

并联机器人视觉盲区末端位姿检测方法

高国琴, 韩滢

(江苏大学 电气信息工程学院, 江苏 镇江 212013)

摘要: 为解决并联机器人末端执行器受机构支路遮挡造成的双目视觉盲区末端位姿错误检测问题, 提出一种运动学正解结合混合优化 RBF 神经网络 (RBFNN) 误差补偿的视觉盲区末端位姿检测方法; 首先在非视觉盲区采集 RBFNN 训练样本, 其中运动学正解为输入样本, 运动学正解和视觉检测位姿的差值为输出样本; 然后进行训练, 并采用 GWO (Grey Wolf Optimization) 算法和 LM (Levenberg-Marquardt) 算法混合优化权重; 最后将训练好的网络用于视觉盲区, 通过对运动学正解进行误差补偿以提高末端位姿检测精度; 实验结果表明, 与未补偿的检测方法相比, 混合优化 RBFNN 补偿后的末端位姿检测方法, 其末端位姿分量 x , y , z , γ 的误差平均绝对值分别降低了 54.4%、67.7%、54.7% 和 52.9%, 误差标准差分别降低了 52.9%、62.8%、51.9% 和 58.8%, 验证了所提方法的有效性。

关键词: 并联机器人; 视觉盲区; 运动学正解; RBF 神经网络; GWO 算法; 末端位姿检测

Pose Detection For Visual Blindness of Parallel Robot

Gao Guoqin, Han Ying

(School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: In the pose detection for a parallel robot based on binocular vision, error detection can be caused by end-effector being obscured by the branch of the mechanism. To solve the problem, a pose detection method for visual blindness based on the direct kinematics compensated by a hybrid optimization RBF neural network (RBFNN) is proposed. Firstly, RBFNN training samples are collected in non-visual blindness, where the direct kinematics is the input sample, and the difference value between direct kinematics and pose detected by binocular vision is the output sample. Then, grey wolf optimization (GWO) algorithm and Levenberg-Marquardt (LM) algorithm optimize the weights in the training process. Finally, the hybrid optimized RBFNN having been trained is applied to compensate the error of direct kinematics to improve the accuracy of pose detection for visual blindness. Experimental results show that compared with the uncompensated pose detection method, when the pose detection method compensated by a hybrid optimization RBFNN is applied, the mean absolute value of error for pose component x , pose component y , pose component z and pose component γ are reduced by 54.4%, 67.7%, 54.7% and 52.9%, respectively; the standard deviation of error for pose component x , pose component y , pose component z and pose component γ are reduced by 52.9%, 62.8%, 51.9% and 58.8%, respectively. The results verify the effectiveness of the proposed method.

Keywords: parallel robot; visual blindness; direct kinematics; RBF neural network; grey wolf optimization algorithm; pose detection

0 引言

目前, 机器人在水果分拣中的应用越来越广泛, 而并联机构具有结构稳定、精度高、动态性能好等优点, 因此研制了一种水果分拣并联机器人。水果分拣并联机器人分拣水果时, 末端执行器的位姿反映了机器人的运动状态且对实现闭环控制有重要意义, 因此对末端位姿的实时检测是成功抓取并分拣水果的前提。

收稿日期: 2020-02-18; 修回日期: 2020-03-19。

基金项目: 国家自然科学基金项目(51375210); 镇江市重点研发计划(GZ2018004); 江苏高校优势学科建设工程资助项目(苏政办发[2014]37号)。

作者简介: 高国琴(1965-), 女, 江苏扬州人, 教授, 博士生导师, 博士, 主要从事并联机器人控制研究和并联机器人位姿检测方向的研究。

韩滢(1994-), 女, 江苏南通人, 硕士, 主要从事并联机器人位姿检测方向的研究。

现有位姿检测方法中, 双目视觉末端位姿检测具有适用性强、性价比高等优点, 适用于难以直接检测的多运动自由度并联机器人末端位姿检测^[1]。然而并联机器人由多支路构成, 机构复杂, 在双目视觉成像中末端执行器易受到机构自身支路的遮挡, 导致双目视觉盲区末端位姿检测错误。针对双目视觉检测盲区问题, 有研究采用多目相机获取球形视野, 消除视觉盲区, 并应用于电动轮椅的安全避障和手势识别^[2], 但该方法应用于并联机器人末端位姿检测时存在相机标定困难和多幅图像难以实现高准确率匹配问题; 有研究采用一对广角鱼镜头扩大视野范围, 但该方法应用于并联机器人末端位姿检测时图像边缘畸变较大, 导致立体匹配产生较大误差^[3]。因此, 上述研究应用于水果分拣并联机器人末端位姿检测不仅对硬件要求高, 同时会带来后续图像处理难度。

为解决双目视觉盲区末端位姿错误检测的问题, 考虑采用运动学正解得到末端位姿, 然而并联机器人各部件的

加工制造误差、装配过程中产生的误差、因重力在不同位形下的变形误差等, 均会造成运动学模型建立不精确, 进而导致基于运动学模型求解出的运动学正解存在较大误差, 且该误差难以用一个准确的数学模型来描述^[4]。RBF神经网络 (RBFNN) 具有较强的预测和泛化能力, 适用于水果分拣并联机器人末端位姿检测的实时误差补偿。但 RBFNN 在进行样本训练时, 存在权值随机选取而引起的预测精度不高问题, 因此需要对权值进行优化以提高其预测精度^[5]。针对这一问题, 国内有研究提出 GWO 算法优化 RBFNN 权值并应用于模拟电路故障诊断^[6]; 国外有研究提出一种 GWO 算法优化 RBFNN 的油水相对渗透率预测模型, 并与 PSO (粒子群)、GA (遗传) 和 DE (差分进化) 算法进行对比, 验证了 GWO 算法优化 RBFNN 权值的优越性^[7]。然而上述方法应用于并联机器人末端位姿误差补偿时, GWO 算法易出现早熟收敛, 致使网络预测精度不高。为解决这一问题, 提出一种 GWO 算法和 LM 算法混合优化 RBFNN 权值的方法, 并将混合优化的 RBFNN 应用于视觉盲区, 通过对运动学正解进行误差补偿以提高末端位姿检测精度。

1 水果分拣并联机器人运动学正解

水果分拣并联机器人机构原型如图 1 所示, 该机构主要由静平台、主(辅)动平台和连接动、静平台的四组支链组成。其中, 静平台上安装有伺服电机、减速器和双目相机, 每条支链都由主动臂和从动臂组成, 主动臂与减速器通过涨紧套固定连接。利用与减速器配接的伺服电机实现主动臂转动, 从而实现末端执行器的三自由度平动和绕竖轴转动^[8]。

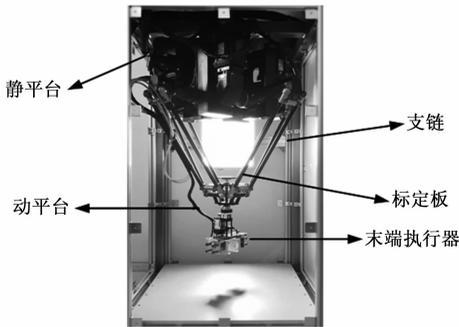


图 1 水果分拣并联机器人

为便于运动学正解求解, 将并联机器人的主体机构—Cross-IV 机械手简化为图 2 所示结构。

如图 2 所示, Cross-IV 机械手的动平台分为主平台和辅平台, 将主平台和辅平台分别简化为质点 P_1 和 P_2 , P_2 为标定板中心点, 建立参考坐标系 $O-xyz$, 原点静平台中心, 则点 P_2 在该坐标系中的位置矢量 r 可表示为:

$$r + \epsilon_i s \hat{z} = e_i + l_1 u_i + l_2 w_i, \quad i = 1 \sim 4 \quad (1)$$

式中, $\epsilon_{i=1,3} = 0, \epsilon_{i=2,4} = 1$; e_i 表示 O 到 A_i 的向量, $|e_i|$ 表示动平台与静平台的内切圆半径差, $X_i = (X_{i1}, X_{i2}, \dots, X_{in})$; γ_i 表示静平台结构角, $\gamma_i = (i-1)\pi/2$; l_1, l_2, u_i, w_i 分别

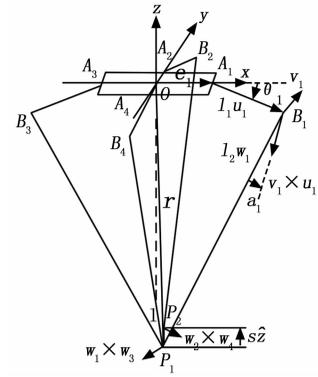


图 2 Cross-IV 机械手结构简图

表示支链 i 的主动臂和从动臂的杆长与单位矢量, 其中, $u_i = (\cos\gamma_i, \cos\theta_i, \sin\gamma_i, \cos\theta_i, -\sin\theta_i)^T$, θ_i 表示主动臂 i ($i = 1, 2, 3, 4$) 的转角。

将式 (1) 改写为:

$$l_2 w_i = r + \epsilon_i s \hat{z} - e_i - l_1 u_i \quad (2)$$

同时两端点乘各自的转置, 得:

$$l_2^2 = (r + \epsilon_i s \hat{z} - e_i - l_1 u_i)^T (r + \epsilon_i s \hat{z} - e_i - l_1 u_i) \quad (3)$$

展开公式 (3) 得:

$$x^2 + y^2 - 2(e + l_1 \cos\theta_i)(x \cos\gamma_i + y \sin\gamma_i) + (e + l_1 \cos\theta_i)^2 + (z + \epsilon_i s + l_1 \sin\theta_i)^2 - l_2^2 = 0 \quad (4)$$

公式 (4) 展开得:

$$x^2 - 2xe \cos\gamma_i + e^2 \cos^2 \gamma_i - 2l_1 x \cos\gamma_i \cos\theta_i + 2el_1 \cos^2 \gamma_i \cos\theta_i + l_1^2 \cos^2 \gamma_i \cos^2 \theta_i + y^2 - 2ye \sin\gamma_i + e^2 \sin^2 \gamma_i - 2l_1 y \sin\gamma_i \cos\theta_i + 2el_1 \sin^2 \gamma_i \cos\theta_i + l_1^2 \sin^2 \gamma_i \cos^2 \theta_i + (z + \epsilon_i s)^2 + 2l_1(z + \epsilon_i s) \sin\theta_i + l_1^2 \sin^2 \theta_i - l_2^2 = 0 \quad (5)$$

根据 θ_i ($i = 1, 2, 3, 4$) 即可求出点 P_2 的位置 (x, y, z) 和 s 。将 s 代入式 (6) 求出绕 Z 轴的转角 γ :

$$\gamma = (2\pi/p)s \quad (6)$$

2 混合优化的 RBFNN 设计

为解决 RBFNN 对视觉盲区的运动学正解进行误差补偿时存在的预测精度不高问题, 需对其网络权值进行优化。GWO 算法具有较强的全局搜索能力, 实现简单且收敛速度快^[9], 但其优化 RBFNN 权值时存在因早熟收敛而引起的网络预测精度不高问题。针对该问题, 提出一种 GWO 算法和 LM 算法混合优化 RBFNN 权值方法, 不仅能避免 GWO 算法单独优化 RBFNN 权值时出现的早熟收敛问题, 同时能利用 GWO 算法的全局优化性能和 LM 算法的局部优化性能提高 RBFNN 的预测精度。GWO 算法和 LM 算法混合优化 RBFNN 权值的过程如下:

- 1) 建立 RBFNN, 设置测试误差阈值 ϵ , 阻尼因子 μ , 阻尼系数 β , 最大迭代次数 K , 初始迭代次数 $k = 0$;
- 2) 最近邻聚类算法确定 RBFNN 基函数的中心、宽度和初始权值 w ;
- 3) 输入权值构建新的 RBFNN;

- 4) 计算网络目标误差函数 $E(x)$;
- 5) 计算雅克比矩阵 J ;
- 6) 计算权值向量调整值 Δw 并进行权值更新 $w^{k+1} = w^k + \Delta w$;
- 7) 判断是否 $E(w) < \epsilon$, 满足则结束训练, 否则执行步骤 8) ;
- 8) 计算 $E(w^{k+1})$, 判断是否 $E(w^{k+1}) < E(w^k)$, 满足则令 $\mu = \mu/\beta$, $k = k+1$, 并执行步骤 9) , 否则令 $\mu = \mu * \beta$, 并执行步骤 6) ;
- 9) 初始化灰狼种群, 最大迭代次数 T , 初始化参数 a 、 A 、 C ;
- 10) 计算种群内每个个体的适应度值, 确定 α 、 β 、 δ 灰狼 ;
- 11) 在定义域内随机产生 α 灰狼、 β 灰狼、 δ 灰狼的位置, 并计算其余灰狼 ω 位置, 更新参数 a 、 A 、 C ;
- 12) 判断是否达到最大迭代次数或精度, 若达到, 执行步骤 3) , 否则执行步骤 10)。

具体权值优化流程图如图 3 所示。

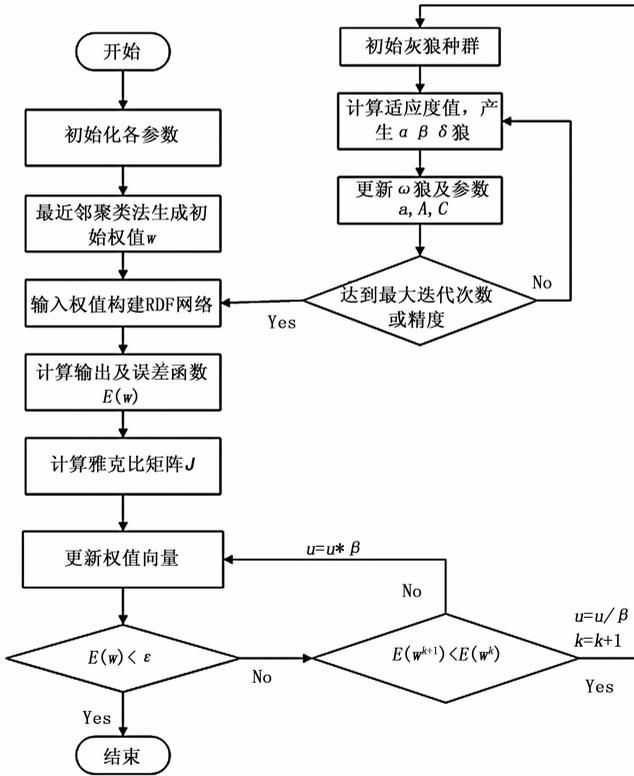


图 3 GWO 算法和 LM 算法混合优化 RBFNN 权值流程图

2.1 GWO 算法

GWO 算法通过模拟自然界中灰狼寻找、包围和攻击猎物等狩猎机制的过程来完成优化工作。如图 4 所示, 将灰狼族群划分为 4 个等级, 分别为最优灰狼 α 、次优灰狼 β 、第三优灰狼 δ 和普通灰狼 ω [10], 在追击猎物过程中, 由 α 、 β 、 δ 灰狼进行猎物追捕, 而普通灰狼 ω 跟随灰狼 α 、 β 、 δ 进行猎物围捕, 猎物的位置则是问题的最优解。

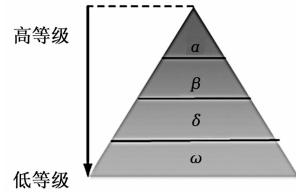


图 4 灰狼族群等级制度结构图

定义在 S 维搜索空间内第 i 只狼的位置为 $X_i = (X_{i1}, X_{i2}, \dots, X_{is})$, 其中 $(i = 1, 2, \dots, N)$, 第 i 只狼与猎物间的距离为 D_i , 则灰狼追捕猎物的行为描述如下:

$$X_i(t+1) = X_p(t) - A_i \cdot D_i \quad (7)$$

$$D_i = |C_i \cdot X_p - X_i| \quad (8)$$

式中, t 为迭代次数, $X(t)$ 表示第 t 代灰狼个体当前的位置, $X_p(t)$ 为第 t 代猎物的位置; A_i 为收敛因子, C 表示向量系数, 且:

$$A_i = 2ar_1 - a \quad (9)$$

$$C_i = 2r_2 \quad (10)$$

式中, a 随着迭代次数 t 的增加从 2 线性递减至 0; r_1, r_2 为 $[0, 1]$ 内的随机数。

定义灰狼族群向猎物追捕过程中, 灰狼个体的位置向量更新方式为:

$$D_\alpha = |C_1 \cdot X_\alpha(t) - X_\omega(t)| \quad (11)$$

$$D_\beta = |C_2 \cdot X_\beta(t) - X_\omega(t)| \quad (12)$$

$$D_\delta = |C_3 \cdot X_\delta(t) - X_\omega(t)| \quad (13)$$

$$X_1 = X_\alpha - A_1 \cdot D_\alpha \quad (14)$$

$$X_2 = X_\beta - A_2 \cdot D_\beta \quad (15)$$

$$X_3 = X_\delta - A_3 \cdot D_\delta \quad (16)$$

$$X_\omega(t+1) = (X_1 + X_2 + X_3)/3 \quad (17)$$

式中, $X_\omega(t+1)$ 表示灰狼个体更新后的位置向量。

图 5 为说明上述公式的灰狼位置更新机制原理图, 最优灰狼 α 、次优灰狼 β 和第三优灰狼 δ 对猎物的位置进行追踪, 普通灰狼 ω 以此为参考在猎物周围随机更新位置, 直到猎物在灰狼 α 、 β 或 δ 的随机圆内停止更新 [11]。

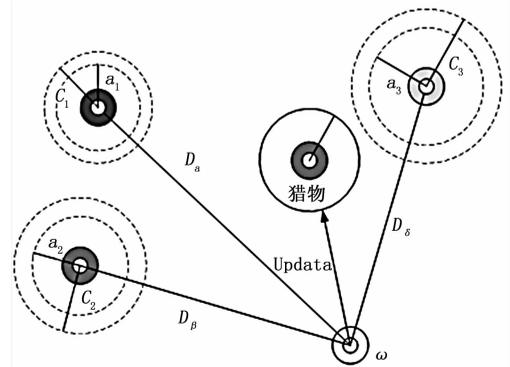


图 5 灰狼位置更新原理图

2.2 LM 算法

LM 算法是梯度下降法和高斯-牛顿法相结合的快速数值优化算法, 其局部搜索能力强, 具有局部快速收敛特

性^[12]。根据 LM 算法的基本思想, 设 $\omega_k \in \mathbf{R}_n$ 表示经过第 k 次迭代后的网络权值向量, 则新的权值向量 ω_{k+1} 可根据下面的公式求得^[13]:

$$\omega_{k+1} = \omega_k + \Delta\omega \quad (18)$$

$$\Delta\omega = -[\mathbf{J}^T(\omega)\mathbf{J}(\omega) + \mu\mathbf{I}]^{-1}\mathbf{J}^T(\omega)e(\omega) \quad (19)$$

式 (19) 中, $\mathbf{J}(\omega)$ 为 Jacobi 矩阵, $e(\omega) = (e_1, e_2, \dots, e_N)^T$ 表示误差, \mathbf{I} 为单位矩阵, n 为网络权值数量; μ 为阻尼因子。

设误差函数为:

$$E(\omega) = \frac{1}{2} \sum_{i=1}^N e_i^2(\omega) = \frac{1}{2} \sum_{i=1}^N (t_i - o_i)^2 \quad (20)$$

其中: t , o 分别为网络各输出层的实际输出和期望输出。

3 运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测

首先在非视觉盲区采样, 然后进行 RBFNN 训练, 训练中采用 GWO 算法和 LM 算法混合优化网络权值, 将训练好的混合优化 RBFNN 用于视觉盲区末端位姿检测, 通过对运动学正解进行误差补偿以提高末端位姿检测精度。

3.1 RBFNN 的训练样本

水果分拣并联机器人的工作空间较小且 RBFNN 拥有较强的泛化能力, 因此在非视觉盲区进行采样。样本包括运动学正解和视觉检测的末端位姿, 其中运动学正解为 RBFNN 训练的输入样本, 视觉检测的末端位姿与运动学正解的差值为 RBFNN 训练的输出样本。

为保证混合优化 RBFNN 的输入与输出在 $[0, 1]$ 之间, 对训练样本 $[X_o, Y_o]$ 进行归一化处理, 即:

$$x_i = \frac{x_{oi} - x_{oi, \min}}{x_{oi, \max} - x_{oi, \min}}, (i = 1, 2, \dots, n) \quad (21)$$

$$y_i = \frac{y_{oi} - y_{oi, \min}}{y_{oi, \max} - y_{oi, \min}}, (i = 1, 2, \dots, n) \quad (22)$$

式中, $x_{oi, \min}, x_{oi, \max}, y_{oi, \min}$ 与 $y_{oi, \max}$ 分别为 $[X_o, Y_o]$ 中 x_{oi} 与 y_{oi} 的最小值与最大值。

则样本学习后还原得到的网络输出 $y_{i, \text{out}}$ 为:

$$y_{i, \text{out}} = y_{oi, \min} + y_i(y_{oi, \max} - y_{oi, \min}) \quad (23)$$

3.2 GWO 算法和 LM 算法混合优化 RBFNN 权值

首先通过最近邻聚类算法^[14]确定 RBFNN 的径向基函数中心及初始权值, 然后采用 GWO 算法和 LM 算法混合优化 RBFNN 权值, 算法切换可通过精度或最大迭代步数实现。通过互以对方训练结果作为自己的初始群体或初始值, 反复交替训练, 直到达到所设置的测试误差阈值或达到训练的最大次数时输出最优权值。

3.3 运动学正解误差补偿

混合优化的 RBFNN 训练完成后, 将其用于视觉盲区的运动学正解误差补偿, 以提高视觉盲区的末端位姿检测精度。

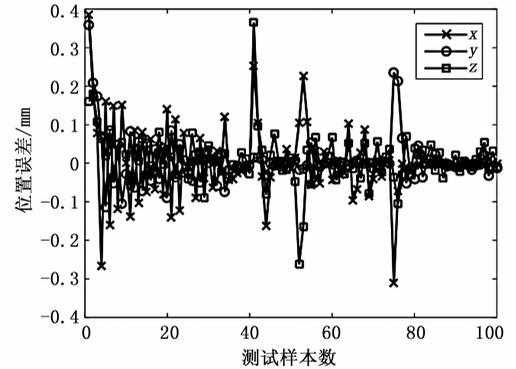
4 实验与结果分析

实验平台包括硬件平台和软件平台。硬件平台: 操作系统 Windows7, 处理器 Intel (R) Core (TM) i7-3770, 主频 3.40 GHz, 内存 8 GB。软件平台: MATLAB、VC++。

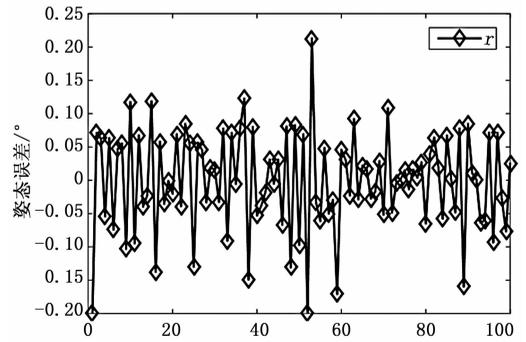
实验方法: 为验证本文提出的 GWO 算法和 LM 混合优化 RBFNN 权值方法相比于 GWO 算法优化 RBFNN 权值方法以及未优化 RBFNN 权值方法的有效性, 进行三组实验对比。在非视觉盲区采集 300 组样本数据, 将运动学正解求得的末端位姿作为 RBFNN 训练的输入样本, 视觉检测的末端位姿与运动学正解的差值作为输出样本。取 2/3 作为训练样本, 1/3 作为测试样本, 分别采用未优化的 RBFNN、GWO 算法优化的 RBFNN、GWO 算法和 LM 算法混合优化的 RBFNN 进行样本训练和测试, 并依据末端位姿 (x, y, z, γ) 各分量的测试误差对 3 种方法进行比较分析。

在视觉盲区进行末端位姿检测实验, 首先通过运动学正解得到末端位姿, 然后采用混合优化的 RBFNN 对运动学正解进行末端位姿误差补偿, 将补偿前的末端位姿和补偿后的末端位姿分别与激光跟踪仪 Leica AT901 和电子罗盘 Honeywell-HMR3100 测得的实际末端位姿进行对比, 以验证所提出的视觉盲区末端位姿检测方法的有效性。

实验结果和分析: 针对相同样本, 采用未优化的 RBFNN、GWO 算法优化的 RBFNN、GWO 算法和 LM 算法混合优化的 RBFNN 进行训练, 所得测试样本误差分别如图 6~8 所示。



(a) 位置参数 x, y, z 的测试误差



(b) 姿态参数 r 的测试误差

图 6 未优化 RBFNN 的测试样本误差

由图 6~8 分析得, GWO 算法和 LM 算法混合优化 RBFNN 的测试误差明显低于未优化的 RBFNN 和 GWO 算法优化的 RBFNN, 说明所提出的混合优化 RBFNN 的预测效果更优。

分别采用基于运动学正解的末端位姿检测方法、运动

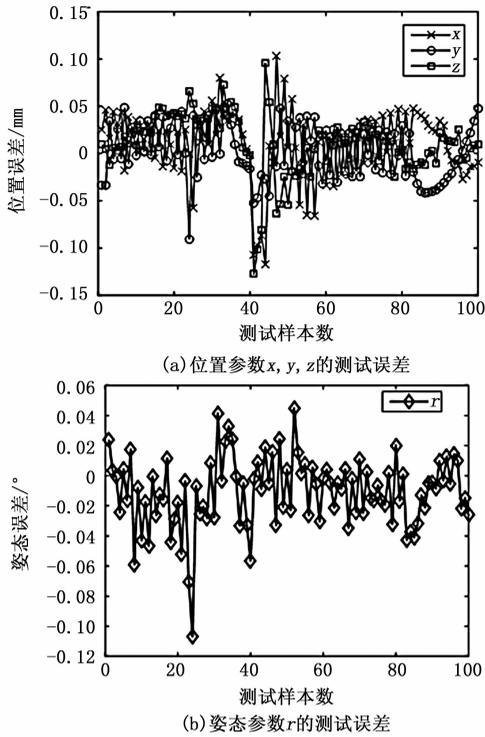


图 7 GWO 算法优化 RBFNN 的测试样本误差

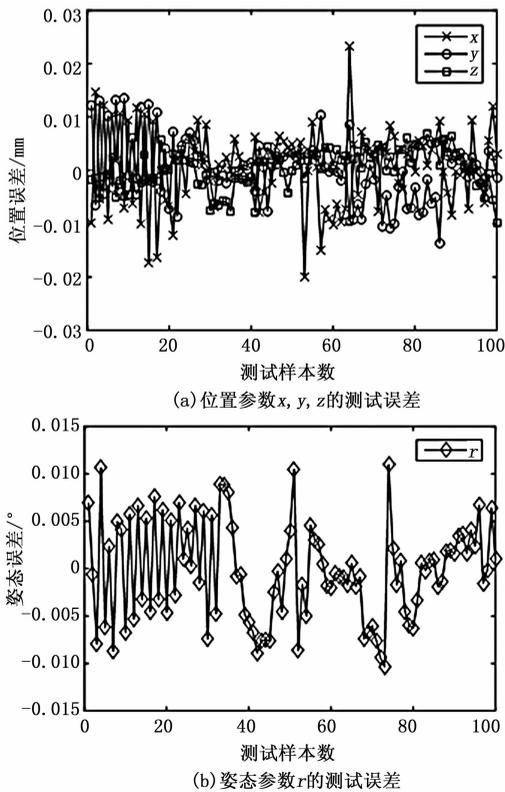


图 8 GWO 算法和 LM 算法混合优化 RBFNN 的测试样本误差

学正解结合混合优化 RBFNN 误差补偿的末端位姿检测方法完成水果分拣并联机器人视觉盲区末端位姿检测实验, 检测误差如图 9~10 所示, 图 9 为基于运动学正解的末端位

姿检测误差, 图 10 为运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测误差, 表 2 为检测误差统计结果。

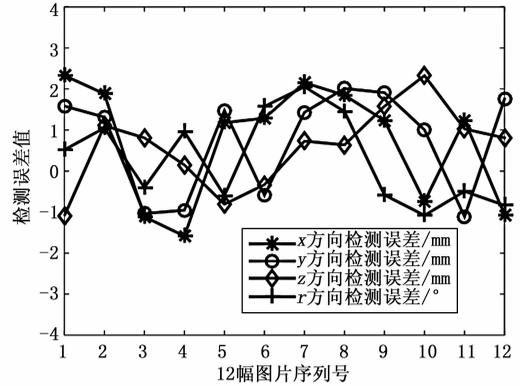


图 9 基于运动学正解的末端位姿检测误差

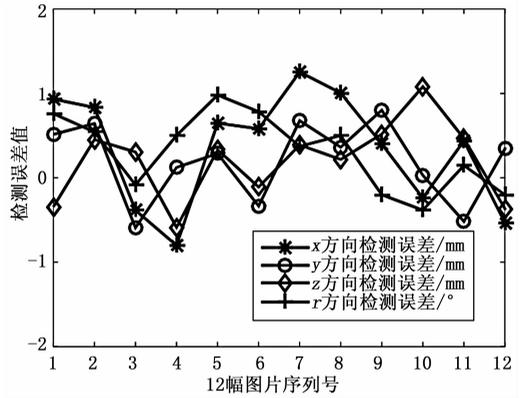


图 10 运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测误差

表 1 视觉盲区末端位姿检测误差结果统计

位姿分量		运动学	运动学正解结合混合
		正解	优化 RBFNN 误差补偿
x 误差/mm	平均绝对值	1.472	0.671
	标准差	1.365	0.643
y 误差/mm	平均绝对值	1.350	0.436
	标准差	1.204	0.448
z 误差/mm	平均绝对值	0.951	0.431
	标准差	0.931	0.448
γ 误差/ $^\circ$	平均绝对值	0.967	0.455
	标准差	1.040	0.428

由表 1 分析得, 与基于运动学正解的末端位姿检测方法相比, 运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测方法将视觉盲区末端位姿 (x, y, z, γ) 分量 x 误差的平均绝对值和标准差降低了 54.4% 和 52.9%; y 误差的平均绝对值和标准差降低了 67.7% 和 62.8%; z 误差的平均绝对值和标准差降低了 54.7% 和 51.9%; γ 误差的平均绝对值和标准差降低了 52.9% 和 58.8%。

5 结束语

为解决水果分拣并联机器人双目视觉盲区的末端位姿

错误检测问题,并提高视觉盲区的末端位姿检测精度,提出一种运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测方法。主要结论如下:

1) 针对 GWO 算法优化 RBFNN 权值时易陷入早熟收敛而引起的网络预测精度不高问题,提出了一种 GWO 算法和 LM 算法混合优化 RBFNN 权值方法,并将混合优化的 RBFNN 应用于水果分拣并联机器人双目视觉盲区末端位姿检测,通过对运动学正解进行误差补偿,不仅解决了并联机器人受机构支路遮挡造成的视觉盲区末端位姿错误检测问题,同时提高了视觉盲区的末端位姿检测精度。

2) 将基于运动学正解的末端位姿检测方法,与运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测方法进行实验对比,实验结果表明运动学正解结合混合优化 RBFNN 误差补偿的末端位姿检测方法将视觉盲区末端位姿 (x, y, z, γ) 分量 x, y, z, γ 的误差平均绝对值分别降低了 54.4%、67.7%、54.7% 和 52.9%, 误差标准差分别降低了 52.9%、62.8%、51.9% 和 58.8%。因此,所提出的末端位姿检测方法提高了视觉盲区水果分拣并联机器人的末端位姿检测精度。

参考文献:

- [1] 高国琴, 张 姝. 基于双目视觉的新型并联机构末端位姿检测[J]. 测控技术, 2016, 35 (11): 14-17.
- [2] Yutaka S, Katsuhiko S. An Omnidirectional Stereo Vision-Based Smart Wheelchair [J]. EURASIP Journal on Image and Video Processing, 2007, (7-8): 1-11.
- [3] Al-Harasis R, Sababha B H. On the Design and Implementation of a Dual Fisheye Camera-Based Surveillance Vision System [J]. Multimedia Tools and Applications, 2019.
- [4] 马 立, 于瀛洁, 程维明, 等. BP 神经网络补偿并联机器人定位误差 [J]. 光学精密工程, 2008, 16 (5): 878-883.
- [5] 陈雷雨, 岳瑞华, 王华国, 等. 基于 DEPSO-RBF 神经网络的

(上接第 99 页)
本文提出的测试方法其应用场景是实际工业环境已部署的以太网环境,而非实验室的测试环境。基于此采用的便携式低成本测试设备存在着算力不高、采样率不高的问题,会对测试产生一定的影响,有待进一步改进。

参考文献:

- [1] 孔 元, 李元轩, 黄志平, 等. 列车以太网物理层一致性测试的应用 [J]. 铁道机车车辆, 2019, 39 (1): 32-35.
- [2] IEEE 802. 3u-1995, IEEE Standards for Local and Metropolitan Area; IEEE 802. 3u [S]. 1995.
- [3] IEEE Std 802. 3-2018, IEEE Standard for Ethernet, Section ONE; IEEE 802. 3-2018 [S]. 2018.
- [4] 邓锦辉. 以太网物理层的一致性测试 [J]. 电子产品世界, 2003 (5): 86-88.
- [5] Soo D C, Bang-Sup Song. NRZ timing recovery technique for band-limited channels [J]. IEEE Journal of Solid-State Circuits, 1997, 32 (4): 514-520.

- 锌银电池 SOC 估计 [J]. 计算机测量与控制, 2015 (9): 297-299.
- [6] 颜学龙, 丁 鹏, 马 峻. 基于狼群算法的 RBF 神经网络模拟电路故障诊断 [J]. 计算机工程与应用, 2017, 53 (19): 152-156.
- [7] Menad N A, Nouredine Z, Hemmati-Sarapardeh A, et al. Modeling temperature-based oil-water relative permeability by integrating advanced intelligent models with grey wolf optimization: Application to thermal enhanced oil recovery processes [J]. Fuel, 2019, 242: 649-663.
- [8] 李玉航, 梅江平, 刘松涛, 等. 一种新型 4 自由度高速并联机械手动力尺度综合 [J]. 机械工程学报, 2014, 50 (19): 32-40.
- [9] Mirjalili, Seyedali, Mirjalili, Seyed Mohammad, Lewis, Andrew. Grey Wolf Optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [10] Wang M, Chen H, Li H, et al. Grey wolf optimization evolving kernel extreme learning machine: Application to bankruptcy prediction [J]. Engineering Applications of Artificial Intelligence, 2017, 63: 54-68.
- [11] Dai S, Niu D, Li Y. Daily peak load forecasting based on complete ensemble empirical mode decomposition with adaptive noise and support vector machine optimized by modified grey wolf optimization algorithm [J]. Energies, 2018, 11 (1): 163.
- [12] Ngia L S H, Sjoberg J. Efficient training of neural nets for nonlinear adaptive filtering using a recursive Levenberg-Marquardt algorithm [J]. IEEE Transactions on Signal Processing, 2000, 48 (7): 1915-1927.
- [13] 张昭昭, 乔俊飞, 余 文. 基于 LM 算法的在线自适应 RBF 网络结构优化算法 [J]. 控制与决策, 2017, 32 (7): 1247-1252.
- [14] 朱明星, 张德龙. RBF 网络基函数中心选取算法的研究 [J]. 安徽大学学报 (自然科学版), 2000 (1): 72-78.
- [6] Cordell R R, Forney J B, Dunn C N, et al. A 50 MHz phase-and frequency-locked loop [J]. IEEE Journal of Solid-State Circuits, 1979, 14 (6): 1003-1010.
- [7] Zhao Ren, Lizhong Gao, Bin CHANG. Eye Diagram Construction and Analysis in Digital Phosphor Oscilloscope [A]. 2010 International Conference on Intelligent Computation Technology and Automation (2010 智能计算技术与自动化国际会议 ICICTA 2010) 论文集 [C]. 2010: 1459-1462.
- [8] 杨 洋, 韩 璐, 沈小青, 等. 100Base-TX 以太网物理层一致性测试技术研究 [J]. 计算机测量与控制, 2016, 24 (9): 74-76.
- [9] Design and Implementation of Advanced Triggering in Digital Phosphor Oscilloscope [A]. Chinese Institute of Electronics (CIE). Proceedings of 2007 8th International Conference on Electronic Measurement & Instruments [C]. ICEMI' 2007.
- [10] Cordell R R, Forney J B, Dunn C N, et al. A 50 MHz phase-and frequency-locked loop [J]. IEEE Journal of Solid-State Circuits, 1979, 14 (6): 1003-1010.