

一种改进的混合灰狼优化支持向量机预测算法及应用

方晓玉, 李晓斌*, 郭震

上海应用技术大学电气与电子工程学院, 上海 201418

摘要 为了改善差分灰狼预测算法的早熟收敛、搜索能力不均衡、容易陷入局部最优等问题,提出了一种改进的混合灰狼优化(HGWO)预测算法,可自适应改进和调整差分进化中的变异算子、交叉算子和变异策略。嵌入具有分类预测功能的支持向量机(SVM),同时引入莱维飞行全局搜索更新狼群位置,优化 SVM 核函数参数 γ 和惩罚因子 C ,构建了 HGWO-SVM 预测算法预测推焦车大车道内物体的运动轨迹。结果表明,与已有算法相比,该算法对行人、自行车、电瓶车、电动三轮车、大中小型四轮汽车的位置预测相对实际值的误差分别降低了 4.21、4.14、7.91、2.03、25.53 个百分点,预测时间减少了 8.8~10 s。可以克服焦炉恶劣的环境影响,准确预测推焦车车道内运动对象的轨迹,为推焦车无人化运行提供主动安全的预测控制方法。

关键词 支持向量机; 灰狼优化算法; 差分进化; 莱维飞行; 目标跟踪; 轨迹预测

中图分类号 TP29

文献标志码 A

doi: 10.3788/LOP57.122801

Improved Hybrid Grey Wolf Optimization Support Vector Machine Prediction Algorithm and Its Application

Fang Xiaoyu, Li Xiaobin*, Guo Zhen

School of Electrical and Electronic Engineering, Shanghai Institute of Technology, Shanghai 201418, China

Abstract In order to solve the problems of premature convergence, uneven search ability, and tendency to fall into local optimality in differential grey wolf prediction algorithm, an improved hybrid grey wolf optimization (HGWO) prediction algorithm is proposed, which can adaptively improve and adjust the mutation operator, crossover operator, and mutation strategy. Support vector machine (SVM) with classification prediction function is embedded, while Levy flight global search is used to update the position of the wolves, and the SVM kernel function parameter γ and penalty factor C are optimized. Thus, an HGWO-SVM prediction algorithm is built to predict the large lane of the coke pusher. The results show that, compared with the existing algorithms, the relative errors of position prediction of pedestrian, bicycle, battery car, electric tricycle, and large, medium and small four-wheel vehicle are reduced by 4.21, 4.14, 7.91, 2.03, and 25.53 percentage points, respectively, and the prediction time is reduced by 8.8–10 s. It can overcome the harsh environmental impact of coke oven, accurately predict the trajectory of the moving targets in the lane of the coke pushing vehicle, and provide an active and safe predictive control method for the unmanned operation of coke pushing truck.

Key words support vector machine; grey wolf optimization algorithm; differential evolution; Levy flight; target tracking; trajectory prediction

OCIS codes 120.1880; 120.2040; 000.3110; 000.3870

1 引言

灰狼优化(GWO)算法^[1]是元启发式智能优化算法,模拟了自然界中灰狼种群的社会等级和捕

食行为。具有基础设置参数少、便于编程等优点,已成功应用于电力系统、无人机路径规划、自动控制、PI 控制器优化、机器学习、车间调度等领域中。

收稿日期: 2019-09-16; 修回日期: 2019-10-17; 录用日期: 2019-10-28

基金项目: 宝山钢铁股份有限公司科研资助项目(2018103104-19R030TAAA,27220H160171-J2016-171)

* E-mail: lixiaobinauto@163.com

标准的GWO算法探测能力弱、容易陷入局部最优、收敛速度慢、优化精度低,为解决这些问题,国内外学者对GWO算法进行了多次改进^[2]。龙文等^[3]通过正切三角函数描述的非线性控制方法调整位置更新公式改进GWO算法;徐松金等^[4]利用遗传算子对灰狼种群进行多样性变异,避免陷入局部最优的问题,提高了算法的性能;张贾奎等^[5]通过Tent混沌映射改进GWO算法,增加了种群个体的多样性;Rodríguez等^[6]使用模糊逻辑动态自适应调整灰狼个体的权重,提高了灰狼优化算法的性能;Rodríguez等^[7]结合混合差分进化算法和灰狼优化算法,求解了全局优化问题。

上述研究对GWO算法的改进是通过修改控制参数、位置更新方程或结合其他的优化算法引入新的算子等,虽然改善了算法的性能,但仍存在早熟收敛、局部和全局搜索全局能力不平衡、会陷入局部最优的缺陷。而支持向量机(SVM)用于分类预测小样本、高维度、局部极小点和非线性问题时,在核函数参数 γ 和罚因子 C 的优化中也存在许多问题,导致预测结果误差偏大。同时由于焦炉区域环境恶劣、行人相对较少、运动类型特殊,推焦车惯性大且刹车距离相对较长。用现有的预测方法对轨道推焦车进行轨迹预测,实际中无法保证正常安全生产。

为改善上述问题,增强算法的性能、提高算法的预测精度,在文献[8]提出的标准差分进化优化混合灰狼(DE-GWO)预测算法的基础上进行改进。考虑到差分算法的性能及控制参数之间存在的相关性较大,对变异算子、交叉算子和变异策略进行自适应调整和改进行,避免陷入局部最优,提高了算法的自适应收敛能力。结合莱维飞行扩大灰狼优化算法的搜索范围,获得最优的SVM核函数参数 γ 和惩罚因子 C 并进行分类预测等操作。使用该算法预测了推焦车运行区域运动物体的轨迹,实验结果表明,该算法在恶劣环境中依然具有良好的实用性能。

2 改进的混合灰狼优化SVM算法

2.1 差分进化算法及自适应改进的GWO算法

差分进化(DE)是在种群演化过程中,根据个体间的差异重新组合,得到竞争力较强的中间种群,后代和父代通过竞争获得下一代种群,更具竞争力^[9]。DE算法结构简单、参数少,主要通过变异、交叉和选择三个步骤进行计算,文献[8]的DE-GWO算法

具体步骤如下。

1) 变异:选取任意两个相异的个体 $X_{r_2}(t)$ 和 $X_{r_3}(t)$ 经差值缩放后,与待变异个体 $X_{r_1}(t)$ 组合,组合后的中间个体 $D_i(t+1)$ 可表示为

$$D_i(t+1) = X_{r_1}(t) + F \times [X_{r_2}(t) - X_{r_3}(t)], \quad (1)$$

式中, t 为当前迭代次数, $D_i(t+1)$ 为第 $t+1$ 代种群中第 i 个种群, F 为 $[0, 2]$ 内的变异算子, r_1, r_2 和 r_3 为 $[1, N]$ 内随机不相等且不为 i 的整数, N 为种群大小。

2) 交叉:利用前种群个体 $X_i(t+1)$ 的部分分量与变异的中间体 $D_i(t+1)$ 的对应分量按照二项交叉进行交换生成交叉种群,针对每个分量产生一个0到1的随机小数与交叉算子进行比较,交叉操作可表示为

$$U_{ij}(t+1) = \begin{cases} D_{ij}(t+1), & \text{if } X_{\text{rand}} \leq X_{\text{CR}} \text{ or } j = X_{\text{rand}}(1, N) \\ X_{ij}(t+1), & \text{if } X_{\text{rand}} > X_{\text{CR}} \text{ or } j \neq X_{\text{rand}}(1, N) \end{cases}, \quad (2)$$

式中, X_{CR} 为 $[0, 1]$ 内的交叉算子, X_{rand} 为 $[0, 1]$ 内的随机数,与交叉算子比较, D 为解空间的维数, j 为 $[1, D]$ 内的随机整数, $D_{ij}(t+1)$ 为变异中间体 $D_i(t+1)$ 的第 j 个分量; $X_{ij}(t+1)$ 为当前种群个体 $X_i(t+1)$ 的第 j 个分量;

3) 选择:经变异、交叉操作得到第 $t+1$ 代种群中第 i 个交叉个体 $U_i(t+1)$ 与第 i 个当前种群个体 $X_i(t+1)$ 竞争,若父代个体优于新获得的子代,则将父代个体保留给下一代,否则将子代个体保留给下一代,即通过适应值函数 f ,将种群的个体映射为一个实数。

$$X_i(t+1) = \begin{cases} U_i(t+1), & f[U_i(t+1)] \leq f[X_i(t)] \\ X_i(t), & f[U_i(t+1)] > f[X_i(t)] \end{cases}, \quad (3)$$

式中, $U_i(t+1)$ 为第 $t+1$ 代种群中第 i 个交叉个体, $X_i(t+1)$ 为第 $t+1$ 代种群中第 i 个当前种群个体。可以发现DE受 N, F 和交叉算子 X_{CR} 以及变异策略的影响,实验通过优化 F, X_{CR} 和变异策略提高种群的平均性能,得到最优的参数值。

2.1.1 自适应改进变异算子

由(1)式可以发现, F 的大小对算法的搜索范围和变异目标矢量的计算有很大的影响。若 F 取值过大,会使算法的搜索效率降低,影响求解全局最优解的精度;若 F 取值过小,会降低种群的多样性,容易早熟^[10]。传统DE算法中, F 为常数,不能平衡

全局搜索能力和收敛速度。本算法可自适应地改进变异算子 F , 使算法整体具有更好的全局收敛能力和速度, 可表示为

$$F = F_0 \times 2^{\exp\left(1 - \frac{T}{T+1}\right)}, \quad (4)$$

式中, F_0 为改进前的变异算子, T 为最大进化代数。可以看出, 改进后的 F 初期较大, 但随进化次数的增加会逐渐减小。

2.1.2 自适应改进交叉算子

从(2)式和(3)式中可以看出, X_{CR} 较大时有利于增强算法的局部搜索能力, X_{CR} 较小时有利于维护种群多样性。算法运行前期要避免出现局部最优的情况, 后期要注意加强局部收敛的能力。本算法使 X_{CR} 先小后大, 可表示为

$$X_{CR} = 0.8 \times (1 - F), \quad (5)$$

式中, X_{CR} 的变化趋势与 F 相反, 单调递增, 取值范围为 $[0, 0.8]$ 。自适应调整 X_{CR} 的取值范围, 可保证算法在运行前期有较大的种群多样性, 后期有较快的收敛速度。

2.1.3 改进变异策略

标准差分进化通常使用 DE/rand/1 变异策略, 即产生一个试验个体, 差分和交叉建立新的变异试验个体, 并决定哪一个个体能够进入下一代。本算法对其进行了调整和改进^[11], 围绕 $X_{r2}(t)$ 进行差值缩放, 但结果有局限性, 不具有向最优解进行快速收敛的能力, 局部搜索能力有待提高。因此添加了随机扰动进行扩容, 对差值进行一个范围内的上下浮动, 以增加数据量, 全局寻优, 在一定程度上修正算法运行中不可避免的误差, 使结果更加精确、算法收敛速度更快、更趋向最优解。改进的变异策略可表示为

$$D_i(t+1) = X_{r1}(t) + F \times [X_{rand} \times X_{r2}(t) - X_{randn} \times X_{r3}(t)], \quad (6)$$

式中, X_{rand} 为 $[0, 1]$ 之间的随机取值, X_{randn} 为方差为 1 均值为 0 正态分布的任意数, 通过改进后的差分进化优化 GWO 算法, 提高了算法的收敛和局部搜索的能力。

2.2 灰狼优化算法

GWO 算法是一种新的优化算法, 源于自然界中灰狼种群的社会等级和捕食行为^[1], 灰狼群体的等级结构如图 1 所示。

图 1 中顶层头狼 (α 狼) 负责群体的决策, 二层 β 狼协助管理决策, 三层 δ 狼负责侦查、放哨、捕猎、看护等行为, 底层 ω 狼, 负责平衡内部关系^[12]。狼的捕食行为包括三个部分: 搜索跟踪、包围和攻




图 1 灰狼群体的等级结构

Fig. 1 Hierarchical structure of the gray wolf group

击猎物。在搜索跟踪猎物时, 灰狼个体与猎物的距离为

$$d = |D \times X_p(t) - X(t)|, \quad (7)$$

式中, $X_p(t)$ 为猎物的位置, $X(t)$ 为当前迭代 ω 狼的位置, $D = 2m_1$ 为协同系数向量, m_1 为 $[0, 1]$ 之间的随机向量。

灰狼种群捕食位置更新公式为

$$\begin{cases} X(t+1) = X_p(t) - A \times d \\ A = 2am_2 - a \\ a = 2 - \frac{2t}{T} \end{cases}, \quad (8)$$

式中, A 为协同系数向量, a 为距离控制参数, 取值为 $[0, 2]$, m_2 为 $[0, 1]$ 之间的随机向量。狼群中其他灰狼个体将 α 、 β 和 δ 狼视为搜索的 3 个最优解, 利用(7)式更新 ω 狼所处的位置。

$$\begin{cases} d_\alpha = |D_1 \cdot X_\alpha(t) - X(t)| \\ d_\beta = |D_2 \cdot X_\beta(t) - X(t)| \\ d_\delta = |D_3 \cdot X_\delta(t) - X(t)| \end{cases}, \quad (9)$$

$$\begin{cases} X_1(t) = X_\alpha(t) - A_1 \cdot d_\alpha \\ X_2(t) = X_\beta(t) - A_2 \cdot d_\beta \\ X_3(t) = X_\delta(t) - A_3 \cdot d_\delta \end{cases}, \quad (10)$$

$$X(t+1) = \frac{X_1(t) + X_2(t) + X_3(t)}{3}, \quad (11)$$

式中, $X_\alpha(t)$ 、 $X_\beta(t)$ 、 $X_\delta(t)$ 分别为 α 、 β 、 δ 狼的位置向量, d_α 、 d_β 、 d_δ 分别为当前狼趋向 3 个最优解的距离, 根据 α 、 β 、 δ 狼的位置, 判断猎物和灰狼个体 ω 的位置关系。

2.3 莱维飞行改进位置更新公式

莱维飞行^[13]是一种搜索方法, 本算法利用莱维飞行对灰狼种群的更新位置进行改进, 扩大了 GWO 算法的搜索范围, 避免了出现局部最优线性, 改进后的位置更新可表示为

$$L(t+1) = X_\alpha(t) + X_{alpath} \oplus X_{Levy}(v), \quad (12)$$

$$L(t+1) = X_\beta(t) + X_{alpath} \oplus X_{Levy}(v), \quad (13)$$

$$L(t+1) = X_\delta(t) + X_{alpath} \oplus X_{Levy}(v), \quad (14)$$

式中, X_{alpath} 为步长控制量, 取 0.01, \oplus 为点对点乘

法, $\mathbf{X}_{Levy}(v)$ 为随机搜索路径, 可表示为

$$\mathbf{X}_{Levy}(v) = X_{step} \cdot [\mathbf{X}(t) - \mathbf{X}_m(t)] \cdot X_{randn} \quad (15)$$

式中, v 的取值区间为 $[1, 3]$, 实验中取 $v = 1.5$,

$X_{step} = \frac{u}{|v|^{1/v}}$ 为随机步长, $\mathbf{X}_m(t)$ 为当前迭代时 α 、 β 和 δ 狼的位置, u 和 v 服从正态分布。

$$\begin{cases} v \sim N(0, 1) \\ u \sim N(0, S^2) \\ S = \left[\frac{\Gamma(1+v) \cdot \sin\left(\frac{\pi \cdot v}{2}\right)}{\Gamma\left(\frac{1+v}{2}\right) \cdot v \cdot 2^{(v-1)/2}} \right]^{\frac{1}{v}}, \end{cases} \quad (16)$$

式中, Γ 为伽玛函数。本算法在 GWO 算法更新灰狼种群位置公式的基础上, 结合莱维飞行扩大了搜索范围, 再代入(7)式~(9)式中, 分析猎物与灰狼个体位置之间的关系, 提升了算法搜索的灵活性, 加强了算法的性能。

3 改进的 HGWO-SVM 预测算法

3.1 参数选择

考虑到推焦车大车道环境恶劣, 影响因素较多, 运动对象数量少且类型特殊, 选择具有非线性映射能力的径向基函数(RBF)作为 SVM^[14] 预测算法的核函数。均方误差(MSE)是预测值与实际值差的平方期望值, MSE 越小, 表明预测算法的精确度越高, 因此选择为适应度函数。由(4)式可以看出, SVM 的核函数参数 γ 和惩罚因子 C 对算法预测输出有很大的影响。本算法结合改进的差分进化算法、莱维飞行、GWO 算法对 γ 和 C 进行优化, 以减小恶劣环境对预测算法的影响, 获取 SVM 参数的最优解, 可准确预测推焦车车道恶劣环境中运动对象的轨迹, 从而控制推焦车实现自动安全运行。

3.2 HGWO-SVM 算法

将自适应改进的差分算法融入 GWO 算法中, 可避免算法陷入局部最优。在更新 $\mathbf{X}_\alpha(t)$ 、 $\mathbf{X}_\beta(t)$ 和 $\mathbf{X}_\delta(t)$ 时, 引入莱维飞行, 避免了 GWO 算法早熟收敛, 提高了算法的搜索能力, 得到最佳适应度函数下的 C 和 γ 。对 SVM 进行优化, 建立了基于自适应差分莱维飞行改进的 HGWO-SVM 轨迹预测算法。具体步骤如下。

1) 初始化灰狼种群、灰狼个体的位置和目标函数值 C 、 γ 。

2) 遍历狼群全部个体, 计算出狼群个体适应度的 MSE, 最优适应度作为 α 狼群, 其次作为 β 狼群, 剩下作为 δ 和 ω 狼群。

3) 更新狼群位置, 根据(7)式~(11)式对灰狼种群进行全局搜索, 更新 a 、 A 、 D 等参数的值。

4) 对每个狼在新位置上的适应度进行计算, 如果新个体适应度优于旧个体, 则用新个体的位置替换原来的位置, 同时更新适应度, 反之保留旧个体, 保持原有的适应度不变。

5) 依据(1)式~(6)式, 选择灰狼父代个体通过(1)式产生变异中间种群, 得到下一代子代种群。计算个体适应度, 再经过(3)式比较父代种群与子代种群的适应度, 选出较优的个体组成下一代种群, 由适应度函数决定下一代狼群种群。结合(12)式~(16)式扩大搜索范围, 更新 α 、 β 和 δ 狼的位置。

6) 根据(6)式添加随机扰动策略, 计算新产生个体的适应度, 若新个体适应度值优于旧个体, 则更新该个体。

7) 令 $t = t + 1$, 转至步骤 2) 继续运行, 达到最大迭代次数后, 输出全局最优目标函数值。

8) 输出 α 狼的位置, 即最优参数 C 、 γ 。

9) 采用最优参数 C 、 γ 进行 SVM 建模, 对测试集进行预测和结果分析。

4 实验结果及分析

4.1 实验数据集

为验证本算法在推焦车车道环境中的可行性和优越性, 将本算法应用在宝钢四焦炉大车道内运动对象的轨迹预测中。通过激光点云进行目标跟踪操作^[15-18], 扫描推焦车运行区域, 对运动目标(人和物体)的实时位置进行定位, 观察发现运动目标大致可分为行人、自行车、电瓶车、电动三轮车、大中小型四轮汽车五类。用改进的 HGWO-SVM 算法预测运动目标轨迹的实用性, 现场得到的扫描图如图 2 所示。

4.2 实验环境和开发工具箱

实验选用 RS-LiDAR-16 激光雷达, 进行轨迹数据采集, 采集数据作为物体的实际运动轨迹。实验的硬件为 Microsoft Windows 7 操作系统, 软件平台为 Matlab R2014a, 工具箱为林智仁开发设计的 LIBSVM, 操作简便。

4.3 样本数据选择和基础参数设置

在推焦车的大车道平面进行实验, 推焦车在固

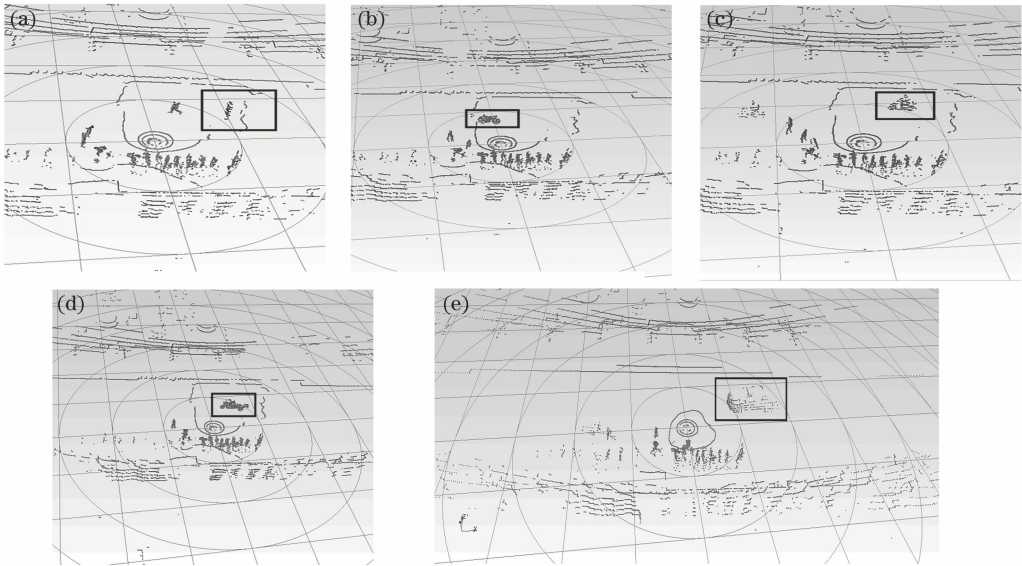


图 2 现场扫描图。(a)行人;(b)自行车;(c)电瓶车;(d)电动三轮车;(e)四轮汽车

Fig. 2 Scanning scene. (a) Pedestrian; (b) bicycle; (c) battery car; (d) electric tricycle; (e) four-wheel vehicle

定轨道上直行,因此不需要预测运动轨迹坐标的 X 轴,仅对运动目标每一帧的 Y 轴位置进行预测。每类运动目标轨迹选取 50 frame 数据代入改进后的 HGWO-SVM 算法中对物体运动轨迹进行预测,行人为第 1 组,自行车为第 2 组,电瓶车为第 3 组,电动三轮车为第 4 组,四轮汽车为第 5 组。训练集为各组的 1~32 frame,测试集为各组的 33~50 frame。灰狼种群大小为 30,迭代次数为 300,自变量维数为 2,即对两个参数进行优化, C 和 γ 的寻优范围分别为 $[0.1, 100]$ 和 $[0.01, 1000]$,缩放比例因子范围为 $[0.2, 0.8]$,交叉概率 X_{CR} 的初始值为 0.2。

4.4 推焦车车道现场行人轨迹预测实验

为验证改进后的 HGWO-SVM 算法在预测推焦车恶劣环境中运动对象轨迹方面的有效性和优越性,用改进的 HGWO-SVM 算法对五组数据进行训练实验,与 DEGWO-SVM 算法预测的位置进行比较,结果如图 3 所示。改进后的 HGWO-SVM 算法优化得到 1~5 组数据的最佳惩罚参数 C 分别为 12.4849、15.5353、9.6322、9.4674、9.7111,最佳核函数参数 γ 均为 0.01。

图 3 中箭头表示整体的运动方向,可以明显看出 HGWO-SVM 估测的轨迹运动方向与现场扫描得到的连线更加吻合,这表明改进后的算法预测结果更接近物体的实际运动的趋势和轨迹。5 组图像的算法运行时间如表 1 所示,轨迹预测结果的相对

误差如表 2 所示。

从表 1 可以看出,在参考文献[8]提出的 DEGWO-SVM 算法上,分别改进变异算子、交叉算子、变异策略、加入莱维飞行,均能提高算法的收敛速度,减少运行时间,而本算法能明显缩短算法的运行时间,可减少 8.8~10.0 s。

现场实验得到 1~5 组的 MSE 值分别为 0.0631732、0.0746209、0.0438458、0.0587132、0.0646481 m,这表明 HGWO-SVM 算法具有较好的精确度。

从表 2 中可以看出改进后的 HGWO-SVM 算法对各组轨迹位置预测的相对误差均比 DEGWO-SVM 小,减小了 2.03 至 25.53 个百分点。这表明改进后的算法预测精度高。实验仅对物体的运动方向进行预测,结合图 3 的轨迹预测图可以发现,改进后的 HGWO-SVM 预测算法相对误差更小,整体预测的运动方向更准确,且运行时间更少、效率更高,可以应用于区域内行人和物体运动的轨迹预测。

5 结 论

以 DEGWO-SVM 算法为参考,自适应地改进算法的变异算子,交叉算子和变异策略,结合莱维飞行优化 SVM 算法的核函数参数 γ 和惩罚因子 C ,训练 SVM。在宝钢四焦炉大车道进行现场试验,结果表明,与 DEGWO-SVM 算法的预测结果相比,改进后的算法建立的预测算法可以准确预测

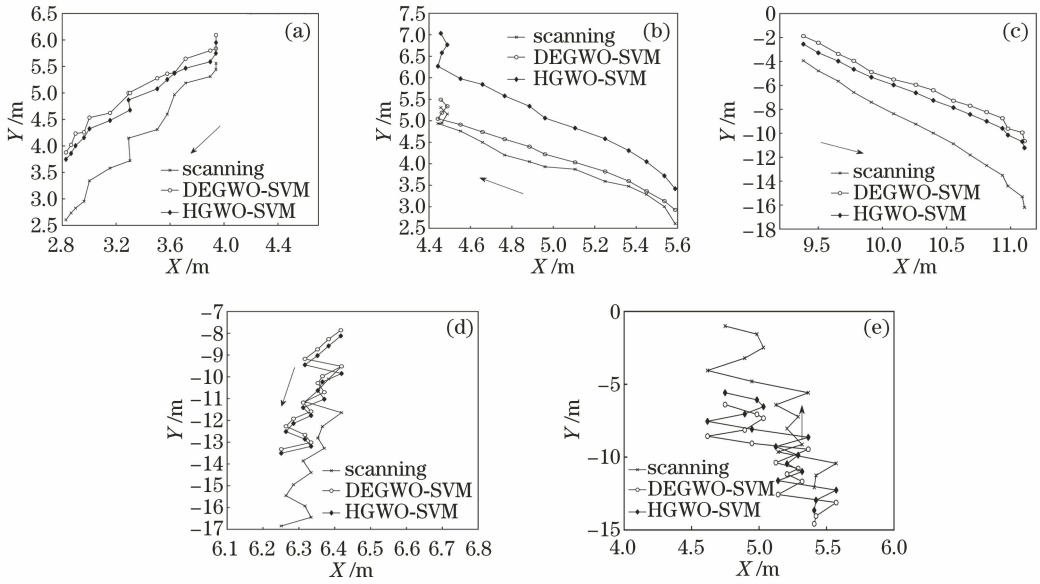


图 3 运动轨迹预测图。(a)行人;(b)自行车;(c)电瓶车;(d)电动三轮车;(e)四轮汽车

Fig. 3 Prediction graph of motion trajectory. (a) Pedestrian; (b) bicycle; (c) battery car; (d) electric tricycle; (e) four-wheel vehicle

表 1 改进后的算法运行时间

Table 1 Run time of the improved algorithm

unit: s

Number	DEGWO-SVM	Improved mutation operator	Improved crossover factor	Improved mutation strategy	Improved levy flight	HGWO-SVM
Group1	49.021701	43.253558	46.732346	47.625673	41.143532	39.083659
Group2	48.954682	44.024647	47.923113	46.253631	42.253612	40.138830
Group3	48.487896	43.638574	46.743213	46.132435	42.412663	39.990193
Group4	50.368133	42.354325	46.931367	47.721573	41.315262	40.358665
Group5	51.155398	44.356235	47.622442	48.256367	42.043422	41.315698

表 2 运动目标位置预测的相对误差

Table 2 Relative error of the position prediction of

moving target unit: %

Number	DEGWO-SVM	HGWO-SVM
Group1	26.12	21.91
Group2	22.11	17.97
Group3	37.46	29.55
Group4	19.30	17.27
Group5	119.36	95.83

推焦车车道内对象(行人与车辆)的运动轨迹,且运行时间更短、预测值与实际值的相对误差更小,可应用于预测推焦车运行区域内运动对象的轨迹。

参 考 文 献

[1] Mirjalili S, Mirjalili S M, Lewis A. Greywolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
 [2] Wei Y, Ni, Liu DY, et al. An improved grey wolf

optimization strategy enhanced SVM and its application in predicting the second major [J]. Mathematical Problems in Engineering, 2017, 2017: 1-12.

[3] Long W, Wu T B. Improved grey wolf optimization algorithm coordinating the ability of exploration and exploitation [J]. Control and Decision, 2017, 32 (10): 1749-1757.
 龙文, 伍铁斌. 协调探索和开发能力的改进灰狼优化算法 [J]. 控制与决策, 2017, 32(10): 1749-1757.
 [4] Xu S J, Long W. Improved grey wolf optimization algorithm embedded with genetic operators [J]. Journal of Lanzhou University of Technology, 2016, 42(4): 102-108.
 徐松金, 龙文. 嵌入遗传算子的改进灰狼优化算法 [J]. 兰州理工大学学报, 2016, 42(4): 102-108.
 [5] Zhang J K, Cui L J, Guo Q, et al. Grey wolf optimizer based on tent chaotic sequence [J]. Microelectronics & Computer, 2018, 35(6): 11-16.

- 张贾奎, 崔利杰, 郭庆, 等. 基于 Tent 混沌序列的灰狼优化算法[J]. 微电子学与计算机, 2018, 35(6): 11-16.
- [6] Rodríguez L, Castillo O, Soria J. Grey wolf optimizer with dynamic adaptation of parameters using fuzzy logic [C]//2016 IEEE Congress on Evolutionary Computation, July 24-29, 2016. Vancouver, BC, Canada. New York: IEEE, 2016: 3116-3123.
- [7] Rodríguez L, Castillo O, Soria J, et al. A fuzzy hierarchical operator in the grey wolf optimizer algorithm [J]. Applied Soft Computing, 2017, 57: 315-328.
- [8] Deng S H, Wang X L, Zhu Y S, et al. Hybrid grey wolf optimization algorithm - based support vector machine for grout ability prediction of fractured rock mass[J]. Journal of Computing in Civil Engineering, 2019, 33(2): 04018065.
- [9] Zhang X M, Tu Q, Kang Q, et al. Hybrid optimization algorithm based on grey wolf optimization and differential evolution for function optimization[J]. Computer Science, 2017, 44(9): 93-98, 124.
张新明, 涂强, 康强, 等. 灰狼优化与差分进化的混合算法及函数优化[J]. 计算机科学, 2017, 44(9): 93-98, 124.
- [10] Yuan Y C, Yang Z, Luo T X, et al. Multi-population-based competitive differential evolution algorithm for dynamic optimization problem [J]. Journal of Computer Applications, 2018, 38(5): 1254-1260.
袁亦川, 杨洲, 罗廷兴, 等. 求解动态优化问题的多种群竞争差分进化算法[J]. 计算机应用, 2018, 38(5): 1254-1260.
- [11] Bi X J, Wang J H. Teaching-learning-based optimization algorithm with hybrid learning strategy [J]. Journal of Zhejiang University (Engineering Science), 2017, 51(5): 1024-1031.
毕晓君, 王佳荟. 基于混合学习策略的教与学优化算法[J]. 浙江大学学报(工学版), 2017, 51(5): 1024-1031.
- [12] Long W, Cai S H, Jiao J J, et al. Hybrid grey wolf optimization algorithm for high-dimensional optimization [J]. Control and Decision, 2016, 31(11): 1991-1997.
- 龙文, 蔡绍洪, 焦建军, 等. 求解高维优化问题的混合灰狼优化算法[J]. 控制与决策, 2016, 31(11): 1991-1997.
- [13] Mo Y H, Nie H, Liu Z B, et al. Grey wolf optimization algorithm based on levy flight [J]. Microelectronics & Computer, 2019, 36(4): 78-83.
莫艳红, 聂慧, 刘振丙, 等. 基于莱维飞行的灰狼优化算法[J]. 微电子学与计算机, 2019, 36(4): 78-83.
- [14] Yang Z J. Bankruptcy prediction based on support vector machine optimized by particle swarm optimization and genetic algorithm [J]. Computer Engineering and Applications, 2013, 49(18): 265-270.
杨钟瑾. 粒子群和遗传算法优化支持向量机的破产预测[J]. 计算机工程与应用, 2013, 49(18): 265-270.
- [15] Qian Q S, Hu Y H, Zhao N X, et al. Target tracking algorithm based on global feature matching processing of laser point cloud [J]. Laser & Optoelectronics Progress, 2020, 57(6): 061012.
钱其姝, 胡以华, 赵楠翔, 等. 基于激光点云全局特征匹配处理的目标跟踪算法[J]. 激光与光电子学进展, 2020, 57(6): 061012.
- [16] Chen X Y, Yun T, Xue L F, et al. Classification of tree species based on LiDAR point cloud data [J]. Laser & Optoelectronics Progress, 2019, 56(12): 122801.
陈向宇, 云挺, 薛联凤, 等. 基于激光雷达点云数据的树种分类[J]. 激光与光电子学进展, 2019, 56(12): 122801.
- [17] Lu X Y, Yun T, Xue L F, et al. Effective feature extraction and identification method based on tree laser point cloud [J]. Chinese Journal of Lasers, 2019, 46(5): 0510002.
卢晓艺, 云挺, 薛联凤, 等. 基于树木激光点云的有效特征抽取与识别方法[J]. 中国激光, 2019, 46(5): 0510002.
- [18] Tong Y, Xia M, Yang K C, et al. Target reflection feature extraction based on LiDAR intensity value [J]. Laser & Optoelectronics Progress, 2018, 55(10): 102802.
童祎, 夏珉, 杨克成, 等. 基于激光雷达强度值的目标反射特征提取[J]. 激光与光电子学进展, 2018, 55(10): 102802.