doi:10.6041/j.issn.1000-1298.2025.02.017

基于 IPO - VMD - GRNN 的田间四足机器人摔倒状态预测方法

张伟荣[1,2]　陈学庚[3]　齐江涛[1,2]　周俊博[1,2]　熊悦淞[1,2]　王　硕[2,4]

(1. 吉林大学工程仿生教育部重点实验室, 长春 130022; 2. 吉林大学生物与农业工程学院, 长春 130022;
3. 石河子大学机械电气工程学院, 石河子 832003; 4. 吉林省智慧农业装备与技术重点实验室, 长春 130022)

摘要: 农业四足机器人作业环境复杂,导致其在田间行走时易摔倒,影响机器人作业效率,准确预测机身摔倒状态对机器人行走稳定性具有重要意义。提出一种基于本体传感器信号处理的机器人摔倒临界状态预测方法。首先,采集四足机器人在玉米田间行走摔倒和 Gazebo 软件模拟机器人田间行走过程摔倒状态的惯性测量传感器信号,对机器人正常行走、摔倒临界稳定状态 2 个阶段及完全摔倒的 4 种工况信号进行分类,生成不同机身状态的信号数据集。其次,采用种群优化算法(Improved population optimization, IPO)优化变分模态分解(Variational mode decomposition, VMD)参数,提出基于改进种群优化-变分模态分解(Improved population optimization - variational mode decomposition, IPO - VMD)的信号处理方法;采用 IPO 算法对广义回归神经网络(General regression neural network, GRNN)的参数进行优化,提出基于改进种群优化-广义回归神经网络(Improved population optimization - general regression neural network, IPO - GRNN)模型。最后,基于上述信号处理方法,建立基于 IPO - VMD - GRNN 模型的田间作业机器人摔倒预测方法,采用机器人实际田间行走横滚角、俯仰角作为模型测试数据,验证田间作业机器人摔倒预测模型性能。试验结果表明:提出的 IPO - VMD - GRNN 模型输出总误差为 0.146 7、平均相对误差为 0.006 5、均方误差为 0.000 3,提取的特征有良好代表性;相比 VMD - BPNN、VMD - GRNN、PSO - VMD - GRNN 模型,平均预测成功响应时间缩短 127.75、91.5、39.5 ms。该算法能提供机器人在田间行走时的机器人摔倒临界状态预测能力,可为提高四足机器人自主作业的田间通过性提供技术支撑。

关键词: 农业机器人; 四足机器人; IPO - VMD - GRNN; 变量模态分解; 摔倒状态预测

中图分类号: TP29; S24　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)02-0175-12　　**OSID**:

Predication Method of Fall State for Quadrupedal Robot in Field Based on IPO - VMD - GRNN

ZHANG Weirong[1,2]　CHEN Xuegeng[3]　QI Jiangtao[1,2]　ZHOU Junbo[1,2]　XIONG Yuesong[1,2]　WANG Shuo[2,4]

(1. *Key Laboratory of Bionic Engineering*, *Ministry of Education*, *Jilin University*, *Changchun* 130022, *China*
2. *College of Biological and Agricultural Engineering*, *Jilin University*, *Changchun* 130022, *China*
3. *College of Mechanical and Electrical Engineering*, *Shihezi University*, *Shihezi* 832003, *China*
4. *Jilin Provincial Key Laboratory of Smart Agricultural Equipment and Technology*, *Changchun* 130022, *China*)

Abstract: The complex operating environment of agricultural quadruped robots causes them to fall easily when walking in the field, which affects the operating efficiency of the robot, and accurate prediction of the body fall state is of great significance to the walking stability of the robot. A critical state prediction method for robot fall was proposed based on ontology sensor signal processing. Firstly, the inertial measurement sensor signals of the quadruped robot walking and falling in a corn field and the fall state of the robot during field walking simulated by Gazebo software were collected, and the signals of the robot's normal walking, the two phases of the critical stable state of falling and the four working conditions of complete falling were classified to generate signal datasets of different body states. Secondly, a population

收稿日期: 2024 - 11 - 28　修回日期: 2024 - 12 - 29

基金项目: 吉林省科技发展计划项目(20230508032RC)和国家自然科学基金项目(32271988)

作者简介: 张伟荣(1994—),男,博士生,主要从事精准农业与仿生智能农机装备研究,E-mail: zhangwr21@mails.jlu.edu.cn

通信作者: 齐江涛(1981—),男,教授,博士生导师,主要从事精准农业与仿生智能农机装备研究,E-mail: qijiangtao@jlu.edu.cn

optimisation algorithm was used to optimize the parameters of variational mode decomposition (VMD), and an improved population optimization - variational mode decomposition (IPO - VMD) algorithm was proposed. And IPO algorithm was adopted to optimize the parameters of general regression neural network (GRNN), and improved population optimization - general regression neural network (IPO - GRNN) was proposed. Finally, based on the above signal processing method, a fall prediction method for field operation robots based on the IPO - VMD - GRNN model was established, and the signals of the traverse roll and pitch attitude angle of the robot's actual field walking were used as the model test data to verify the performance of the fall prediction model for field operation robots. The test results showed that the IPO - VMD - GRNN model outputed a total error of 0.146 7, an average relative error of 0.006 5, and a mean square error of 0.000 3, and the extracted features were well represented; compared with the VMD - BPNN, VMD - GRNN, and PSO - VMD - GRNN models, the average prediction of a successful response time was faster than the average predicted response times of 127.75 ms, 91.5 ms, and 39.5 ms. The algorithm can provide the ability to predict the critical state of robot fall when the robot walked in the field, and the results can provide technical support to improve the field passability of quadruped robots for autonomous operation.

Key words: agricultural robot; quadruped robot; IPO - VMD - GRNN; variable modal decomposition; fall state prediction

0 引言

随着农业装备与信息技术的高度融合,农业机器人自主作业对于无人农场发展和农业生产效率提高具有重要意义[1-2]。相比传统的轮式和履带式机器人,农业四足机器人凭借腿部多自由度运动方式、灵活的机身和稳定控制策略,在田间非结构化环境下行走具备独特优势[3-4]。但是,由于田间地表情况复杂,比如行走地表湿滑或垄作模式下地表起伏较大等原因,四足机器人在田间行走存在摔倒的风险。因此,研究机器人的摔倒临界状态识别方法,进行机身摔倒阶段的识别和预测,对提升农业四足机器人的自主作业能力具有重要意义。

近年来,研究人员利用信号处理或机器学习的数据特征提取方法对机器人状态识别进行了广泛研究。闫煦[5]在研究四足机器人关节远程状态监测及故障诊断系统过程中,针对经验模态分解(Empirical mode decomposition, EMD)、集合经验模态分解(Ensemble empirical mode decomposition, EEMD)因端点效应和模态混叠限制其分解性能的问题,使用改进后的 C - EEMD 方法对采集到的状态信号进行分解,比 EEMD 具有更好的性能和更低的计算成本。ZHAO 等[6]提出了一种新型的 ESMF 算法来精确评估拐点角度,有效解决了标记点丢失问题,结果表明算法能准确计算机器人行走的膝关节角度并对拖拽步态进行识别。KERTESZ 等[7]开发了可识别索尼 AIBO 机器人正常行走和摔倒 2 种状态的机器学习模型,识别精度达 98%。此外,部分研究采用不同机器学习方式进行了机器人的故障诊断和机身状态识别[8-10],但没有涉及到机器人摔倒临界状态识别的问题。

文献[11-13]使用简化模型来分析预测跌倒,缺点为存在限定的假设条件,如固定的质量模型、预定义的惯性参考点等,方法在复杂情况下适用性有限。

有研究人员使用机器人系统的完整动态模型来预测摔倒情况。MUMMOLO 等[14]基于单腿模型的关节空间和笛卡尔空间动力学,利用完整动态模型及约束,通过迭代优化确定平衡与摔倒的机身状态,可识别足式机器人的正常行走、摔倒临界和已摔倒状态。ATKESON 等[15]通过机器人模型,捕捉其受外力导致的校正捕获点偏移量,判定当校正捕捉点接近支撑多边形的边界时,基于校正捕捉点的预警系统可有效避免机器人摔倒。然而,上述方法大多局限于足式机器人在平坦地形上行走,对农业足式机器人的田间作业地形不平整、存在较大起伏的场景缺少研究。

部分研究人员通过分析机身的传感器数据进行足式机器人的摔倒预测[15-19]。这些方法优点在于精度高,缺点为需要采集多种传感器数据进行计算,硬件成本较高,缺乏适用性,导致部分方法在不同场景下的摔倒识别精度表现一般[20]。

复杂多变农田地形和起伏差异导致四足机器人行走过程中易摔倒,对四足机器人的行走稳定性构成了挑战。提出一种基于 IPO - GRNN 模型的农业四足机器人摔倒临界状态预测方法。通过机器人本体传感器采集 IMU 数据,建立基于 IPO - VMD - GRNN 模型的田间作业机器人摔倒预测方法,在机器人出现摔倒趋势时及时预测其异常状态,通过实

时监测、分析和反馈数据特征，使其能更好适应复杂地形并减小摔倒概率，为后期机器人的防摔控制策略提供信息来源，提升四足机器人在农田行走的稳定性和自适应性。

1　信号采集场景与数据集制作

1.1　机器人行走摔倒场景及信号采集

本研究使用 Unitree Robotics 公司的 A1 四足机器人平台进行数据采集。如图 1 所示，机器人在田间行走时，受地面表层青草覆盖或垄作地形起伏的影响，垄作地形包括高起垄作物行（高度 20 cm）、低起垄作物行（高度 10 cm），足端在落地时发生位置偏移导致机身重心不稳，机器人无法调整稳定的姿态从而摔倒。试验在吉林省长春市吉林大学农业试验基地进行，数据采集时间为 2023 年 7—9 月。



(a) 高起垄地形行走　(b) 低起垄地形行走　(c) 青草地形摔倒　(d) 高起垄地形摔倒　(e) 低起垄地形摔倒

图 1　田间机器人行走和摔倒场景

Fig. 1　Scenes of falling robots in field

采集四足机器人在田间行走和摔倒过程中的 IMU 传感器数据，通过自带的 NVIDIA JETSON NANO 处理器保存摔倒临界状态下的信号，为后续机器人调整机身行走策略提供信息感知能力。IMU 传感器包含大量的机器人运动状态信息，位姿信息的变化会反映在机身 IMU 传感器的感知数据中[21－22]，在机器人出现摔倒趋势时，机身姿态角将出现不同于正常行走的数据特征。

机器人田间行走中的摔倒过程分为 4 个阶段，包括正常行走、摔倒临界第 1 阶段、摔倒临界第 2 阶段和完全摔倒阶段。机器人在正常行走过程中，由于垄作的地形起伏，如图 2a 所示，机器人的左侧足端与地面发生滑移，此时机器人向左发生偏移。如图 2b、2c 所示，机器人检测到机身倾斜后稳定策略控制机器人往右平移从而摆正机身，但此时足端落地瞬间，与起垄地形的垄坡发生触碰后足端再次滑移，如图 2d 所示。经由大量田间试验验证，机器人易在摔倒临界第 2 阶段摔倒。因此，本文取其摔倒临界第 1 阶段和第 2 阶段的 IMU 信号作为后续模型输入，提取机器人摔倒过程的信号特征，从而进行摔倒预测模型构建。

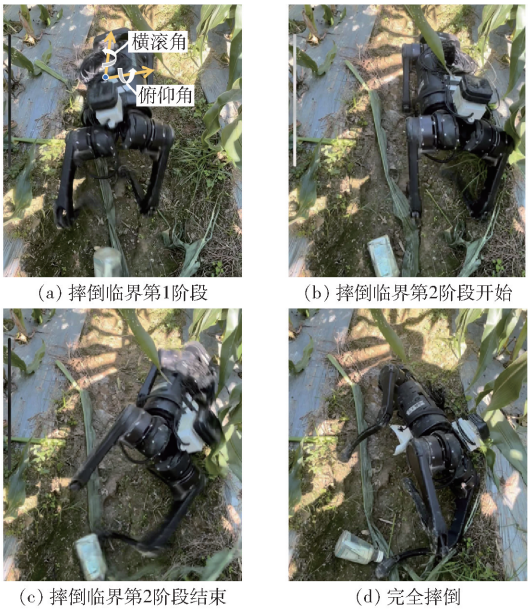

(a) 摔倒临界第1阶段　(b) 摔倒临界第2阶段开始　(c) 摔倒临界第2阶段结束　(d) 完全摔倒

图 2　机器人田间行走摔倒过程

Fig. 2　Fall process of quadrupedal robot in field

数据增强是利用先验知识在不改变原始数据标签的前提下扩展原始数据集，从而增加样本多样性的技术，能显著提升模型的稳健性。在本文的研究中，针对摔倒信号的划分阶段保持不变，对采集的 IMU 信号样本进行了部分倒置处理，以此扩充数据集。生成了新的训练样本，不仅增加数据集的多样性和规模，还促进了模型对数据内在特征的学习，进而提高了其泛化能力。同时，由于数据集的扩充，模型在训练时能够更好地避免过拟合的风险，即模型不会过于依赖训练数据中的特定模式，而是能够学习到更普遍、更通用的特征。

本文共采集机器人摔倒的 200 组数据信号，由于机器人摔倒信号样本较少、异常作业工况信号样本难以获取，基于大量数据驱动的机器学习模型难以达到理想的识别精度，限制了机器人对复杂地形中摔倒临界状态的预测能力。如图 3 所示，建立机器人运动仿真模型，基于 Gazebo 机器人仿真软件采集正常行走、摔倒中及已摔倒工况下的机器人姿态角信息，加入噪声信号模拟机器人田间行走过程中的摔倒状态，得到机器人正常行走、摔倒临界稳定状态及完全摔倒的工况信号。

经上述过程，得到机器人摔倒的训练与验证数据集 2 000 组，其中实际田间摔倒 200 组，仿真摔倒

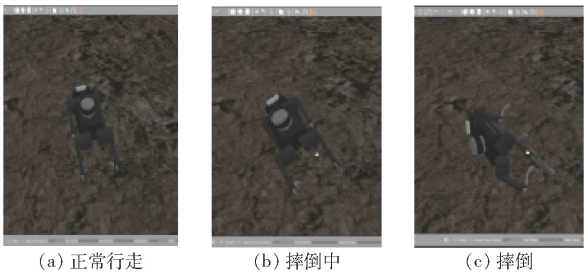

(a) 正常行走 (b) 摔倒中 (c) 摔倒

图 3 Gazebo 软件中机器人摔倒过程

Fig. 3 Fall of quadrupedal robot in Gazebo

1 800 组。通过扩大行走状态监测模型的训练样本量,提高模型运行可靠性及监测精度。

1.2 IMU 数据预处理

对于机器人 4 种工况,采集横滚角和俯仰角信号组(f_{r1},f_{p1})、($f_{r2(1)}$,$f_{p2(1)}$)、($f_{r2(2)}$,$f_{p2(2)}$)、(f_{r3},f_{p3}),如图 4 所示,其中,f_{r1}、f_{p1}分别表示机器人正常行走时横滚角、俯仰角,$f_{r2(1)}$、$f_{p2(1)}$分别表示机器人摔倒临界第 1 阶段时横滚角、俯仰角,$f_{r2(2)}$、$f_{p2(2)}$分别表示机器人摔倒临界第 2 阶段时横滚角、俯仰角,f_{r3}、f_{p3}分别表示机器人完全摔倒时横滚角、俯仰角。机器人田间作业环境复杂,IMU 传感器信号包含大量噪声,由此需要对信号进行降噪处理,采用高斯降噪算法对f_{r1}、f_{p1}、$f_{r2(1)}$、$f_{p2(1)}$、$f_{r2(2)}$、$f_{p2(2)}$、f_{r3}、f_{p3}进行降噪,得到去噪信号f'_{r1}、f'_{p1}、$f'_{r2(1)}$、$f'_{p2(1)}$、$f'_{r2(2)}$、$f'_{p2(2)}$、f'_{r3}、f'_{p3},由于篇幅有限,以正常行走时横滚角为例,信号去噪效果如图 5 所示。

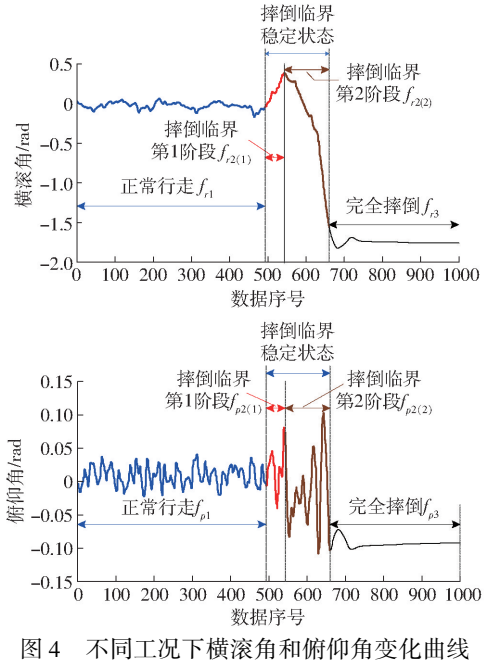

图 4 不同工况下横滚角和俯仰角变化曲线

Fig. 4 Roll angle and pitch angle signals under different operating conditions

横滚角和姿态角幅值有很大的区别,通道中的数值若用来直接训练模型,可能会导致训练模型不稳定。本文对数据进行归一化,以产生相同数量级

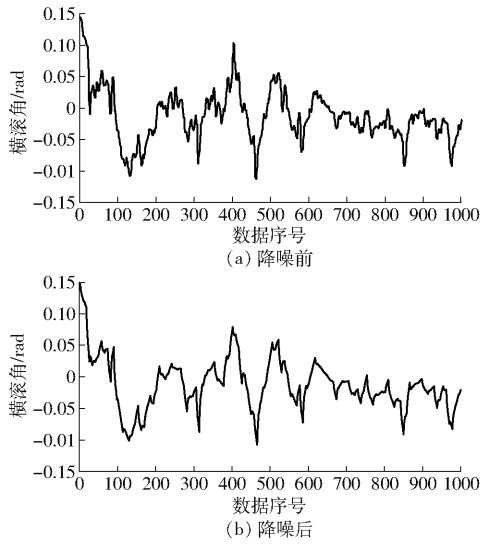

图 5 正常行走横滚角降噪效果

Fig. 5 Diagrams of signal denoising effect

的所有数据值。采用零均值归一化方法将横滚角和姿态角数据归一化为[-1,1]。

2 基于 IMU 数据的机器人摔倒预测模型

2.1 VMD 信号特征提取方法优化

2.1.1 变分模态分解

变分模态分解(Variational mode decomposition, VMD)[23]是一种自适应、完全非递归的模态变分和信号处理方法,其自适应性表现在根据实际情况确定序列的模态分解个数,随后的搜索和求解过程中可以自适应地匹配每种模态的最佳中心频率和有限带宽,并且可以实现信号的频域划分,进而得到给定信号的有效分量,最终获得变分问题的最优解。

相较于经验模态分解 EMD[24],VMD 具有较强的鲁棒性,能够有效避免模态混叠现象[25],也可避免在分解过程中出现虚假分量的现象[26],由此本文采用 VMD 对机器人行走过程的姿态角信号进行处理。

为验证 VMD 的可行性,以图 4b 中的信号为例,分别采用 VMD 和 EMD 对其进行 5 层信号分解,将所得的 IMF 信号转换到频域中,绘制频谱图,分解结果如图 6 所示。由图 6a 可知,信号由 VMD 处理后,所有 IMF 均未产生模态混叠现象,观察图 6b 可知,EMD 信号分解的 IMF 中,IMF2 出现了模态混叠现象,IMF1 为噪声虚假分量。因此,相较于 EMD 而言,VMD 性能较佳,可将信号的各个频率成分准确提取,便于机器人姿态信号特征提取。

2.1.2 VMD 优化方法

在 VMD 过程中,IMF 分量个数 K 与二次惩罚因子 a 对其分解结果有较大影响。一般地,K 与 a 的

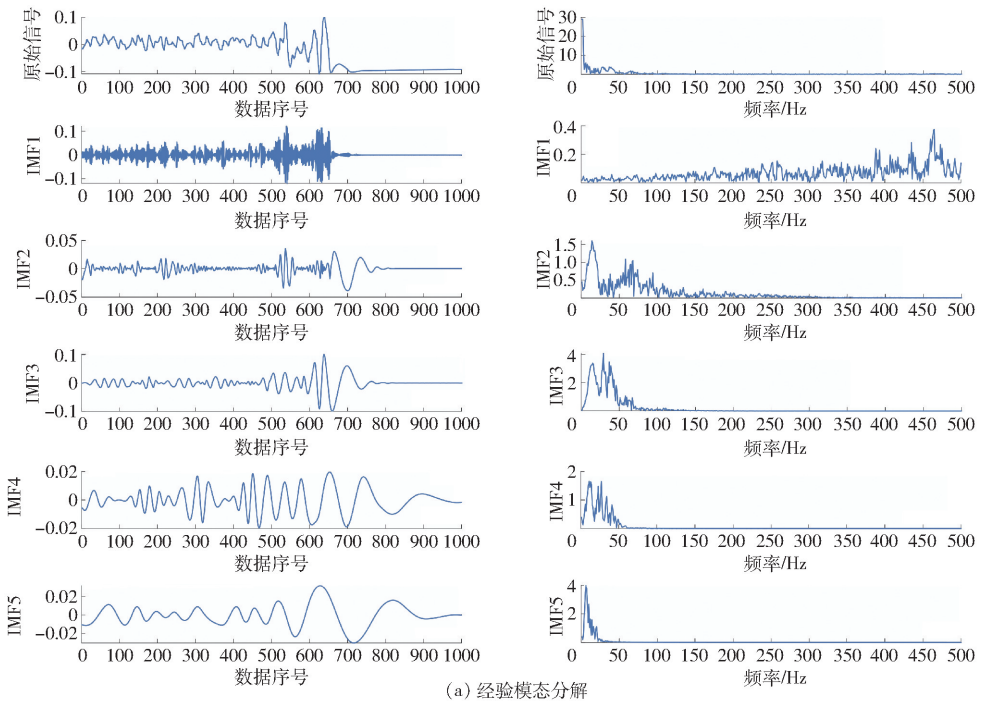

(a) 经验模态分解

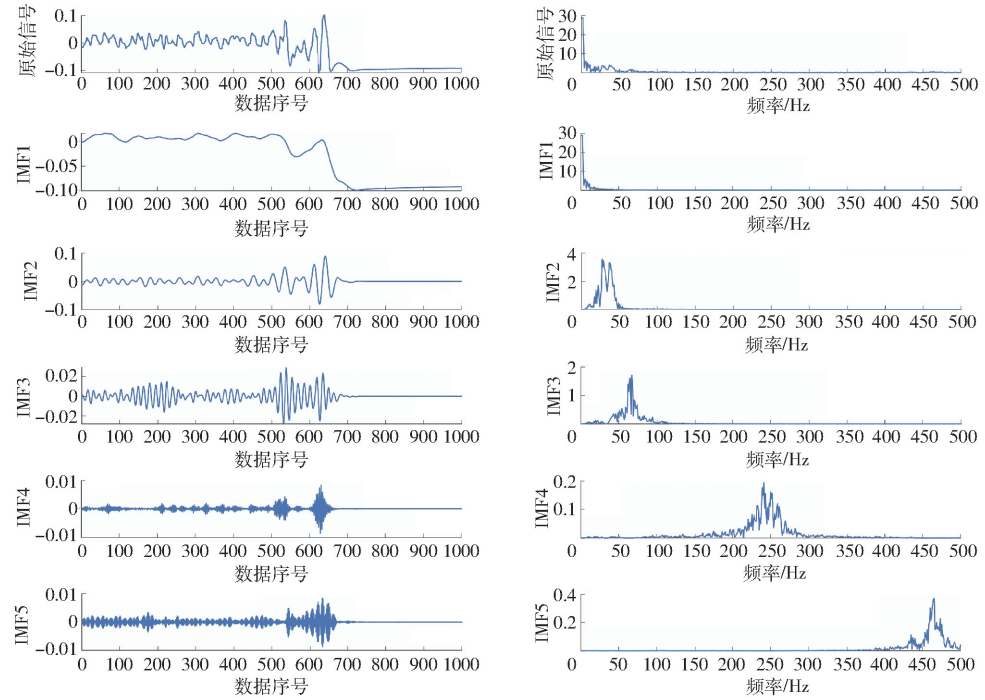

(b)变分模态分解

图 6　信号经不同方法分解后各分量时域与频域图

Fig. 6　Time-domain and frequency-domain diagrams of each component of signal decomposed by different methods

取值都是依靠文献中的经验参数,其适用的广泛性有一定限制,由此需对两个参数进行寻优。种群算法具有寻优效率高、易实现等优点而被广泛运用于参数寻优中,但传统种群算法也存在易陷入局部最优、收敛性欠佳等缺点难以运用于实际工程问题中。因此,采用种群优化算法优化 VMD 中的参数 K、a,针对传统种群算法的缺陷进行算法改进,提出了一种改进种群优化(Improved population optimization, IPO)算法,据此构建 IPO－VMD 模型。IPO 算法具体步骤如下:

(1)设置种群规模(个体数)为 M;当前迭代(进化)次数为 T_c;迭代(进化)次数为 $T_{\max}$。

(2)假设 α、β、γ 是 3 个潜在解,且 α、β、γ 与全局最优解的距离满足

$$l_{\alpha-best} < l_{\beta-best} < l_{\gamma-best} \tag{1}$$

式中　$l_{\alpha-best}$、$l_{\beta-best}$、$l_{\gamma-best}$——α、β、γ 与全局最优解的距离

(3)对 β、γ 进行速度更新:

$$\begin{cases} v_{\beta(m+1)} = \omega' v_{\beta m} + c_1 r_1 (p_{\beta best} - x_{\beta m}) + c_2 r_2 (g_{\beta best} - x_{\beta m}) \\ v_{\gamma(m+1)} = \omega' v_{\gamma m} + c_1 r_1 (p_{\gamma best} - x_{\gamma m}) + c_2 r_2 (g_{\gamma best} - x_{\gamma m}) \\ \omega' = \omega_{\max} - (\omega_{\max} - \omega_{\min}) T_c^2 T_{\max}^{-2} \end{cases} \tag{2}$$

式中 $v_{\beta(m+1)}$、$v_{\gamma(m+1)}$——更新后 β、γ 种群个体速度

$v_{\beta m}$、$v_{\gamma m}$——当前 β、γ 种群个体速度

$x_{\beta m}$、$x_{\gamma m}$——当前 β、γ 种群个体位置

c_1、c_2——个体、社会学习因子

r_1、r_2——两个互不相同的[0,1]间随机数

$p_{\beta best}$、$p_{\gamma best}$——当前 β、γ 种群个体最优解

$g_{\beta best}$、$g_{\gamma best}$——当前 β、γ 种群全局最优解

ω'——变量权值系数

$\omega_{\max}$、$\omega_{\min}$——最大、最小惯性权重

(4)对 α 进行速度更新:

$$\begin{aligned} v_{\alpha(m+1)} = {} & v_{\alpha m} + c_1 r_1 (p_{\alpha best} - x_{\alpha m}) + \\ & \frac{F_\gamma}{F_\alpha + F_\beta + F_\gamma} c_2 r_2 (g_{\alpha best} - x_{\alpha m}) + \\ & \frac{F_\beta}{F_\alpha + F_\beta + F_\gamma} c_3 r_3 (g_{\beta best} - x_{\beta m}) + \\ & \frac{F_\alpha}{F_\alpha + F_\beta + F_\gamma} c_4 r_4 (g_{\gamma best} - x_{\gamma m}) \end{aligned} \tag{3}$$

式中 $v_{\alpha(m+1)}$——更新后 α 种群中个体速度

$v_{\alpha m}$——当前 α 种群中个体速度

$x_{\alpha m}$——当前 α 种群中个体位置

c_3、c_4——群间学习因子

$$\begin{cases} D_{j+1} = | C_2 g_{jbest} - x_{m+1} | \\ x_{m+2} = \begin{cases} v_{\alpha(m+1)} + r_9 \dfrac{\sum (x_{m+1} - A_2 D_{j+1})}{3} & (\mathrm{rand}(0,T_c) < \mathrm{rand}(T_c,T_{\max}), F_m < \min(F_r)) \\ v_{\alpha(m+1)} + r_9 \dfrac{\sum \left(A_2 D_{j+1} - 2\sin\left(r_{10} + \dfrac{\pi}{2}\right) x_{m+1}\right)}{3} & (\mathrm{rand}(0,T_c) < \mathrm{rand}(T_c,T_{\max}), F_m \geqslant \min(F_r)) \\ r_{11} & (\mathrm{rand}(0,T_c) \geqslant \mathrm{rand}(T_c,T_{\max})) \end{cases} \\ A_2 = 2a_2 r_{12} - a_2 \\ C_2 = 2r_{13} \end{cases} \tag{5}$$

式中 D_{j+1}——g_{jbest} 与 x_{m+1} 之间的欧几里得距离

x_{m+2}——第 1 次位置更新后个体位置

A_2、C_2——两个互不相同的变量系数

F_m——m 个体适应度

F_r——种群内随机个体适应度

a_2——不同于 a_1 的收缩因子

r_9、r_{10}、r_{11}、r_{12}、r_{13}——5 个不同的[0,1]区间随机数

由式(1)~(4)可知,IPO 算法首先根据与最优解的距离划分了 α、β、γ,以加强算法种群内部各个个体间的信息交流,并先对 β、γ 的速度进行更新,再根据 α、β、γ 适应度相对种群所有个体适应度的占比对 α 个体的速度进行更新,提高了个体间的信息交流能力;其次引用灰狼算法包围猎物的方式对个体位置进行第 1 次更新,以 α、β、γ 种群的引领作用对种群各个个体位置进行更新,避免了个体的“贪心性”,算法不易陷入局部最优,同时在包围猎物过程中引入黑翅鸢攻击猎物方式[27],改进个体位置移动方式,以扩大算法的寻优范围;最后引用黑翅鸢迁移方式对个体位置进行第 2 次更新,进一步提

$p_{\alpha best}$——当前 α 种群个体最优解

r_3、r_4——两个互不相同的[0,1]间随机数

$g_{\alpha best}$——目前 α 种群全局最优解

F_α、F_β、F_γ——α、β、γ 种群中所有个体适应度平均值

(5)种群个体第 1 次位置更新:

$$\begin{cases} D_j = | C_1 g_{jbest} - x_m | \\ x_{m+1} = \begin{cases} \left(\dfrac{\pi}{2} - \theta\right) \dfrac{\sum_{j=1}^{3} (g_{jbest} - A_1 D_j)}{3} & (r_5 < 0.5) \\ x_m + 0.05 \mathrm{e}^{-2\left(\frac{T_c}{T_{\max}}\right)^2} (1 + \cos r_6) x_m & (r_5 \geqslant 0.5;\ r_6 > 0.9) \\ x_m + 0.05 \mathrm{e}^{-2\left(\frac{T_c}{T_{\max}}\right)^2} (2r_6 - 1) x_m & (r_5 \geqslant 0.5, r_6 \leqslant 0.9) \end{cases} \\ A_1 = 2a_1 r_7 - a_1 \\ C_1 = 2r_8 \end{cases} \tag{4}$$

式中 g_{jbest}——种群 j 的全局最优解

D_j——g_{jbest} 与 x_m 之间的欧几里得距离

x_{m+1}——第 1 次位置更新后个体位置

x_m——第 1 次位置更新前个体位置

A_1、C_1——两个互不相同的变量系数

a_1——收缩因子

r_5、r_6、r_7、r_8——4 个不同的[0,1]间随机数

式中 j 取 1、2、3 时,分别对应 α、β、γ。

(6)种群个体第 2 次位置更新:

高算法的全局寻优能力，提出了变异概率随算法迭代次数增加而增加的自适应变异策略，增加算法后期种群多样性，增大算法后期的寻优空间。

图 7 为 IPO－VMD 流程图。IPO－VMD 过程为：

(1)初始化 IPO 算法中的个体位置和速度。

(2)确定 IPO 算法的适应度函数。

排列熵是一种用来表征信号序列复杂程度的无量纲指标，其具有对序列长度要求不高、鲁棒性较强等诸多优点，因此被广泛应用于信号检测[28－29]。基于排列熵特性，在 IPO 算法寻优时将 VMD 的各分量的排列熵作为适应度函数评判信号分解的合理性，个体适应度函数 F 数学表达式为

$$F = \sum_{l=1}^{K} PE\langle u_l \rangle \tag{6}$$

式中　$PE\langle \cdot \rangle$——排列熵算子

u_l——VMD 后的分量

(3) 根据适应度确定 α、β、γ 种群，α、β、γ 种群中的个体适应度满足

$$F(\alpha) < F(\beta) < F(\gamma) \tag{7}$$

(4)采用 IPO 算法对最优参数 a、K 进行寻优。

(5)对 f'_{r1}、f'_{p1}、$f'_{r2(1)}$、$f'_{p2(1)}$、$f'_{r2(2)}$、$f'_{p2(2)}$、f'_{r3}、f'_{p3} 重复步骤(1)～(4)，得到 8 种姿态角信号 VMD 最佳参数组，分别为 (a_{fr1}, K_{fr1})、(a_{fp1}, K_{fp1})、$(a_{fr2(1)}, K_{fr2(1)})$、$(a_{fp2(1)}, K_{fp2(1)})$、$(a_{fr2(2)}, K_{fr2(2)})$、$(a_{fp2(2)}, K_{fp2(2)})$、(a_{fr3}, K_{fr3})、(a_{fp3}, K_{fp3})，以此计算针对任意横滚、俯仰姿态角信号 VMD 模型最优参数组，最优参数确定方式为

$$\begin{cases} a_{rt} = \dfrac{a_{fr1} + a_{fr2(1)} + a_{fr2(2)} + a_{fr3}}{3} \\ a_{pt} = \dfrac{a_{fp1} + a_{fp2(1)} + a_{fp2(2)} + a_{fp3}}{3} \\ K_{rt} = \dfrac{K_{fr1} + K_{fr2(1)} + K_{fr2(2)} + K_{fr3}}{3} \\ K_{pt} = \dfrac{K_{fp1} + K_{fp2(1)} + K_{fp2(2)} + K_{fp3}}{3} \end{cases} \tag{8}$$

式中　a_{rt}、K_{rt}——横滚角信号 VMD 模型最优参数

a_{pt}、K_{pt}——俯仰角信号 VMD 模型最优参数

2.2　优化 GRNN 田间作业机器人摔倒预测模型

广义回归神经网络(General regression neural network，GRNN)[30]是一种改进径向基函数网络，该模型的输入是一组特征向量，输出是对应的目标值。GRNN 模型的训练不需要迭代，具有结构简单、训练速度快速及泛化能力良好等优点。因此，采用 GRNN 作为田间作业机器人摔倒预测模型。

GRNN 模型中平滑因子 s 影响模型的泛化能力，一般通过经验调整参数 s 以获得最优的网络架构，但该方法存在效率低、精度差等问题。本质上参数 s 的选取可归结为一个参数优化问题[31－32]，因此采用上文提出的 IPO 算法对 GRNN 的参数 s 进行优化，据此提出 IPO－GRNN 模型。IPO－GRNN 模型流程如图 8 所示，流程具体为：

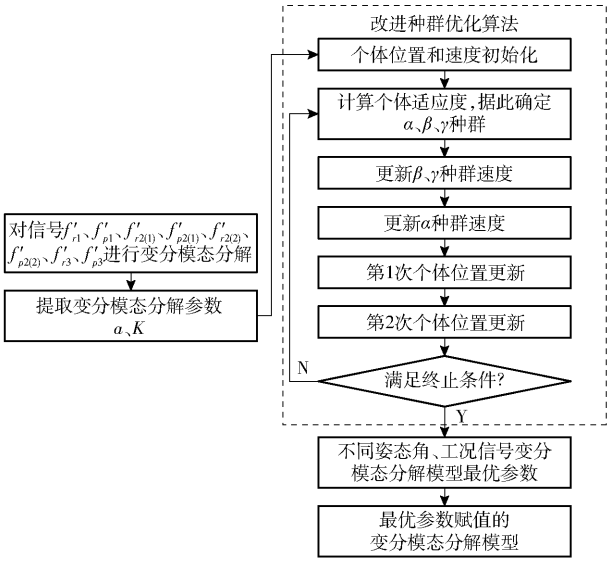

图 7　改进种群优化算法优化变分模态分解流程图

Fig. 7　Flowchart of improved population optimization algorithm for optimizing variational mode decomposition

(1)初始化 IPO 算法中的个体位置和速度。

(2)以 GRNN 均方根误差公式计算粒子适应度

$$F_i = \frac{\sum_{j=1}^{N} (Y_j - y_j)^2}{N} \tag{9}$$

式中　Y_j——IPO 算法第 j 个个体期望输出

y_j——IPO 算法第 j 个个体实际输出

(3)根据适应度确定 α、β、γ 种群，α、β、γ 种群中的个体适应度满足

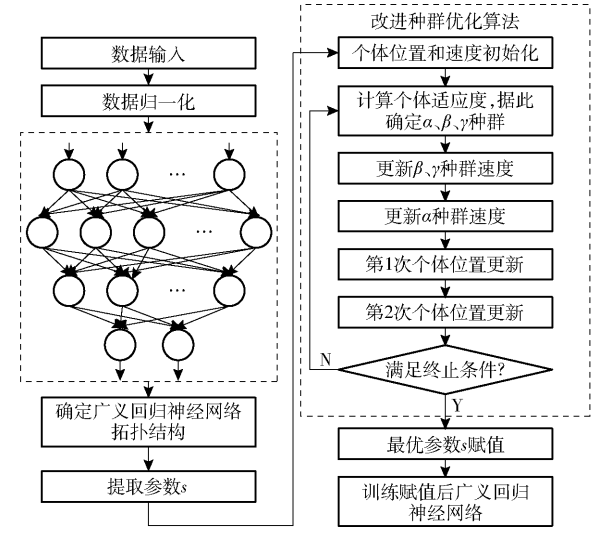

图 8　改进的广义回归神经网络模型流程图

Fig. 8　Flowchart of improved generalized regression neural network model

$$F_i(\alpha) < F_i(\beta) < F_i(\gamma) \tag{10}$$

(4)对网络的输入数据进行归一化处理,其处理方式为

$$y = (y_{\max} - y_{\min})\frac{V - x_{\min}}{x_{\max} - x_{\min}} + y_{\min} \tag{11}$$

式中 y——归一化处理后参数数据

$y_{\max}$——归一化预期范围最大值

$y_{\min}$——归一化预期范围最小值

$x_{\max}$——每一行参数数据最大值

$x_{\min}$——每一行参数数据最小值

V——实际参数

(5)确定 GRNN 结构,提取 GRNN 参数 s。

(6)采用 IPO 算法优化 GRNN 模型参数 s。

(7)将最优参数 s 赋值给 GRNN 模型,训练赋值后的 GRNN。

2.3 田间作业机器人摔倒预测方法性能试验

基于前述的理论基础,利用 IPO - VMD 进行信号处理,提取信号排列熵,将其输入 IPO - GRNN 模型,构建本文的 IPO - VMD - GRNN 模型,实现田间作业机器人摔倒临界状态预测,具体流程为:

(1)采集机器人正常行走、摔倒临界稳定状态的两个阶段及完全摔倒 4 种工况信号,生成 4 种工况的横滚角和俯仰角信号组(f_{r1},f_{p1})、($f_{r2(1)}$,$f_{p2(1)}$)、($f_{r2(2)}$,$f_{p2(2)}$)、(f_{r3},f_{p3})。

(2)采用高斯降噪算法对 f_{r1}、f_{p1}、$f_{r2(1)}$、$f_{p2(1)}$、$f_{r2(2)}$、$f_{p2(2)}$、f_{r3}、f_{p3}进行降噪,得到降噪信号 f'_{r1}、f'_{p1}、$f'_{r2(1)}$、$f'_{p2(1)}$、$f'_{r2(2)}$、$f'_{p2(2)}$、f'_{r3}、f'_{p3}。

(3)采用 IPO 算法寻优 f'_{r1}、f'_{p1}、$f'_{r2(1)}$、$f'_{p2(1)}$、$f'_{r2(2)}$、$f'_{p2(2)}$、f'_{r3}、f'_{p3}信号的 VMD 最优参数,得到这 8 个信号的最优参数组(a_{fr1}, K_{fr1})、(a_{fp1}, K_{fp1})、($a_{fr2(1)}$, $K_{fr2(1)}$)、($a_{fp2(1)}$, $K_{fp2(1)}$)、($a_{fr2(2)}$, $K_{fr2(2)}$)、($a_{fp2(2)}$,$K_{fp2(2)}$)、(a_{fr3},K_{fr3})、(a_{fp3},K_{fp3}),采用式(8)确定针对任意横滚、俯仰姿态角信号 VMD 模型的最优参数组(a_{rt},K_{rt})、(a_{pt},K_{pt}),得到横滚、俯仰姿态角信号的 IPO - VMD 模型。

(4)采用步骤(1)、(2)的方法生成多组姿态角信号 f'_{r1}、f'_{p1}、$f'_{r2(1)}$、$f'_{p2(1)}$、$f'_{r2(2)}$、$f'_{p2(2)}$、f'_{r3}、f'_{p3},采用步骤(3)生成横滚姿态角信号的 IPO - VMD 模型对 f'_{r1}、$f'_{r2(1)}$、$f'_{r2(2)}$、f'_{r3}信号进行分解,提取分解后信号分量的排列熵得到 a_{rt} 维的横滚角信号特征组 PE(f'_{r1})、PE($f'_{r2(1)}$)、PE($f'_{r2(2)}$)、PE(f'_{r3});采用俯仰姿态角信号的 IPO - VMD 模型对 f'_{p1}、$f'_{p2(1)}$、$f'_{p2(2)}$、f'_{p3}信号进行分解,提取分解后信号分量的排列熵得到 a_{pt}维的俯仰角信号特征组 PE(f'_{p1})、PE($f'_{p2(1)}$)、PE($f'_{p2(2)}$)、PE(f'_{p3})。

(5)构建 GRNN 模型,确定 GRNN 模型的输出,为量化机器人行走状态,引入一种评分机制:得分 e 越高则规定为机器人易摔倒,由此 GRNN 的输入对应的输出标签规定如表 1 所示。

表 1 广义回归神经网络输出标签

Tab. 1 Output label of generalized regression neural network

原始信号	降噪信号	特征值(GRNN 输入)	e(输出标签)
f_{r1}、f_{p1}	f'_{r1}、f'_{p1}	PE(f'_{r1})、PE(f'_{p1})	0
$f_{r2(1)}$、$f_{p2(1)}$	$f'_{r2(1)}$、$f'_{p2(1)}$	PE($f'_{r2(1)}$)、PE($f'_{p2(1)}$)	1
$f_{r2(2)}$、$f_{p2(2)}$	$f'_{r2(2)}$、$f'_{p2(2)}$	PE($f'_{r2(2)}$)、PE($f'_{p2(2)}$)	2
f_{r3}	f'_{r3}	PE(f'_{r3})、PE(f'_{p3})	3

基于 GRNN 构建横滚角、俯仰角信号的田间作业机器人摔倒预测模型,采用 IPO 算法优化 GRNN 的参数 s,得到基于横滚角的 IPO - GRNN 摔倒预测模型和基于俯仰角的 IPO - GRNN 摔倒预测模型。

(6)采用 IMU 传感器实时采集横滚角、俯仰角信号 f_{r4}、f_{p4},采用步骤(2)的信号降噪方法得到 f'_{r4}、f'_{p4},将 f'_{r4}、f'_{p4}分别输入步骤(3)姿态角的 IPO - VMD 模型,提取分解信号的排列熵,得到横滚角、俯仰角信号特征组,分别将其输入步骤(5)的 2 个 IPO - GRNN 模型,输出分数。

3 试验结果与分析

3.1 试验平台

采集机器人在玉米作物行不同的田间地形环境下机器人 IMU 传感器信号,包括青草覆盖、高起垄与低起垄作物行地形,使用其横滚、俯仰姿态角信号作为摔倒预测模型的测试数据,以此验证基于 IPO - VMD - GRNN 模型的田间作业机器人摔倒预测方法的性能。试验选用 Intel(R) Core(TM) i7 - 12900K 处理器,内存为 16 GB,使用 Matlab 2018 进行数据处理。

3.2 试验结果分析

3.2.1 IPO - VMD 试验

首先验证 IPO - VMD 方法的可行性,以不同信号 VMD 分出的第一分量为例,将 IPO、GWO、PSO 算法优化 VMD 过程中的适应度曲线进行对比,设置算法迭代次数为 50,图 9 所示为 3 种不同算法优化 VMD 的适应度曲线。图 9a 表明,IPO 算法横滚角迭代次数为 3 次,小于 PSO 和 GWO 算法;适应度为 0.452,小于 GWO 算法的 0.463 和 PSO 算法的 0.478,横滚角适应度分别减小 0.011 和 0.026。图 9b 表明,俯仰角的 IPO 算法迭代次数最少,相比 GWO 和 PSO 算法,俯仰角的适应度分别减小 0.03 和 0.047。

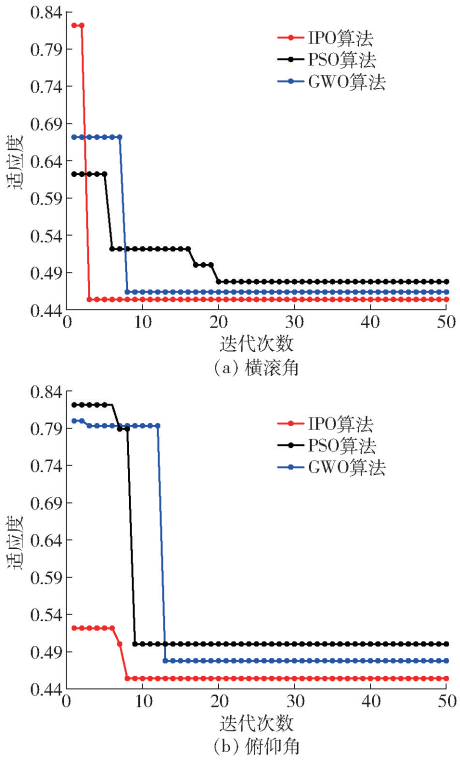

图 9　适应度曲线

Fig. 9　Curves of fitness

在 2 种姿态角信号分解过程中，PSO 算法的适应度最高，可说明其寻得的解为局部最优解，证明 PSO 算法易陷入局部最优；较 PSO 算法而言，GWO 算法的适应度较低，说明 GWO 具有较强的全局寻优能力；而 IPO 算法在迭代次数较低时适应度收敛到了较低值，这是由于 IPO 算法在 GWO、PSO 算法的基础上引入了黑翅鸢攻击猎物方式，同时引入了自适应变异策略，使得算法兼具了良好收敛性能与全局寻优能力。由此采用 IPO 算法对 VMD 的参数 a 和 K 进行优化，分别对横滚姿态角信号 VMD 模型、俯仰姿态角信号 VMD 模型的参数进行寻优，设置 IPO 迭代次数为 50，寻优结果如表 2 所示。

表 2　变分模态分解的最优参数

Tab. 2　Optimal parameters for variational mode decomposition

信号		最优解	
		a	K
横滚角	f'_{r1}	3 524	5
	$f'_{r2(1)}$	3 805	5
	$f'_{r2(2)}$	3 566	5
	f'_{r3}	3 789	5
俯仰角	f'_{p1}	4 026	5
	$f'_{p2(1)}$	4 208	5
	$f'_{p2(2)}$	3 997	5
	f'_{p3}	4 137	5

由表 2 可知，横滚姿态角、俯仰姿态角信号的 VMD 最佳分解层数 K 均为 5，横滚角 VMD 寻优得到的 a 均在 3 671 左右，俯仰角 VMD 寻优得到的 a 均在 4 000 左右，计算 VMD 最优参数可得：a_{rt} = 3 671、K_{rt} = 5；a_{pt} = 4 092、K_{pt} = 5。利用最优参数组合 VMD 对姿态角数据进行信号分解，图 10 展示了利用最佳参数 VMD 后横滚角、俯仰角时域波形与频谱图。从图 10 可看出，两种姿态角信号经 VMD 后的 IMF 分量均未产生模态混叠现象，各个 IMF 分量均可以反映原始信号，验证了 IPO 算法优化 VMD 的可行性。

3.2.2　IPO－VMD－GRNN 试验

提取 IPO－VMD 信号各个分量的排列熵作为特征向量，构建 GRNN 模型训练样本（24 组）与测试样本（16 组）的数据集，采用 IPO 优化算法优化 GRNN 的参数 s，为证明 IPO－VMD－GRNN 模型的可行性，以 VMD－BPNN 模型、VMD－GRNN 模型、PSO－VMD－GRNN 模型作为对比，不同模型的测试样本输出结果如图 11 所示。

由图 11 可知，相较于 BPNN，GRNN 的性能更佳，这是由于相较于 BPNN，GRNN 的结构简单，训练效果与精度更高，PSO 算法一定程度上改善了 VMD 的模型性能与 GRNN 的模型精度，减小了样本 1、8、10、11、12 的输出误差，相比于 PSO，本文的 IPO 改进后 VMD－GRNN 模型的所有测试样本输出与真实标签基本贴合。

选取测试样本对应输出的总误差（Total errors，TE）、平均相对误差（Mean relative errors，MRE）、均方误差（Mean square errors，MSE）评价网络模型输出效果。

IPO－VMD－GRNN 模型输出总误差为 0.146 7、平均相对误差为 0.006 5、均方误差为 0.000 3，分别低于 VMD－BPNN 模型的 4.537 1、0.123 6、0.300 8，VMD－GRNN 模型的 1.597 0、0.050 4、0.043 7，PSO－VMD－GRNN 模型的 0.513 7、0.020 3、0.003 6。一方面说明了 IPO－VMD 信号处理后提取的特征具有良好的代表性，另一方面说明了采用 IPO 优化 GRNN 参数后模型的泛化能力得到增强，同时根据图 9 可知 IPO 算法充分挖掘了种群算法的优化潜力。综上，本文提出的 IPO－VMD－GRNN 模型具有良好的预测能力。

最后，利用田间机器人实际摔倒情况的测试集进行了 100 组试验。如表 3 所示，本文通过设定不同预测成功率阈值，对本文和原始摔倒预测方法的预测时间进行了评估。具体来说，当设定的预测成功率越低，摔倒预测方法响应时间越快，更短的预测时间意味着更好的性能。试验结果表明，本文模型

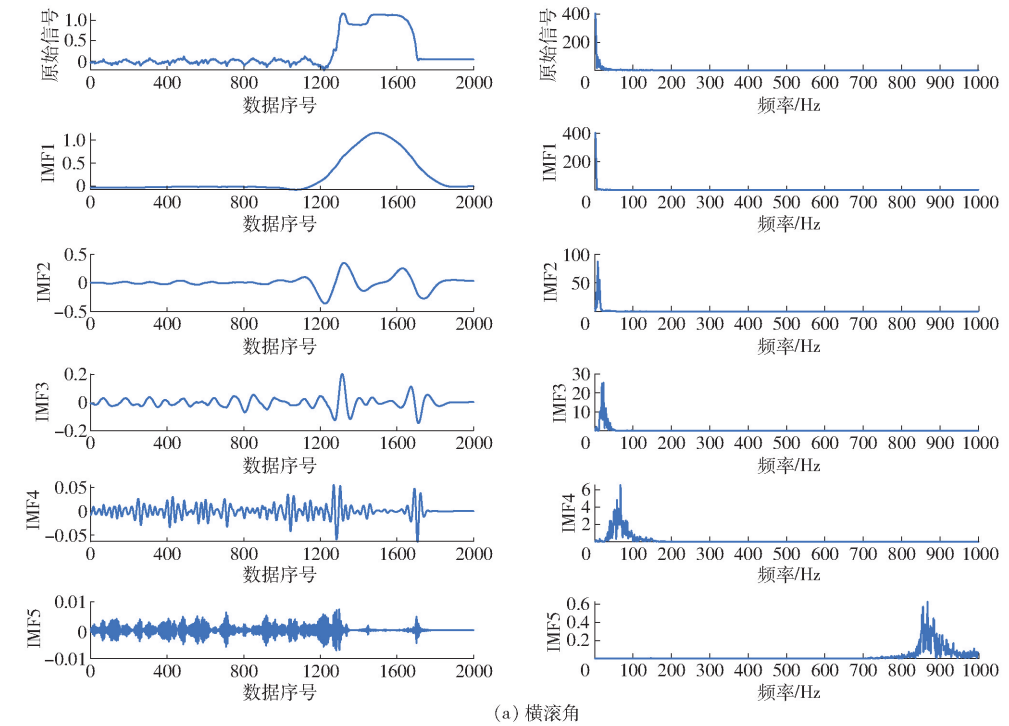

(a) 横滚角

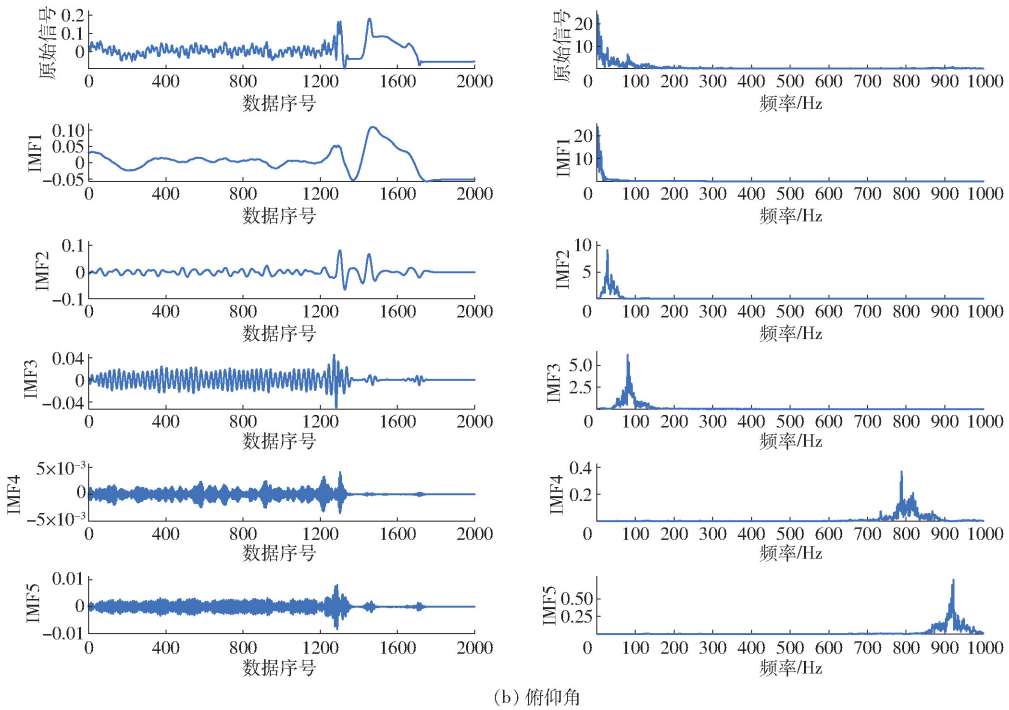

(b) 俯仰角

图 10 VMD 后横滚、俯仰角时域波形与频谱图

Fig. 10 Time-domain and frequency-domain diagrams of roll and pitch angles after VMD

在同样的预测成功率阈值下,具有更快的响应时间,平均预测成功的响应时间缩短 91.5 ms。表明本文模型有效,可使机器人有更多的调整时间来避免摔倒。后续根据控制器响应时间、摔倒预测模型响应速度选择合适的阈值。

4 结论

(1)采用种群优化算法优化 VMD 参数,提出基于 IPO - VMD 的信号处理方法。采用 IPO 算法对 GRNN 的参数进行优化,提出 IPO - GRNN 模型。IPO 算法的横滚角、俯仰角迭代次数最少,相比 GWO 和 PSO 算法,横滚角适应度分别减小 0.011 和 0.026,俯仰角适应度分别减小 0.03 和 0.047。

(2)本文 IPO - VMD - GRNN 模型输出总误差为 0.146 7、平均相对误差为 0.006 5、均方误差为 0.000 3,分别低于 VMD - BPNN 模型的 4.537 1、0.123 6、0.300 8,VMD - GRNN 模型的 1.597 0、0.050 4、0.043 7,PSO - VMD - GRNN 模型的 0.513 7、

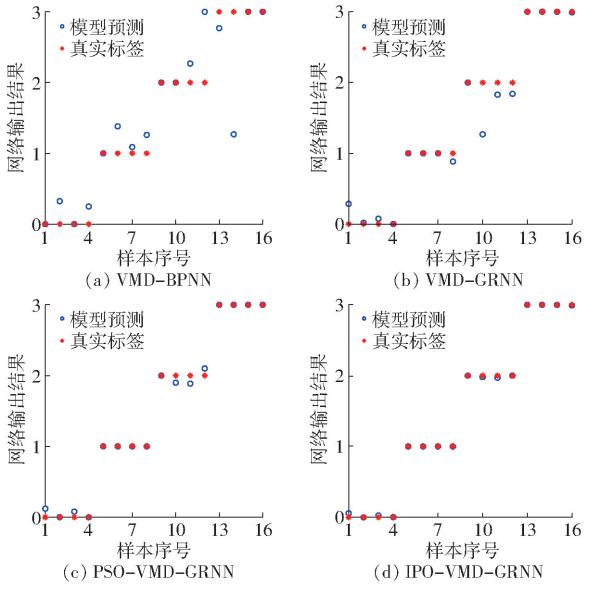

图 11　不同模型测试样本输出结果

Fig. 11　Results of test sample output of different models

表 3　模型输出结果性能评价指标

Tab. 3　Indicator values for performance evaluation of model outputs　　ms

模型	模型预测时间			
	成功阈值为 60%	成功阈值为 70%	成功阈值为 80%	成功阈值为 90%
VMD－BPNN	104	233	386	513
VMD－GRNN	107	229	335	420
PSO－VMD－GRNN	83	145	277	378
IPO－VMD－GRNN	62	114	223	326

0.020 3、0.003 6，IPO－VMD－GRNN 模型平均预测成功的响应时间相较于 VMD－BPNN、VMD－GRNN、PSO－VMD－GRNN 分别缩短 127.75、91.5、39.5 ms，结果表明 IPO－VMD 信号处理后提取的特征具有良好的代表性，采用 IPO 优化 GRNN 参数后模型的泛化能力得到增强。本文提出的 IPO－VMD－GRNN 模型具有良好的预测能力。

参　考　文　献

[1] 陈学庚，温浩军，张伟荣，等. 农业机械与信息技术融合发展现状与方向[J]. 智慧农业(中英文)，2020，2(4)：1－16.
CHEN Xuegeng，WEN Haojun，ZHANG Weirong，et al. Advances and progress of agricultural machinery and sensing technology fusion[J]. Smart Agriculture，2020，2(4)：1－16. (in Chinese)

[2] 韩佳伟，朱文颖，张博，等. 装备与信息协同促进现代智慧农业发展研究[J]. 中国工程科学，2022，24(1)：55－63.
HAN Jiawei，ZHU Wenying，ZHANG Bo，et al. Equipment and information collaboration to promote development of modern smart agriculture[J]. Strategic Study of CAE，2022，24(1)：55－63. (in Chinese)

[3] 王晓磊，金振林，李晓丹，等. 串并混联四足仿生机器人动力学建模与分析[J]. 农业机械学报，2019，50(4)：401－412.
WANG Xiaolei，JIN Zhenlin，LI Xiaodan，et al. Dynamic modeling and analysis of serial-parallel hybrid quadruped bionic robot [J]. Transactions of the Chinese Society for Agricultural Machinery，2019，50(4)：401－412. (in Chinese)

[4] 陈久朋，李春磊，伞红军，等. 基于模型的四足机器人步态转换控制研究[J]. 农业机械学报，2024，55(3)：431－440，451.
CHEN Jiupeng，LI Chunlei，SAN Hongjun，et al. Model based gait transition control for quadruped robots[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(3)：431－440，451. (in Chinese)

[5] 闫煦. 四足机器人关节远程状态监测及故障诊断系统研究[D]. 桂林：桂林理工大学，2022.
YAN Xu. Research on remote condition monitoring and fault diagnosis system of quadruped robot joints[D]. Guilin：Guilin University of Technology，2022. (in Chinese)

[6] ZHAO D，YANG J，OKOYE M O，et al. Walking assist robot：a novel non-contact abnormal gait recognition approach based on extended set membership filter[J]. IEEE Access，2019，7：76741－76753.

[7] KERTESZ C，TURUNE M. Body state recognition for a quadruped mobile robot[C]//2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES). IEEE，2018：323－328.

[8] WU Y，FU Z，FEI J. Fault diagnosis for industrial robots based on a combined approach of manifold learning，treelet transform and Naive Bayes[J]. Review of Scientific Instruments，2020，91(1)：015116.

[9] 刘伟，刘旺，曹大虎，等. 基于改进 EMD 和 GA－BPNN 的机器人磨削颤振监测[J]. 振动与冲击，2024，43(9)：131－138.
LIU Wei，LIU Wang，CAO Dahu，et al. Robot grinding chatter monitoring based on improved EMD and GA－BPNN[J]. Journal of Vibration and Shock，2024，43(9)：131－138. (in Chinese)

[10] 李冰，张永德，袁立鹏，等. 液压四足机器人足端的力预测控制与运动平稳性[J]. 中国机械工程，2021，32(5)：523－532.
LI Bing，ZHANG Yongde，YUAN Lipeng，et al. Predictive control of plantar force and motion stability of hydraulic quadruped robot[J]. China Mechanical Engineering，2021，32(5)：523－532. (in Chinese)

[11] YANG T，ZHANG W，YU Z，et al. Falling prediction and recovery control for a humanoid robot[C]//Proceedings of the 2018 IEEE－RAS 18th International Conference on Humanoid Robots (Humanoids)，2018：1073－1079.

[12] XI Ao，MUDIYANSELAGE T，TAO Dacheng，et al. Balance control of a biped robot on a rotating platform based on efficient reinforcement learning[J]. IEEE/CAA Journal of Automatica Sinica，2019，6(4)：938－951.

[13] LI Zhibin，ZHOU Chengxu，CSTANO J，et al. Fall prediction of legged robots based on energy state and its implication of balance augmentation：a study on the humanoid[C]//Proceedings of the 2015 IEEE International Conference on Robotics and Automation (ICRA)，2015：5094－5100.

[14] MUMMOLO C, MANGIALARDI L, KIM J H. Numerical estimation of balanced and falling states for constrained legged systems[J]. Journal of Nonlinear Science, 2017, 27(4):1291 - 1323.
[15] ATKESON C, BAIDU B, BANERJEE N, et al. No falls, no resets: reliable humanoid behavior in the DARPA robotics challenge[C]//2015 IEEE - RAS 15th International Conference on Humanoid Robots (Humanoids), 2015: 623 - 630.
[16] DI Pei, HASEGAWA Y, NAKAGAWA S, et al. Fall detection and prevention control using walking-aid cane robot[J]. IEEE/ASME Transactions on Mechatronics, 2015, 21(2): 625 - 637.
[17] HUANG J, DI P, WAKITA K, et al. Study of fall detection using intelligent cane based on sensor fusion[C]//2008 International Symposium on Micro-nanomechatronics and Human Science, 2008: 495 - 500.
[18] SUBBURAMAN R, KANOULAS D, MURATORE L, et al. Human inspired fall prediction method for humanoid robots[J]. Robotics and Autonomous Systems, 2019, 121: 103257.
[19] 毕盛,刘皓熙,闵华清,等.基于多传感器信息融合的仿人机器人跌倒检测及控制[J].华南理工大学学报(自然科学版),2017,45(1):95 - 101.
BI Sheng, LIU Haoxi, MIN Huaqing, et al. Fall detection and control of humanoid robots based on multi-sensor information fusion[J]. Journal of South China University of Technology (Natural Science Edition), 2017, 45(1): 95 - 101. (in Chinese)
[20] KORMUSHEV P, UGURLU B, COLASANTO L, et al. The anatomy of a fall: automated real-time analysis of raw force sensor data from bipedal walking robots and humans[C]//Proceedings of the 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2012: 3706 - 3713.
[21] LEE D W, JUN K, NAHEEM K, et al. Deep neural network-based double-check method for fall detection using IMU - L sensor and RGB camera data[J]. IEEE Access, 2021, 9: 48064 - 48079.
[22] 王鑫,郑晓岩,高焕兵,等.基于卷积神经网络和多判别特征的跌倒检测算法[J].计算机辅助设计与图形学学报,2023,35(3):452 - 462.
WANG Xin, ZHENG Xiaoyan, GAO Huanbing, et al. A fall detection algorithm based on convolutional neural network and multi-discriminant feature[J]. Journal of Computer-Aided Design & Computer Graphics, 2023, 50(3): 452 - 462. (in Chinese)
[23] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531 - 544.
[24] SUN Y, LI S, WANG X. Bearing fault diagnosis based on EMD and improved Chebyshev distance in SDP image[J]. Measurement, 2021, 176: 109100.
[25] 周爽.基于自适应 VMD 与优化神经网络的滚动轴承寿命预测与故障诊断研究[D].南京:南京农业大学,2021.
ZHOU Shuang. Research on life prediction and fault diagnosis of rolling bearings based on adaptive VMD and optimized neural network[D]. Nanjing: Nanjing Agricultural University, 2021. (in Chinese)
[26] 何定桥,王鹏军,杨军.深度神经网络在 EMD 虚假分量识别中的应用[J].工程力学,2021,38(增刊 1):195 - 201.
HE Dingqiao, WANG Pengjun, YANG Jun. Application of deep neural networks in EMD false component identification[J]. Engineering Mechanics, 2021, 38(Supp. 1): 195 - 201. (in Chinese)
[27] WANG J, WANG W, HU X, et al. Black-winged kite algorithm: a nature-inspired meta-heuristic for solving benchmark functions and engineering problems[J]. Artificial Intelligence Review, 2024,57(4):98.
[28] RAJABI S, AZARI M S, SANTINI S, et al. Fault diagnosis in industrial rotating equipment based on permutation entropy, signal processing and multi-output neuro-fuzzy classifier[J]. Expert Systems with Applications, 2022, 206: 117754.
[29] 王振亚,姚立纲.广义精细复合多尺度样本熵与流形学习相结合的滚动轴承故障诊断方法[J].中国机械工程,2020,31(20):2463 - 2471.
WANG Zhenya, YAO Ligang. Rolling bearing fault diagnosis method based on generalized refined composite multiscale sample entropy and manifold learning[J]. China Mechanical Engineering, 2020, 31(20): 2463 - 2471. (in Chinese)
[30] GAO Z, YANG S, YU J, et al. Hybrid forecasting model of building cooling load based on combined neural network[J]. Energy, 2024, 297: 131317.
[31] ZHU H R, ZHAO Y L, HE Z K. Fractal localized EBG structure intelligently optimized by K-GRNN and GA method for signal and power integrity[J]. IEEE Transactions on Microwave Theory and Techniques, 2022, 71(6): 2333 - 2346.
[32] 史明泉,崔丽珍,赫佳星.基于 PSO - GRNN 神经网络的煤矿井下定位算法研究[J].中国矿业,2020,29(2):88 - 93.
SHI Mingquan, CUI Lizhen, HE Jiaxing. Underground positioning algorithm of coal mine based on PSO - GRNN neural network[J]. China Mining Magazine, 2020, 29(2): 88 - 93. (in Chinese)