



具有混合策略的樽海鞘群特征选择算法

余紫康, 董红斌

引用本文:

余紫康, 董红斌. 具有混合策略的樽海鞘群特征选择算法[J]. *智能系统学报*, 2024, 19(3): 757-765.

YU Zikang, DONG Hongbin. Salp swarm feature selection algorithm with a hybrid strategy[J]. *CAAI Transactions on Intelligent Systems*, 2024, 19(3): 757-765.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202209040>

您可能感兴趣的其他文章

不完备数据中面向特征值更新的增量特征选择方法

Incremental approach for feature selection in incomplete data while updating feature values

智能系统学报. 2021, 16(3): 493-501 <https://dx.doi.org/10.11992/tis.202006045>

无人机群目标搜索的主动感知方法

Active perception method for UAV group target search

智能系统学报. 2021, 16(3): 575-583 <https://dx.doi.org/10.11992/tis.202009012>

布谷鸟搜索算法研究及其应用进展

Overview of the cuckoo search algorithm and its applications

智能系统学报. 2020, 15(3): 435-444 <https://dx.doi.org/10.11992/tis.201811005>

一种面向任务的对地观测卫星Agent团队构建方法

Agent team formation approach for task-oriented earth observation satellite

智能系统学报. 2017, 12(5): 653-660 <https://dx.doi.org/10.11992/tis.201706017>

面向特征选择问题的协同演化方法

Co-evolutionary algorithm for feature selection

智能系统学报. 2017, 12(01): 24-31 <https://dx.doi.org/10.11992/tis.201611029>

面向特征选择问题的协同演化方法

Co-evolutionary algorithm for feature selection

智能系统学报. 2017, 12(1): 24-31 <https://dx.doi.org/10.11992/tis.201611029>

DOI: 10.11992/tis.202209040

网络出版地址: <https://link.cnki.net/urlid/23.1538.TP.20230913.1858.006>

具有混合策略的樽海鞘群特征选择算法

余紫康, 董红斌

(哈尔滨工程大学 计算机科学与技术学院, 黑龙江 哈尔滨 150001)

摘要:近年来,随着计算机和数据库技术的快速发展,大规模数据集迅速增长,利用特征选择技术来筛选信息量大的特征已经变得非常重要。本文提出了一种具有混合策略的樽海鞘群特征选择算法 (salp swarm feature selection algorithm with hybrid strategy, HS-SSA)。首先,本文生成一张基于互信息的排序表,并由排序表提出了新的初始化策略。其次,提出一个新颖的并且有条件调用的动态搜索算法。最后在位置更新上结合瞬态搜索算法 (transient search algorithm, TSO),改进勘探和开发步骤的效率,增加解空间的灵活性和多样性,从而使算法能够快速定位到全局最优位置。为了验证算法的性能,实验选取 14 个 UCI 的数据集,并且与樽海鞘群算法 (SSA) 以及近几年樽海鞘群的改进算法等多种优化算法进行比较,结果表明 HS-SSA 在特征选择上具有更强的竞争力。

关键词:特征选择;樽海鞘群算法;瞬态搜索算法;启发式算法;互信息;动态搜索算法;秩和检验;K 近邻
中图分类号: TP301 **文献标志码:** A **文章编号:** 1673-4785(2024)03-0757-09

中文引用格式:余紫康,董红斌.具有混合策略的樽海鞘群特征选择算法[J].智能系统学报,2024,19(3):757-765.

英文引用格式:YU Zikang, DONG Hongbin. Salp swarm feature selection algorithm with a hybrid strategy[J]. CAAI transactions on intelligent systems, 2024, 19(3): 757-765.

Salp swarm feature selection algorithm with a hybrid strategy

YU Zikang, DONG Hongbin

(School of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China)

Abstract: In recent years, with the rapid development of computer and database technologies, the number of large-scale datasets has rapidly increased. Thus, the use of feature selection technology is important to screen features with massive amounts of information. In this study, a salp swarm feature selection algorithm with a hybrid strategy (HS-SSA) is proposed. Initially, a sorted table based on mutual information is generated, and a new initialization strategy is proposed on the basis of this sorted table. Furthermore, a novel dynamic search algorithm with conditional call is proposed. With respect to location updates, the efficiency of exploration and development steps is improved, and the flexibility and diversity of the solution space are increased by combining the transient search algorithm (TSO). Consequently, the algorithm can rapidly locate the global optimal location. To verify algorithm performance, 14 UCI datasets were selected for the test. In addition, the proposed algorithm was compared with the salp swarm algorithm (SSA), the improved SSA, and many other improved algorithms in recent years. The results show that HS-SSA is more competitive in feature selection.
Keywords: feature selection; salp swarm algorithm; transient search algorithm; heuristic algorithm; mutual information; dynamic search algorithm; rank sum test; K-nearest neighbor

在过去的几十年中,计算机和数据库技术的快速发展导致了大规模数据集的增长迅速,因

此,在使用数据集之前,有必要对数据进行预处理,去除冗余特征。所以特征选择变得越来越重要。它通过消除不相关、冗余或噪声数据来降低数据的维数,是简化数据分析、获取数据关键特征的有效技术^[1]。最终从给定的数据集中选择最

收稿日期:2022-09-19. 网络出版日期:2023-09-15.

基金项目:黑龙江自然科学基金项目(LH2020F023).

通信作者:董红斌. E-mail: donghongbin@hrbeu.edu.cn.

©《智能系统学报》编辑部版权所有

有用的特征集,这有利于提高机器学习算法的泛化能力,减少训练时间,使模型更具可解释性。基于特征的选择机制,特征选择通常可以分为两类:过滤式(filter)、包裹式(wrapper)。过滤式是根据原始数据上的每个特征的属性直接计算评价指标^[2],特征选择过程与后续学习算法无关。包裹式方法首先由 John 等提出^[3]。它需要一个预先设定的学习算法,将特征子集在其算法上的表现作为评估来确定最终的特征子集^[4]。基于过滤式方法的特征选择算法的优点是通常比包裹式方法的计算复杂度低得多,但是所选的特征子集在分类准确率方面通常低于包裹式方法。包裹式方法依赖于分类器的优化或所选分类器本身,所以它的特征通用性不强,并且计算复杂度更高。目前基于二者的混合方法已经被提出^[5],它结合了上述两种方法的优点。

据报道,特征选择是一个 NP 难问题,它试图从一个有 N 个特征的数据集的 $2^n - 1$ 个可能的特征子集中找到最佳子集。这对特征选择问题的搜索策略提出了很大的挑战^[6]。近年来,许多优化算法根据其性能被应用于包裹模式下的特征选择问题,并取得了良好的效果。例如粒子群优化(particle swarm optimization, PSO)^[7]、樽海鞘群算法(salp swarm algorithm, SSA)^[8]、哈里斯鹰优化(Harris Hawks optimization, HHO)^[9]、灰狼优化器(grey wolf optimizer, GWO)^[10]和遗传算法(genetic algorithms, GA)^[11]等。对于每一种优化算法,都存在分类精度低,泛化能力差、勘探与开发不平衡,容易陷入局部最优等缺点。为了克服这些问题,许多优化算法的改进版本被提出。例如 Kilic 等^[12]提出了一种新的基于多种群的粒子群算法(multi population PSO, MPPSO)进行特征选择。在该方法中,多种群从随机生成的初始解和基于 Relieff 排序生成的初始解同时开始,使用两个种群搜索解空间,使搜索空间多样化。Tu 等^[13]提出了一种多策略集成 GWO,该方法克服了全局优化算法在求解函数优化问题时搜索策略单一的局限性。Mafarja 等^[14]将 8 个时变传递函数集成到蜻蜓算法中,实现了勘探与开发之间的稳定平衡。还有 Tubishat 等^[15]提出了一种动态 SSA(dynamic SSA, DSSA),在 SSA 的基础上提出了一个新的位置更新方程,增强了 SSA 解决方案的多样性,并且开发出了一种新的局部搜索算法来帮助算法跳出局部最优。

同时也有不少研究者在先前算法的基础上结合一些启发式算法来解决特征选择问题。例如

Zawbaa 等^[16]开发了一种基于 GWO 和蚁狮优化器的混合特征选择方法来解决精度、高维数和计算复杂度的问题。Zivkovic 等^[17]提出了一种具有替换机制的 SSA 和正弦余弦算法(SSA with replacement mechanism and sine cosine algorithm, SSARM-SCA)。Mafarja 等^[18]提出了结合鲸鱼优化算法和模拟退火的混合算法。还有 Dhal 等^[19]提出了一种基于 PSO 和 GWO 的混合特征选择方法的二进制版本,融合 PSO 的挖掘能力与 GWO 探测能力。针对樽海鞘群算法存在容易陷入局部最优,种群多样性较差等缺点,本文提出了一种具有混合策略的樽海鞘群特征选择算法(salp swarm feature selection algorithm with hybrid strategy, HS-SSA)。在原有的 SSA 算法的基础上进行了 3 个改进:

1) 利用互信息生成了特征排序表,并提出了新的初始化策略,提高了初始种群的质量和多样性;

2) 提出了一个新颖的根据最佳解的改进情况和迭代次数有条件执行的动态搜索算法,来帮助种群在初期淘汰替换较差的种群,后期避免局部最优;

3) 结合瞬态搜索算法,随机地选择位置更新方程,这改进了勘探和开发步骤的效率,增加了解空间灵活性和多样性。

1 背景知识

1.1 樽海鞘群算法

樽海鞘群算法(SSA)在 2017 年由 Mirjalili 等^[8]提出。它是利用樽海鞘链的概念来模拟樽海鞘在水中的群集行为,这种行为可以用于它们寻找食物的运动中。樽海鞘的链式群行为中,通常个体首尾相接,形成一条“链”,依次跟随进行移动。在樽海鞘链中,第一个个体被划分为领导者,其他的为追随者,领导者不断向着食物移动,并带领其他追随者移动。在搜索空间中每个樽海鞘个体都在 n 维的搜索空间中搜索,其中 n 为数据中特征的数量,此外我们用 F 表示食物的位置,也就是樽海鞘链中个体的最好位置。SSA 的领导者位置更新公式为

$$X_j^1 = \begin{cases} F_j + r_1((u_j - l_j)r_2 + l_j), & r_3 \geq 0.5 \\ F_j - r_1((u_j - l_j)r_2 + l_j), & r_3 < 0.5 \end{cases} \quad (1)$$

式中: X_j^1 的上标 1 表示樽海鞘链中的第一个樽海鞘,也就是领导者;下标 j 代表第 j 维,所以它表示领导者在第 j 维的位置; F_j 代表食物在第 j 维的

位置; u_j 和 l_j 分别表示上下边界在第 j 维的位置, $j \in [1, n]$; r_2 和 r_3 是 $[0, 1]$ 之间的随机数, 分别表示了领导者在更新时的移动位置大小和移动方向; n 是收敛因子, 起到了平衡全局搜索和局部开发的作用, n_1 的更新公式为

$$r_1 = 2 \exp[-(4l/L)^2] \quad (2)$$

式中: l 为当前迭代次数, L 表示总共要迭代的次数。SSA 追随者的位置更新公式为

$$X_j^i = \frac{1}{2}(X_j^i + X_j^{i-1}), i \geq 2 \quad (3)$$

式中: X_j^i 表示第 i 个樽海鞘在第 j 维的位置, 第 i 个樽海鞘即追随者的位置更新受它前一个樽海鞘 X^H 的位置影响, 以此类推, 都由领导者间接引领。

1.2 瞬态搜索算法

瞬态搜索优化算法 (transient search optimization, TSO) 是于 2020 年 Qais 等^[20]提出的, 是一种新的基于物理的启发式优化算法。该算法的灵感来自于包含电感和电容等存储元件的开关电路的瞬态行为。TSO 算法被建模为在搜索区域的下界和上界之间初始化搜索代理; 寻找最佳解决方案 (探索); 达到稳定状态或最佳解决方案 (开发)。

TSO 搜索代理进行初始化的公式为

$$Y = l + r \times (u - l) \quad (4)$$

式中: l 是搜索空间的下界, u 是搜索空间的上界, r 是 $(0, 1)$ 上均匀分布的随机向量。

TSO 的探测行为是受到的二阶电路在零点附近振荡的启发。利用随机数 n_1 来平衡勘探 ($n_1 \geq 0.5$) 和开发 ($n_1 < 0.5$) 之间的关系。TSO 算法的开发和探索的数学模型为

$$Y_{t+1} = \begin{cases} Y_t^* + (Y_t - C_1 \times Y) \exp(-T), & r_1 < 0.5 \\ Y_t^* + \exp(-T) [\cos(2\pi T) + \sin(2\pi T)] |(Y_t - C_1 Y_t^*)|, & r_1 \geq 0.5 \end{cases} \quad (5)$$

$$T = 2 \times z \times r_2 - z \quad (6)$$

$$C_1 = k \times z \times r_3 + 1 \quad (7)$$

$$z = 2 - 2 \left(\frac{l}{L_{\max}} \right) \quad (8)$$

式中: Y_{t+1} 是当前的搜索代理 Y_t 的此次迭代更新的位置, Y_t^* 是全局最佳位置, l 为当前迭代次数, L_{\max} 为最大迭代次数, z 为从 2 变为 0 衰减系数变量。 n_1 、 r_2 、 r_3 为 $[0, 1]$ 内的随机数, T 和 C_1 为热阻系数, k 是一个常数 ($k = 0, 1, \dots$)。

2 提出的方法

2.1 基于互信息的初始化策略

互信息的概念是由 Shannon 等^[21]首先提出, 它的引入是用来衡量两个变量间相互依赖的程

度, 描述了变量之间的公共信息。给定两个变量 X 和 Y , 其边缘概率为 $P(x)$ 和 $P(y)$, 联合概率为 $P(x, y)$, 条件概率为 $P(x|y)$ 。 $H(X)$ 表示随机变量的熵, 它度量一个变量的不确定性, $H(X|Y)$ 是条件熵, 它们两者之间差值可以表示为互信息 $I(X; Y)$, 具体表达式为

$$H(X) = - \sum_{x \in X} P(x) \log_2 P(x) \quad (9)$$

$$H(X|Y) = - \sum_{y \in Y} \sum_{x \in X} [P(x, y) \log_2 P(x|y)] \quad (10)$$

$$I(X; Y) = H(X) - H(X|Y) \quad (11)$$

可以取 X 为某种特征, Y 为类标签, 用来计算互信息, 结果越大, 表明该特征与类标签的相关性越大, 则认为该特征分类效果更好。并且互信息的有效性已经被证明^[6, 22-23]。

在本文利用数据集中每个特征与类标签之间的互信息值进行排序, 生成一张排序表, 排序中数值越大越靠前的特征被认为是和类标签关系越密切, 即更加重要。排序表被分成了 4 个部分, 每部分被选中的概率依次减小。通过这种方式既保证每个特征都有机会被选中, 继续参加后续迭代, 又使得表现良好的特征传给下一代的机会更大。在此策略中 60% 的初始数据集生成利用此互信息表, 另外 40% 采用随机初始化策略。此划分能使大部分初始种群生成受到互信息表影响, 更多的去选择与类标签关系紧密的特征, 另外一小部分则保持随机生成, 这同时能兼顾初始种群的多样性。

2.2 动态搜索算法

SSA 位置更新公式 (式 (1)) 仅用于领导者, 而追随者的移动依赖于自身和前一个个体, 如果该算法幸运地找到了搜索空间中最优解所在区域, 那么搜索过程最终会收敛, 得到满意的解。相反, 搜索将停留在次最优区域, 在运行结束时, F 将远离全局最优解, 为此本文对原始 SSA 提出的第 2 种改进为有条件的使用动态搜索算法 (dynamic search algorithm, DSA), 在每一次迭代结束后, 会判断是否调用此算法, 这是为了避免多次计算消耗。此算法被调用是根据种群最优解 F 来判断的, 为此在 SSA 末尾增加了一个计数器 count, 当 F 的适应度一次迭代后没有变化时, count 就会加 1, 当 count 到达 3 时就会调用 DSA, DSA 的伪代码如算法 1 所示。

算法 1 动态搜索算法的伪代码

输入 当前种群位置 L , 当前迭代次数 t 和最大迭代次数 M , 后半段动态搜索算法迭代次数 K
输出 新的种群位置

- 1) If $t < M/2$ /*算法前半段*/
- 2) $Loc = DSA_1(L,t)$
- 3) Else /*算法后半段*/
- 4) $Loc = DSA_2(L,t,K)$
- 5) End If
- 6) Return Loc

此算法前半段受到进化种群动态机制^[24]的启发,此机制是一种通过将最坏的解决方案重新安置在最好的解决方案周围。本文的 DSA 在迭代次数小于一半时,将适应度后 50% 的个体淘汰,并将 25% 的新个体通过在最佳解 F 周围生成,对 F 随机取反 1~5 个特征 (小到大的数据集都适用),如图 1 所示。

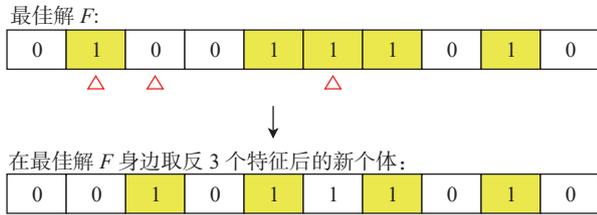


图 1 通过反转 3 个特征在最佳解身边生成的新个体实例
Fig. 1 New individual instances generated around the best solution by reversing the three features

另外 25% 的个体则通过初始化机制生成。此划分以目前种群的最优解作为找到最优可能性较大的位置,在它身边进行发掘,同时考虑了其他位置寻找到最优的可能性。DSA 前半段的伪代码如算法 2 所示。

算法 2 DSA_1(L, t)

输入 当前种群位置 L , 当前迭代次数 t
输出 新的种群位置

- 1) 利用式 (12) 计算种群适应度,并淘汰较差的 50% 樽海鞘个体
- 2) 利用 2.1 节的策略生成 $25\% \times N$ 个新个体到种群
- 3) For $i = 1$ to $N \times 25\%$ do
- 4) 把 F 的值赋给 F_copy , n 随机初始化为 1~5
- 5) 从 F_copy 中随机挑选 n 个特征
- 6) For 对于被挑选的特征 in F_copy
- 7) If 特征的值为 1 /*1 代表被选择, 0 为没有*/
- 8) 特征值改为 0
- 9) Else
- 10) 特征值改为 1
- 11) End If
- 12) End For
- 13) 把 F_copy 加入到种群中
- 14) End For

- 15) 寻找这些新个体的最优适应度值的个体 m
- 16) If $f(m) < f(F)$ /*适应度越小越好*/
- 17) $F = m$
- 18) End If
- 19) Return Loc

当迭代次数大于一半时,为保持种群的稳定性,此时算法不再大规模地替换种群,而是采取结合互信息排序表,在最佳解 F 身边寻找, DSA 的每一次迭代中都会生成 2 个新个体,第 1 个利用互信息排序表,从最佳个体中删除已选择的排序表后端的 1~5 个特征,增添未选择的排序表前端的 1~5 个特征。第 2 个个体从最佳个体上随机挑选 1~5 个特征取反。之后这两个个体中最好的个体 m 与种群最佳个体比较,如果 m 适应度值优于当前的最佳解,则更新 F ,把 F 的值更新为 m ,否则用 m 去替换当前种群适应度最差的个体。DSA 的后半段能够帮助算法避免局部最优。伪代码中的 K 是后半段 DSA 的迭代次数,本文 K 设置为 5。DSA 后半段的伪代码如算法 3 所示。

算法 3 DSA_2(L, t, K)

输入 当前种群位置 L , 当前迭代次数 t , 后半段动态搜索算法的迭代次数 K

输出 新的种群位置

- 1) For $i = 1$ to k
- 2) n_1, n_2 和 n_3 分别在 1~5 中初始化,把 F 赋给 F_copy1, F_copy2 , 利用排序表从后往前从 F_copy1 中挑选 n_1 个已选特征,利用排序表从前往后挑选 n_2 个未选特征。从 F_copy2 随机挑选 n_3 个特征
- 3) For 对于被挑选的特征 in (F_copy1, F_copy2)
- 4) If 特征的值为 1 /* 1 代表被选择, 0 为没有*/
- 5) 特征值改为 0
- 6) Else
- 7) 特征值改为 1
- 8) End If
- 9) End For
- 10) 把 F_copy1, F_copy2 中适应度最佳个体赋给 m
- 11) If $f(m) < f(F)$
- 12) 把 m 赋给 F
- 13) Else
- 14) 把 m 赋给种群中最差的个体
- 15) End If
- 16) End For

17) Return Loc

2.3 HS-SSA 描述

本文对 SSA 有 3 个改进: 1) 利用互信息生成了特征排序表, 并用在新的初始化策略上; 2) 提出了动态搜索算法, 并且根据计数器 count 和迭代次数有条件的执行; 3) 在位置更新策略上, 原 SSA 追随者更新公式相对简单, 算法存在收敛速度较慢、容易陷入局部最优等缺点。为此, 本文将追随者的位置更新公式随机的在原式 (3) 和 TSO 搜索公式(式 (5))中进行选择, 这改进了勘探和开发步骤的效率, 增加了解空间灵活性和多样性, 从而算法能快速定位全局最优。算法 4 给出了 HS-SSA 的伪代码。

算法 4 HS-SSA 的伪代码

输入 最大迭代次数 M , 种群数量 N

输出 最佳适应度值的樽海鞘个体的位置 F

- 1) 用 2.1 节初始化策略初始化种群 $X_i(i = 1, 2, \dots, N)$
- 2) 计算所有个体适应度, 并把最佳个体位置赋给 F
- 3) While $t < M$
- 4) 更新 n, Z, T 和 C_i 通过式 (2)、(8)、(6) 和 (7)
- 5) For (每一个个体 X_i)
- 6) If $i == 1$
- 7) 通过式 (1) 更新领导者位置
- 8) Else
- 9) 生成 $[0,1]$ 的随机值 r
- 10) If $r > 0.5$
- 11) 通过 SSA 原位置更新公式(式 (3))更新追随者
- 12) Else
- 13) 通过 TSO 搜索公式(式 (5))更新追随者
- 14) End If
- 15) End If
- 16) End For
- 17) 更新超出上下边界的樽海鞘个体
- 18) 更新所有个体适应度, 把最佳个体位置赋给 F
- 19) 判断 F 是否变化从而更新计算器 count
- 20) If(count==3)
- 21) 在当前种群基础上调用算法 1
- 22) count = 0
- 23) End If
- 24) $t = t+1$
- 25) End While
- 26) Return F

2.4 适应度计算函数

适应度计算函数为

$$f(X_i) = \alpha \times e(X_i) + \beta \times \frac{s}{n} \tag{12}$$

式中: $\alpha \in (0, 1)$, $\beta = 1 - \alpha$, α 和 β 分别为错误率和选择特征比的权重系数, s 表示选择特征的数量, n 为数据集的特征维度, $e(X_i)$ 表示当前个体放入分类器中得到的错误率。在本文中 α 设置为 0.99, 则 β 为 0.01。

3 实验和结果分析

实验中代码运行环境为 Python3.9。硬件环境为 Intel(R) Core(TM) i5-7300HQ CPU @ 2.50 GHz, RAM 为 16.0 GB。

3.1 实验描述

为验证本文算法的性能, 使用了 14 个 UCI 数据集^[25]进行实验, 表 1 显示了数据集的基本信息。

表 1 数据集信息

Table 1 Information of dataset

| 数据集 | 特征数 | 样本数 | 类别数 |
|--------------|-----|------|-----|
| BreastEW | 30 | 568 | 2 |
| CongressEW | 16 | 434 | 2 |
| Exactly | 13 | 1000 | 2 |
| HeartEW | 13 | 270 | 2 |
| Horse | 27 | 368 | 2 |
| ionosphere | 34 | 351 | 2 |
| KrVsKpEW | 36 | 3196 | 2 |
| Lymphography | 18 | 148 | 4 |
| PenglungEW | 325 | 73 | 7 |
| Sonar | 60 | 208 | 2 |
| SpectEW | 22 | 267 | 2 |
| Tic-tac-toe | 9 | 958 | 2 |
| vehicle | 18 | 846 | 4 |
| Zoo | 16 | 101 | 7 |

实验采用了 80%:20% 的数据集划分, 即 80% 的数据作为训练集, 20% 数据作为测试集并且使用 K 近邻 (K-nearest neighbor) 作为分类器, $K=5$ 。同时和 SSA 算法、SSA 变体 DSSA^[15] 和 SSARM-SCA^[17], 还有 PSO、HHO 和 GWO 进行了实验对比, 表 2 给出了所有算法的参数设置。为确保结果更精确, 减少误差, 所有算法在每个数据集上运行 20 次, 取出分类准确率和维度缩减率的平均值, 并且做了 Wilcoxon 秩和检验以确定算法的显著性。

表 2 对比算法的参数设置
Table 2 Parameter setting of comparison algorithm

| 算法名称 | 参数设置 |
|---------------------------|---|
| HS-SSA | $N=30, M=200$, SSA中的 r_2, r_3 和TSO中的 r_2 和 r_3 为 $[0,1]$ 中的随机数, TSO中的 K 取值为3 |
| SSA ^[8] | $N=30, M=200$, r_2, r_3 为 $[0,1]$ 中的随机数 |
| DSSA ^[15] | $N=30, M=200$, r_2 和 r_3 为 $[0,1]$ 中的随机数, max_LSA_number_of_iterations=10 |
| SSARM-SCA ^[17] | $N=30, M=200$, r_2 和 r_3 为 $[0,1]$ 中的随机数, 替换机制次数设为 $M/10$, 最差替换解数设为 $N/5$ |
| PSO ^[7] | $N=30, M=200$, 设置 $c_1 = c_2 = 2, w=1$ |
| HHO ^[9] | $N=30, M=200$ |
| GWO ^[10] | $N=30, M=200$ |

3.2 实验结果与分析

为了使实验结果更具说服力, 对每个数据集都运行 20 次再取平均, HS-SSA 和对比算法运行

20 次以后得到的平均分类准确率和维度缩减率分别统计在表 3 和表 4。每个数据集中表现最好的标粗体。

表 3 HS-SSA 与对比算法在运行 20 次的平均准确率
Table 3 Average accuracy of the HS-SSA and competing algorithms in 20 runs

| 数据集 | HS-SSA | SSA | SSARM-SCA | DSSA | PSO | HHO | GWO |
|--------------|-----------------|----------|-----------|----------|----------|----------|----------|
| BreastEW | 0.971 05 | 0.959 21 | 0.959 65 | 0.961 84 | 0.952 63 | 0.952 63 | 0.957 46 |
| CongressEW | 0.985 63 | 0.971 26 | 0.975 86 | 0.978 74 | 0.977 59 | 0.966 09 | 0.975 86 |
| Exactly | 1.000 00 | 0.948 00 | 0.944 50 | 0.999 75 | 0.974 50 | 0.880 25 | 0.986 00 |
| HeartEW | 0.893 52 | 0.870 37 | 0.871 30 | 0.887 04 | 0.875 93 | 0.862 96 | 0.885 19 |
| Horse | 0.871 62 | 0.802 70 | 0.798 65 | 0.847 97 | 0.820 27 | 0.786 49 | 0.847 30 |
| ionosphere | 0.973 94 | 0.928 17 | 0.922 54 | 0.960 56 | 0.946 48 | 0.940 85 | 0.960 56 |
| KrVsKpEW | 0.985 86 | 0.971 56 | 0.975 08 | 0.984 22 | 0.981 17 | 0.971 88 | 0.980 78 |
| Lymphography | 0.948 33 | 0.918 33 | 0.923 33 | 0.931 67 | 0.930 00 | 0.896 67 | 0.923 33 |
| PenglungEW | 0.996 67 | 0.906 67 | 0.910 00 | 0.933 33 | 0.940 00 | 0.950 00 | 0.990 00 |
| Sonar | 0.982 14 | 0.923 81 | 0.922 62 | 0.966 67 | 0.961 91 | 0.938 10 | 0.972 62 |
| SpectEW | 0.921 30 | 0.906 48 | 0.900 93 | 0.919 44 | 0.912 04 | 0.880 56 | 0.912 96 |
| Tic-tac-toe | 0.849 48 | 0.828 39 | 0.844 01 | 0.832 81 | 0.832 29 | 0.821 09 | 0.831 51 |
| vehicle | 0.775 59 | 0.747 35 | 0.746 47 | 0.759 12 | 0.757 35 | 0.729 71 | 0.770 59 |
| Zoo | 0.995 24 | 0.976 19 | 0.976 19 | 0.983 33 | 0.980 95 | 0.976 19 | 0.985 71 |

表 4 HS-SSA 与对比算法在运行 20 次的平均维度缩减率
Table 4 Average dimension reduction rate of HS-SSA and comparison algorithm in 20 runs

| 数据集 | HS-SSA | SSA | SSARM-SCA | DSSA | PSO | HHO | GWO | % |
|--------------|--------------|-------|-----------|-------|-------|--------------|--------------|---|
| BreastEW | 89.17 | 73.17 | 65.00 | 87.50 | 84.17 | 83.00 | 90.83 | |
| CongressEW | 72.19 | 64.06 | 63.13 | 70.94 | 70.94 | 77.19 | 74.06 | |
| Exactly | 53.85 | 44.23 | 44.62 | 53.08 | 50.38 | 44.62 | 53.85 | |
| HeartEW | 68.08 | 60.38 | 56.92 | 63.85 | 64.62 | 66.54 | 66.54 | |
| Horse | 85.93 | 62.96 | 54.63 | 69.63 | 66.30 | 81.48 | 82.59 | |
| ionosphere | 88.53 | 65.00 | 63.82 | 76.32 | 75.44 | 82.06 | 85.15 | |
| KrVsKpEW | 51.11 | 43.47 | 20.14 | 46.25 | 46.11 | 33.19 | 62.50 | |
| Lymphography | 69.44 | 60.28 | 57.22 | 66.11 | 65.28 | 59.44 | 69.17 | |
| PenglungEW | 95.71 | 58.43 | 61.09 | 82.62 | 70.14 | 92.66 | 96.97 | |
| Sonar | 82.67 | 57.58 | 56.17 | 74.58 | 69.67 | 73.50 | 84.75 | |

续表 4

| 数据集 | HS-SSA | SSA | SSARM-SCA | DSSA | PSO | HHO | GWO |
|-------------|--------------|-------|-----------|-------|-------|-------|--------------|
| SpectEW | 72.05 | 57.73 | 45.00 | 60.68 | 65.23 | 67.27 | 71.59 |
| Tic-tac-toe | 8.33 | 14.44 | 13.33 | 23.33 | 13.33 | 21.67 | 31.67 |
| vehicle | 61.67 | 48.33 | 40.56 | 53.06 | 50.83 | 51.94 | 56.94 |
| Zoo | 68.44 | 60.31 | 61.88 | 68.13 | 64.06 | 61.88 | 69.69 |

从表 3 中可以看出在准确率上, HS-SSA 在所有数据集的平均分类精度优于所有对比算法。与 SSA 和 SSA 变体 SSARM-SCA 相比时更加卓越, 在数据集 Exactly、Horse、ionosphere、PenglungEW、Sonar 上, HS-SSA 的准确率都提高了至少 4.5%, 特别是在 PenglungEW 分别高达 9% 和 8.67%。对于 DSSA、HS-SSA 也有稳步提高, 特别是在数据集 PenglungEW 上提高了 6%。这说明算法 HS-SSA 在原始 SSA 上取得了巨大的突破的同时, 还在近几年基于 SSA 改进的算法中具有较大的竞争力。与其他对比算法相比, HS-SSA 也有较好的表现。与 HHO 对比, 除了数据集 KrVsKpEW 以外 HS-SSA 都有比较大的提升, 特别在数据集 Exactly 上 HS-SSA 比 HHO 的准确率提高了接近 12%, 而从表 4 可以看出在数据集 KrVsKpEW 上 HS-SSA 比 HHO 的维度缩减率多了 17.92%。在数据集 vehicle 上 HS-SSA 的准确率比 PSO 和 GWO 提升相对不多, 但是在维度缩减方面表现较好, 分别多出 10.84% 和 4.73%。对于 HS-SSA 在维度缩减方面的表现, 显然不如它在准确率上的优异, 但是也在一半的数据集中表现最好, 而且在剩下的一半数据集中维度缩减率也接近最好的。特别是在高维数据集 PenglungEW、HS-SSA 的维度缩减率高达 95.71%。这证明了在不同维度的数

据集下算法的降维都具有有效性。在与 SSA、DSSA、SSARM-SCA 和 PSO 对比, 除了数据集 Tic-tac-toe 以外, HS-SSA 在维度缩减的方面都表现得更佳, 可见它的降维能力。

HS-SSA 的优势在于利用排序表拥有一个质量更好的初始化种群, 并且利用 DSA 在前期淘汰较差的解决方案, 在后期避免局部最优, 并且利用瞬态搜索更新公式改进了解的多样性。通过表 3 和表 4 可以看出在大部分数据集上 HS-SSA 展现出来的优越性, 同时这些结果也强调了它的稳定性, 通过选择信息量大的特征来平衡开发和勘探。为评估实验结果的显著性, 采用了 Wilcoxon 秩和检验, 它是通过推断总体的分布是否相同, 进而判断两组样本之间的差异是否显著。该测试可以评估 HS-SSA 相对于对比算法的显著性, 在这个测试中, 使用的显著性水平是 5%。

表 5 给出了以 20 次运行准确率为基础的 HS-SSA 与对比算法的秩和检验的 P 值, 当 P 小于 5% 时, 说明 HS-SSA 相对于竞争算法有明显改进, 标粗体, 当大于 5% 时则没有。可以看出在大多数数据集上 HS-SSA 在分类准确率上比其他对比算法有显著提高。特别是与 SSA 和 HHO 对比, 所有数据集都有显著提高。

表 5 以 20 次运行准确率为基础的 HS-SSA 与对比算法的单边 Wilcoxon 秩和检验的 P 值

Table 5 Test P -value of unilateral Wilcoxon rank sum test between HS-SSA and comparison algorithm based on the accuracy of 20 runs

| 数据集 | SSA | SSARM-SCA | DSSA | PSO | HHO | GWO |
|--------------|---|---|---|---|---|---|
| BreastEW | 2.42×10^{-2} | 1.58×10^{-2} | 4.05×10^{-2} | 6.43×10^{-4} | 1.90×10^{-3} | 6.41×10^{-3} |
| CongressEW | 4.18×10^{-3} | 2.27×10^{-2} | 4.17×10^{-2} | 1.99×10^{-2} | 4.39×10^{-4} | 3.82×10^{-2} |
| Exactly | 1.46×10^{-3} | 7.62×10^{-5} | 3.93×10^{-1} | 5.23×10^{-2} | 2.19×10^{-4} | 3.93×10^{-1} |
| HeartEW | 1.86×10^{-2} | 1.04×10^{-2} | 3.52×10^{-1} | 3.39×10^{-2} | 7.18×10^{-3} | 2.24×10^{-1} |
| Horse | 6.65×10^{-8} | 3.01×10^{-7} | 3.50×10^{-2} | 5.24×10^{-7} | 4.59×10^{-8} | 6.66×10^{-3} |
| ionosphere | 1.87×10^{-6} | 1.59×10^{-7} | 1.37×10^{-2} | 5.85×10^{-4} | 2.63×10^{-5} | 1.24×10^{-2} |
| KrVsKpEW | 4.30×10^{-6} | 3.46×10^{-7} | 3.52×10^{-1} | 1.52×10^{-2} | 9.01×10^{-7} | 1.69×10^{-2} |
| Lymphography | 4.89×10^{-3} | 4.70×10^{-3} | 4.42×10^{-2} | 4.17×10^{-2} | 5.80×10^{-5} | 2.34×10^{-2} |
| PenglungEW | 1.55×10^{-5} | 1.17×10^{-4} | 5.80×10^{-5} | 2.56×10^{-3} | 1.28×10^{-3} | 3.88×10^{-1} |
| Sonar | 1.44×10^{-6} | 2.75×10^{-6} | 9.48×10^{-2} | 3.70×10^{-3} | 3.12×10^{-5} | 4.95×10^{-2} |
| SpectEW | 4.17×10^{-2} | 4.42×10^{-2} | 4.46×10^{-1} | 1.07×10^{-1} | 2.81×10^{-4} | 2.54×10^{-1} |

续表 5

| 数据集 | SSA | SSARM-SCA | DSSA | PSO | HHO | GWO |
|-------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| Tic-tac-toe | 3.28×10^{-3} | 1.93×10^{-1} | 2.90×10^{-3} | 9.30×10^{-3} | 5.07×10^{-4} | 2.16×10^{-3} |
| vehicle | 6.84×10^{-5} | 6.47×10^{-5} | 2.57×10^{-2} | 1.11×10^{-2} | 5.24×10^{-7} | 2.05×10^{-1} |
| Zoo | 2.74×10^{-2} | 1.52×10^{-2} | 8.81×10^{-2} | 5.23×10^{-2} | 1.52×10^{-2} | 2.01×10^{-1} |

4 结束语

本文针对樽海鞘群算法在特征选择上存在容易陷入局部最优和种群多样性较差等缺点,提出了一种具有混合策略的樽海鞘群特征选择算法(HS-SSA)。对于 SSA 有 3 点改进:提出了一种基于互信息的排序表并基于此提出了新的初始化策略;提出了一个有条件调用的动态搜索算法;提出了一种让 SSA 和瞬态搜索(TSO)相结合的更新策略。通过在 14 个 UCI 数据集上和 6 种不同的对比算法进行实验,得出在准确率上优于全部的其他算法,在维度缩减上一半的数据集都是最好的。并且从显著性检验来看,大部分数据集上该算法的性能对于其他算法有显著性的增强。下一步的研究工作重点主要集中在两个方面:进一步增强算法的降维能力;尝试 SSA 与其他启发式算法相结合。

参考文献:

- [1] WANG Changzhong, HU Qinghua, WANG Xizhao, et al. Feature selection based on neighborhood discrimination index[J]. *IEEE transactions on neural networks and learning systems*, 2018, 29(7): 2986–2999.
- [2] LI Xiaoping, WANG Yadi, RUIZ R. A survey on sparse learning models for feature selection[J]. *IEEE transactions on cybernetics*, 2022, 52(3): 1642–1660.
- [3] JOHN G H, KOHAVI R, PFLEGER K. Irrelevant features and the subset selection problem[M]//Machine learning proceedings 1994. Amsterdam: Elsevier, 1994: 121–129.
- [4] 董红斌, 滕旭阳, 杨雪. 一种基于关联信息熵度量的特征选择方法[J]. *计算机研究与发展*, 2016, 53(8): 1684–1695.
DONG Hongbin, TENG Xuyang, YANG Xue. Feature selection based on the measurement of correlation information entropy[J]. *Journal of computer research and development*, 2016, 53(8): 1684–1695.
- [5] SONG Xianfang, ZHANG Yong, GONG Dunwei, et al. Feature selection using bare-bones particle swarm optimization with mutual information[J]. *Pattern recognition*, 2021, 112: 107804.
- [6] LI Anda, XUE Bing, ZHANG Mengjie. Improved binary particle swarm optimization for feature selection with new initialization and search space reduction strategies[J]. *Applied soft computing*, 2021, 106: 107302.
- [7] 杨维, 李歧强. 粒子群优化算法综述[J]. *中国工程科学*, 2004, 6(5): 87–94.
YANG Wei, LI Qiqiang. Survey on particle swarm optimization algorithm[J]. *Engineering science*, 2004, 6(5): 87–94.
- [8] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp swarm algorithm[J]. *Advances in engineering software*, 2017, 114(C): 163–191.
- [9] 刘骏鹏. 哈里斯鹰算法的改进及应用研究[D]. 杭州: 浙江大学, 2021.
LIU Junpeng. Research on improvement and application of Harris eagle algorithm[D]. Hangzhou: Zhejiang University, 2021.
- [10] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in engineering software*, 2014, 69: 46–61.
- [11] HOLLAND J H. Genetic algorithms[J]. *Scientific American*, 1992, 267(1): 66–72.
- [12] KILIC F, KAYA Y, YILDIRIM S. A novel multi population based particle swarm optimization for feature selection[J]. *Knowledge-based systems*, 2021, 219: 106894.
- [13] TU Qiang, CHEN Xuechen, LIU Xingcheng. Multi-strategy ensemble grey wolf optimizer and its application to feature selection[J]. *Applied soft computing*, 2019, 76(C): 16–30.
- [14] MAFARJA M, ALJARAHA I, HEIDARI A A, et al. Binary dragonfly optimization for feature selection using time-varying transfer functions[J]. *Knowledge-based systems*, 2018, 161: 185–204.
- [15] TUBISHAT M, JA'AFAR S, ALSWAITTI M, et al. Dynamic salp swarm algorithm for feature selection[J]. *Expert systems with applications*, 2021, 164: 113873.
- [16] ZAWBAA H M, EMARY E, GROSAN C, et al. Large-dimensionality small-instance set feature selection: a hybrid bio-inspired heuristic approach[J]. *Swarm and evolutionary computation*, 2018, 42: 29–42.
- [17] ZIVKOVIC M, STOJANOVIC C, CHHABRA A, et al. Novel improved salp swarm algorithm: an application for feature selection[J]. *Sensors*, 2022, 22(5): 1711.
- [18] MAFARJA M M, MIRJALILI S. Hybrid whale optimization algorithm with simulated annealing for feature selection

- tion[J]. *Neurocomputing*, 2017, 260(C): 302–312.
- [19] DHAL P, AZAD C. A multi-objective feature selection method using Newton's law based PSO with GWO[J]. *Applied soft computing*, 2021, 107: 107394.
- [20] QAIS M H, HASANIEN H M, ALGHUWAINEM S. Transient search optimization: a new meta-heuristic optimization algorithm[J]. *Applied intelligence*, 2020, 50(11): 3926–3941.
- [21] SHANNON C E. A mathematical theory of communication[J]. *The bell system technical journal*, 1948, 27(3): 379–423.
- [22] 滕旭阳, 董红斌, 孙静. 面向特征选择问题的协同演化方法[J]. *智能系统学报*, 2017, 12(1): 24–31.
- TENG Xuyang, DONG Hongbin, SUN Jing. Co-evolutionary algorithm for feature selection[J]. *CAAI transactions on intelligent systems*, 2017, 12(1): 24–31.
- [23] LU Huijuan, CHEN Junying, YAN Ke, et al. A hybrid feature selection algorithm for gene expression data classification[J]. *Neurocomputing*, 2017, 256(C): 56–62.
- [24] MAFARJA M, ALJARAHI I, HEIDARI A A, et al. Evolutionary population dynamics and grasshopper optimization approaches for feature selection problems[J]. *Knowledge-based systems*, 2018, 145(C): 25–45.
- [25] DAVIE A, PATRICK M, CHRISTOPHER M, et al. UCI machine learning repository[EB/OL]. [2022–09–19]. <https://archive.ics.uci.edu/>.

作者简介:



余紫康, 硕士研究生, 主要研究方向是群智能算法、数据挖掘。E-mail: y402153832@163.com。



董红斌, 教授, 博士生导师, 中国计算机学会高级会员, 主要研究方向为多智能体系统、机器学习。主持和完成国家自然科学基金、工信部基础研究项目、黑龙江省自然科学基金项目, 荣获黑龙江省高校科学技术奖和黑龙江省优秀高等教育科学成果奖。

主编教材 2 部, 发表学术论文 90 余篇。E-mail: donghongbin@hrbeu.edu.cn。

2024 全球人工智能技术博览会 2024 Global Artificial Intelligence Technology Expo

由中国人工智能学会主办, CAAI 智能光学成像专委会执行的 2024 全球人工智能技术博览会将于 2024 年 6 月 22—25 日在杭州市余杭区未来科技城国际会议中心举办。会展旨在整合行业资源, 促进人工智能产业蓬勃发展, 推动高新技术成果转化, 促进人工智能企业间的科技交流与合作。

作为 2024 全球人工智能技术大会“一会一展一赛”的重要组成部分, 本届主题展览展展面积共计 4 094.2 m², 聚焦 AR/VR、人工智能大模型、智能芯片/高校、自动驾驶、智能交互、机器人等多个场景应用和功能领域, 展出项目涵盖政府科技产业、智能制造、电子信息、新材料、机器人、AR/VR、人工智能、AI 热点、智慧教育、智慧医疗、信息技术、光电芯片等产业领域, 将汇集 79 家行业领军企业和科研平台的展品、核心部件和解决方案, 为我国“人工智能+”行动添能蓄力。

联系电话

綦老师 15650578043(微信同号)

郝老师 15201113688(微信同号)