, \Delta z_n$  的样本集合  $\{(x_i, \Delta x_i), i=1, 2, \dots, n\}$ ,  $\{(x_i, \Delta y_i), i=1, 2, \dots, n\}$ ,  $\{(x_i, \Delta z_i), i=1, 2, \dots, n\}$ ,  $x_i \in \mathbf{R}^3$ .对 3 个样本集合分别构建线性回归函数:

$$f(x) = \mathbf{w}^T \varphi(x) + b. \quad (5)$$

式中:  $\mathbf{w}$  为将样本数据映射到高维空间之后对应权重的向量系数;  $\varphi(x)$  为非线性映射函数;  $b$  为偏差量.

采用结构风险最小化准则,式(5)可以转换为

$$\left. \begin{aligned} \min_{\mathbf{w}, b, \zeta} J(\mathbf{w}, \zeta) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} r \sum_{i=1}^n \zeta_i^2, \\ \text{s.t. } y_i &= \mathbf{w}^T \varphi(x_i) + b + \zeta_i, i=1, 2, \dots, n. \end{aligned} \right\} \quad (6)$$

式中:  $J$  为目标函数,表示风险最小化准则下的优化目标;  $\zeta$  为松弛变量;  $\zeta_i$  为第  $i$  个样本对应的松弛变量;常数  $r$  为惩罚因子,  $r > 0$ .

为简化计算,引入 Lagrange 乘子  $\alpha_i$ ,将目标函数(6)转化为

$$\mathcal{L}(\mathbf{w}, b, \zeta, i) = J(\mathbf{w}, \zeta) - \sum_{i=1}^n \alpha_i (\mathbf{w}^T \varphi(x_i) + b + \zeta_i - y_i). \quad (7)$$

根据 KKT(Karush-Kuhn-Tucker)优化条件可得

$$\left. \begin{aligned} \frac{\partial \mathcal{L}}{\partial \mathbf{w}} = 0 &\Rightarrow \mathbf{w} = \sum_{i=1}^n \alpha_i \varphi(x_i), \\ \frac{\partial \mathcal{L}}{\partial b} = 0 &\Rightarrow \sum_{i=1}^n \alpha_i = 0, \\ \frac{\partial \mathcal{L}}{\partial \zeta_i} = 0 &\Rightarrow \alpha_i = r \zeta_i, \\ \frac{\partial \mathcal{L}}{\partial \alpha} = 0 &\Rightarrow \mathbf{w}^T \varphi(x_i) + b + \zeta_i - y_i = 0. \end{aligned} \right\} \quad (8)$$

将式(8)消去变量  $\mathbf{w}$  和  $\zeta_i$  得到矩阵方程:

$$\begin{bmatrix} \mathbf{0} & \mathbf{I}^T \\ \mathbf{I} & \mathbf{\Omega} + \frac{1}{r} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ \mathbf{y} \end{bmatrix}. \quad (9)$$

式中:  $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$ ;  $\mathbf{I} = [1, 1, \dots, 1]^T$ ;  $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ ;  $\mathbf{\Omega}$  为  $n$  维方阵,  $\Omega_{i,j} = \varphi(x_i) \cdot \varphi(x_j)$ ,  $i, j = 1, 2, \dots, n$ .

通过最小二乘法求解式(9)中的  $b$  和  $\boldsymbol{\alpha}$ ,为避免计算非线性映射函数  $\varphi(x)$ ,引入核函数  $K(x, x_i)$ ,使函数的求解直接在输入空间进行,最后得到被估计函数为

$$f(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b. \quad (10)$$

泛径向基核函数(RBF)具有良好的非线性拟合能力和泛化性能,特别适用于输入变量与输出变量间复杂非线性关系的建模,故式(10)中核函数选用 RBF:

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\delta^2}\right). \quad (11)$$

式中,  $\delta$  为控制核函数宽度的参数,可调整模型对特定问题的灵敏度.

LSSVR 算法结构(图 8)与神经网络模型相似,但 LSSVR 算法直接通过支持向量的组合来构建回归模型,可提高算法的训练速度,区别于神经网络模型使用的隐藏层和激活函数.与神经网络相比, LSSVR 算法在处理大规模数据集时具有更高的计算效率,并且避免了反向传播和梯度下降等复杂过程,能够更快地收敛到最优解.




图 8 LSSVR 算法结构

Fig. 8 LSSVR algorithm structure

### 2.2 基于麻雀搜索算法(SSA)的 LSSVR 算法参数优化

LSSVR 算法中的惩罚因子  $r$  和核函数宽度参数  $\delta$  直接影响模型性能,其中  $r$  控制模型的训练误差,增大  $r$  值能减小训练误差,但  $r$  值过大时模型对训练数据过于敏感导致过拟合,泛化能力较差;  $\delta$  对模型性能的影响效果与  $r$  相同,较

大的  $\delta$  能提高拟合能力,但  $\delta$  过大也会降低模型的泛化能力.为了提高模型的训练精度和鲁棒性,此处引入麻雀搜索算法(SSA)优化参数组合  $r$  和  $\delta$ .

SSA 是一种模拟麻雀觅食和逃避行为的优化算法<sup>[15]</sup>,通过个体的合作和竞争机制实现全局和局部搜索,具有良好的寻优能力和较快的收敛速度.其参数优化过程为:在多维空间内随机生成一定数量的参数初始解(麻雀种群),根据当前每个初始解(麻雀位置)的好坏更新参数解:

$$X_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \exp\left(\frac{-i}{\rho I_{\max}}\right), R_2 < S_{\text{safe}}; \\ x_{i,j}^t + QL, R_2 \geq S_{\text{safe}}. \end{cases} \quad (12)$$

式中:  $x_{i,j}^t$  为第  $i$  个解在第  $j$  维的第  $t$  次迭代的参数解;  $\rho$  为 0~1 之间的随机数;  $I_{\max}$  为最大迭代次数;  $R_2$  为预警值;  $S_{\text{safe}}$  为安全值;  $Q$  为服从正态分布的随机数;  $L$  表示  $1 \times d$  维元素均为 1 的矩阵.

为保证计算出的参数解的可靠性,将计算出来不好的解(掠食者位置)作为边限定以缩小并更新参数寻优范围:

$$X_{i,j}^{t+1} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), i > \frac{n}{2}; \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| A^+ L, i \leq \frac{n}{2}. \end{cases} \quad (13)$$

式中:  $X_{\text{worst}}^t$  为第  $t$  次迭代的边界位置;  $X_p^{t+1}$  为第  $t+1$  次迭代发现者的最优位置;  $A$  为元素随机为 -1 或 1 的  $1 \times d$  维矩阵,且  $A^+ = A^T(AA^T)^{-1}$ .

将惩罚因子  $r$  的搜索范围设为  $[1, 1000]$ ,核函数宽度  $\sigma$  设为  $[0.01, 100]$ ,种群规模设为 30,最大迭代次数为 100.在 SSA 搜索过程中,以均方根误差(RMSE)作为适应度函数目标,搜索过程中模型误差逐步下降并收敛.最终获得  $r$  和  $\sigma$  的一组最优解组合.由于模型训练结果受初始种群及随机搜索路径影响,优化结果在  $r \approx 400 \sim 600$ ,  $\sigma \approx 8 \sim 15$  区间内, RMSE 较基线模型下降约 10%~15%.

最后在上述过程的基础上计算寻找出全局最优解,并通过设定的终止条件(如达到最大迭代次数、适应度满足要求等),判断是否满足结束搜索的条件.如果满足条件,则结束搜索过程,否则继续进行迭代.

### 2.3 改进麻雀搜索算法(ISSA)

SSA 的求解效率和搜索能力很大程度上依赖于初始解的生成质量,而 SSA 采取的传统随机生成策略无法保证初始解的均匀分布,这会对其搜索能力产生限制.对此采用 Tent 混沌映射策略改进初始

解的生成质量,而为了避免 Tent 混沌序列的小循环周期性的干扰,引入随机变量对其进行改进:

$$z_{i+1} = \begin{cases} 2z_i + \text{rand}(0, 1) \times \frac{1}{N_T}, 0 \leq z_i \leq \frac{1}{2}; \\ 2(1 - z_i) + \text{rand}(0, 1) \times \frac{1}{N_T}, \frac{1}{2} < z_i \leq 1. \end{cases} \quad (14)$$

式中:  $z_i$  表示第  $i$  个混沌变量(取值范围为  $[0, 1]$ );  $N_T$  为 Tent 混沌序列中的粒子个数.

将生成的混沌序列映射到 SSA 的初始解空间中:

$$X_{d,\text{new}} = j_{\min} + (j_{\max} - j_{\min}) \times z_d. \quad (15)$$

式中:  $j_{\min}, j_{\max}$  分别为第  $j$  维变量的上下限;  $z_d$  为混沌序列;  $X_{d,\text{new}}$  为混沌序列映射后的初始解; 下标  $d$  为维度索引.

此外,传统 SSA 在更新最优解的过程中存在陷入局部最优解的风险,对此,采取 Levy 飞行策略生成随机步长,以增加其跳出局部最优解能力:

$$S_{\text{step}} = \frac{u}{|v|^{\frac{1}{\beta}}}, u \sim N(0, \sigma^2), v \sim N(0, 1); \quad (16)$$

$$\sigma^2 = \begin{cases} \frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\beta \cdot \Gamma\left(\frac{1+\beta}{2}\right) \cdot 2^{\frac{\beta-1}{2}}}, 1 < \beta \leq 2. \end{cases}$$

式中:  $S_{\text{step}}$  为飞行步长;  $u, v$  为随机数;  $\Gamma$  为伽马函数,  $\Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt; 0 < \beta < 2$ .

改进后的 SSA 参数解更新公式为

$$X_{i,j}^{t+1} = \begin{cases} L_{\text{Levy}}(\beta) + x_{i,j}^t \exp\left(\frac{-i}{\alpha I_{\max}}\right), R_2 < S_{\text{step}}; \\ x_{i,j}^t + QL, R_2 \geq S_{\text{step}}. \end{cases} \quad (17)$$

式中,  $L_{\text{Levy}}(\beta)$  表示 Levy 飞行策略的步长分布函数.

### 2.4 基于 ISSA-LSSVR 算法的预测补偿步骤

基于改进麻雀搜索算法优化最小二乘支持向量回归(ISSA-LSSVR)的机器人预测补偿方法通过 ISSA-LSSVR 算法分别预测机器人  $X, Y, Z$  方向的矢量误差  $\Delta x_n, \Delta y_n, \Delta z_n$ ,再将预测的误差结果对机器人理论加工点补偿以提高机器人定位精度.以  $X$  方向矢量误差  $\Delta x_n$  的预测补偿为例,具体步骤如下:

1) 构建训练集和测试集.分别将测量点样本和需要补偿的机器人加工点的理论位置作为训练集和测试集,并分别以机器人的  $X, Y, Z$  理论坐标和矢量误差  $\Delta x_n$  作为输入和输出,将训练集进行数据归一化处理.

2) 提取最优参数.利用 ISSA 搜索最优的  $r$  和

$\varepsilon$  参数组合,提高 LSSVR 算法的回归性能.

3) LSSVR 模型训练. 利用 ISSA 优化后的 LSSVR 算法对测试集预测,对预测数据反归一化得到误差预测结果  $\Delta x_{np}$ .

4) 误差补偿. 将预测结果代入待补偿的机器人加工点进行补偿:

$$x_c = x'_n + \Delta x_{np}, \tag{18}$$

式中,  $x_c$  为机器人补偿后的  $X$  坐标;  $x'_n$  为理论  $X$  坐标.

同理即可实现机器人  $Y$  方向和  $Z$  方向的误差预测补偿.

与传统回归方法相比,本文所提出的 ISSA-LSSVR 算法通过 Tent 混沌映射优化初始种群分布,并引入 Levy 飞行策略提升全局搜索能力,显著增强了误差预测的鲁棒性与泛化性能.

### 3 误差补偿实验验证及对比分析

为验证 ISSA-LSSVR 算法对机器人误差补偿的效果,在采样点取样空间 ( $1\ 000\text{ mm} \leq X \leq 1\ 700\text{ mm}$ ,  $-900\text{ mm} \leq Y \leq 900\text{ mm}$ ,  $800\text{ mm} \leq Z \leq 1\ 800\text{ mm}$ ) 随机选取 100 个实验点(图 9)进行误差补偿实验.

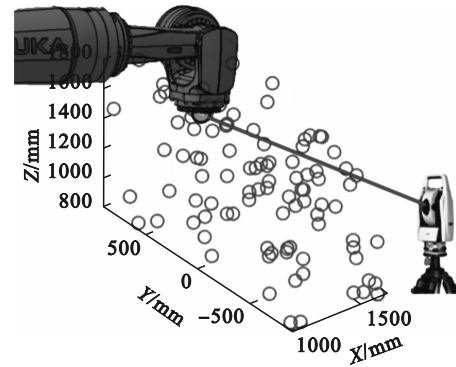


图 9 实验点位置测量

Fig. 9 Experimental point position measurement

算法预测补偿所用的训练集取自前文所测的测量点样本,测试集为实验点样本. 将  $X, Y, Z$  轴坐标作为特征输入,分别以  $\Delta x_n, \Delta y_n, \Delta z_n$  作为结果输出,再通过 ISSA-LSSVR 算法即可预测实验样本  $X, Y, Z$  坐标方向的误差,结果如图 10 所示. 可以看到实验点的各方向误差预测值与误差真实值基本重合,且误差预测结果的均方根误差(RMSE)较小,证明预测模型的准确性良好.


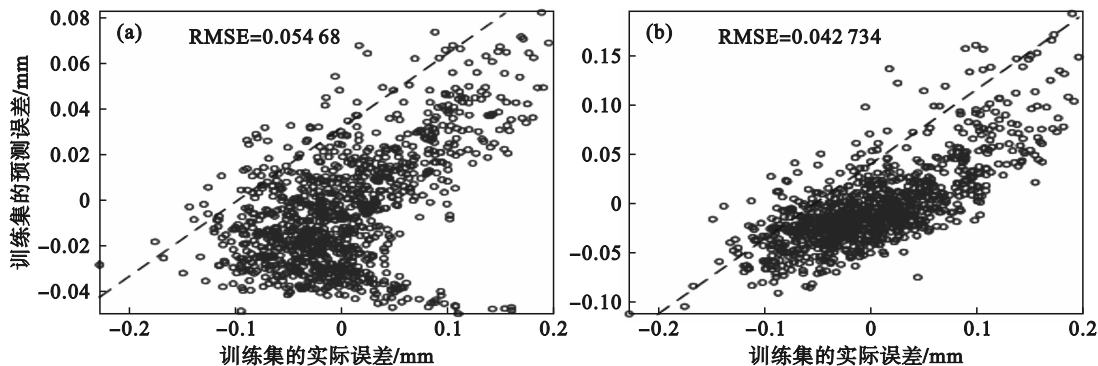


图 10 实验点各方向误差预测结果

Fig. 10 Experimental point error prediction results in all directions

为了验证 ISSA-LSSVR 算法在 6-DoF 机器人误差预测补偿方面的优越性,与 SSA-LSSVR 算法、LSSVR 算法和 SVR 算法误差预测精度进行对比. 由图 11 可知,ISSA-LSSVR 算法的拟合

度最高;且通过比较均方根误差(RMSE)可看到,ISSA-LSSVR 算法 < SSA-LSSVR 算法 < LSSVR 算法 < SVR 算法,综合证明 ISSA-LSSVR 算法的误差预测精度最好.



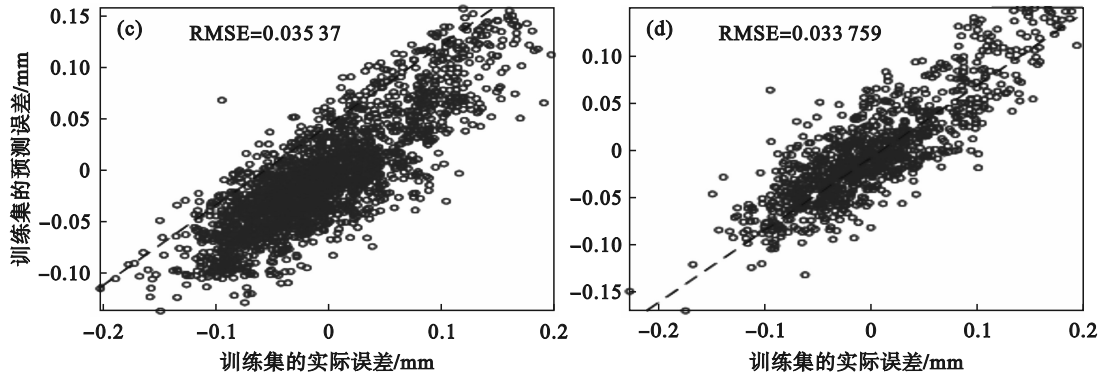


图 11 机器人 X 轴误差训练集预测精度对比

Fig. 11 Comparison of prediction accuracy of robot's X-axis error training set

(a)—SVR算法; (b)—LSSVR算法; (c)—SSA-LSSVR算法; (d)—ISSA-LSSVR算法.

图 12 为不同算法对机器人误差的补偿能力,从图中可以看出,机器人的绝对误差在经过算法补偿后均有明显降低,其中 ISSA-LSSVR 算法补偿后的误差降低最为显著,且具有良好的稳定

性.结合表 1 中的平均绝对误差和方差可以看到:ISSA-LSSVR 算法 < SSA-LSSVR 算法 < LSSVR 算法 < SVR 算法,进一步说明 ISSA-LSSVR 算法的补偿效果最好.




图 12 补偿后误差对比

Fig. 12 Error comparison after compensation

表 1 不同 SVR 算法的补偿效果

Table 1 Compensation effect of different SVR algorithms

算法	绝对误差最大值/mm	绝对误差平均值/mm	方差/mm <sup>2</sup>
未补偿	0.3804	0.1694	0.0054
SVR	0.2070	0.0809	0.0018
LSSVR	0.1648	0.0693	0.0011
SSA-LSSVR	0.1331	0.0594	0.0007
ISSA-LSSVR	0.1184	0.0575	0.0006

## 4 结 论

1) 本文通过对 6-DoF 机器人的定位误差标定测量,提出在机器人高频工作区内利用激光跟踪仪分层逐行采取测量点样本的方法,并通过修正测量过程中产生的累积测量误差,提高了测量结果的准确性.

2) 针对 6-DoF 机器人误差来源,在详细分析机器人的误差测量数据后,发现机器人位置的改

变会直接影响机器人的绝对误差.针对 6-DoF 机器人误差补偿,建立了基于 ISSA-LSSVR 算法的误差补偿模型,该模型通过最小二乘法改善了传统 SVR 算法受异常值干扰问题,并通过在 SSA 算法中引入 Tent 混沌映射、Levy 飞行策略改善了其参数优化搜索能力.

3) 为了验证 ISSA-LSSVR 算法的优越性,通过实验比较了 ISSA-LSSVR 算法与 SSA-LSSVR 算法、LSSVR 算法以及 SVR 算法在精度补偿效果方面的差异.实验结果显示,相较于其他算法

补偿,经过 ISSA-LSSVR 算法补偿后机器人的精度得到了最显著的提升,并具有良好的稳定性,机器人绝对误差从 0.169 mm 降低到 0.058 mm,降低了 65.68%,最大误差从 0.380 mm 降低到 0.118 mm,降低了 68.95%,证明基于 ISSA-LSSVR 算法精度补偿在 6-DoF 机器人精度提高方面具有显著应用价值。

#### 参考文献:

- [1] Peta K, Wlodarczyk J, Maniak M. Analysis of trajectory and motion parameters of an industrial robot cooperating with a numerically controlled machine tools [J]. *Journal of Manufacturing Processes*, 2023, 101: 1332-1342.
- [2] Liu Y, Wang D, Mi J H, et al. Advances in reliability and maintainability methods and engineering applications: essays in honor of professor Hong-zhong Huang on his 60th birthday [M]. Cham: Springer, 2023.
- [3] Zeng Y F, Tian W, Liao W H. Positional error similarity analysis for error compensation of industrial robots [J]. *Robotics and Computer Integrated Manufacturing*, 2016, 42: 113-120.
- [4] Li R, Ding N, Zhao Y, et al. Real-time trajectory position error compensation technology of industrial robot [J]. *Measurement*, 2023, 208: 112418.
- [5] Wang Z, Zhang R N, Keogh P. Real-time laser tracker compensation of robotic drilling and machining [J]. *Journal of Manufacturing and Materials Processing*, 2020, 4(3): 79.
- [6] Yang B, Yang B N, Liu J D. Research on adjustable baseline binocular vision measurement system [J]. *International Journal of Frontiers in Engineering Technology*, 2022, 4(7): 30-34.
- [7] Nubiola A, Bonev I A. Absolute calibration of an ABB IRB 1600 robot using a laser tracker [J]. *Robotics and Computer-Integrated Manufacturing*, 2013, 29(1): 236-245.
- [8] Gao G B, Liu F, San H J, et al. Hybrid optimal kinematic parameter identification for an industrial robot based on BPNN-PSO [J]. *Complexity*, 2018, 2018(1): 4258676.
- [9] 王龙飞, 李旭, 张丽艳, 等. 工业机器人定位误差规律分析及基于 ELM 算法的精度补偿研究 [J]. *机器人*, 2018, 40(6): 843-851, 859.  
(Wang Long-fei, Li Xu, Zhang Li-yan, et al. Analysis of the positioning error of industrial robots and accuracy compensation based on ELM algorithm [J]. *Robot*, 2018, 40(6): 843-851, 859.)
- [10] Ryu D, Choi O, Baik J. Value-cognitive boosting with a support vector machine for cross-project defect prediction [J]. *Empirical Software Engineering*, 2016, 21(1): 43-71.
- [11] 薛祥儒, 张承瑞, 胡天亮, 等. 基于 PSO-SVR 算法的工业机器人分级标定方法 [J]. *计算机集成制造系统*, 2023, 29(1): 51-60.  
(Xue Xiang-ru, Zhang Cheng-rui, Hu Tian-liang, et al. Hierarchical calibration method of industrial robots based on PSO-SVR algorithm [J]. *Computer Integrated Manufacturing Systems*, 2023, 29(1): 51-60.)
- [12] Liu Z Y, Xu Y K, Duan G F, et al. Accurate on-line support vector regression incorporated with compensated prior knowledge [J]. *Neural Computing and Applications*, 2021, 33(15): 9005-9023.
- [13] Yu L A, Xu H J, Tang L. LSSVR ensemble learning with uncertain parameters for crude oil price forecasting [J]. *Applied Soft Computing*, 2017, 56: 692-701.
- [14] Thomas S, Pillai G N, Pal K. Prediction of peak ground acceleration using  $\epsilon$ -SVR,  $\nu$ -SVR and Ls-SVR algorithm [J]. *Geomatics, Natural Hazards and Risk*, 2017, 8(2): 177-193.
- [15] Xue J K, Shen B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.