

基于强化学习的多目标特征选择算法研究

雷明月, 金利英

(湖北文理学院 机械工程学院, 湖北 襄阳 441053)

摘要: 特征选择作为降维方法, 能够减少高维数据计算复杂度; 然而传统方法多集中于单目标优化, 难以同时平衡分类准确率和特征数量, 特别是在高维数据中存在收敛性不足的问题; 针对该问题, 提出了一种基于强化学习和双种群策略的多目标特征选择算法 (QSNSGA-II), 该算法通过强化学习动态调整关键参数, 在保持种群多样性的同时加快收敛速度; 采用双种群协同进化策略, 增强了全局搜索能力, 提高了算法性能; 通过在多个 UCI 数据集上进行实验, 尤其在高维数据集 Musk1 和 Sonar 数据集上准确率达到 91.158 5% 和 84.636%, 展示了该算法优异的特征选择效果及较好的收敛性和多样性。

关键词: 特征选择; 多目标算法; 强化学习; 双种群协同; UCI 数据集

Research on Multi-objective Feature Selection Algorithm Based on Reinforcement Learning

LEI Mingyue, JIN Liying

(School of Mechanical Engineering, Hubei University of Arts and Science, Xiangyang 441053, China)

Abstract: As a dimension reduction method, feature selection can reduce the computational complexity of high-dimensional data. However, traditional methods mostly focus on single-objective optimization, which is difficult to simultaneously balance the classification accuracy and the number of features, especially in high-dimensional data with insufficient convergence. To address this problem, a multi-objective feature selection algorithm (QSNSGA-II) based on reinforcement learning and dual-population strategy is proposed, which dynamically adjusts key parameters through reinforcement learning to accelerate convergence speed while maintaining the diversity of population. A two-population co-evolutionary strategy is used to enhance global search capability and improve the performance of the algorithm. Through experiments on several UCI datasets, especially on the high-dimensional datasets Musk1 and Sonar datasets, the accuracy of the algorithm reaches up to 91.158 5% and 84.636%, respectively, which shows that the algorithm exhibits an excellent feature selection as well as good convergence and diversity.

Keywords: feature selection; multi-objective algorithm; reinforcement learning; collaborative dual populations; UCI datasets

0 引言

特征选择 (FS, feature selection) 是机器学习和数据挖掘领域的一项核心技术, 随着科技的不断发展, 数据维度急剧增加, 高维数据中的冗余特征和噪声不仅增加了计算负担, 还可能对分类性能造成影响, 特征选择作为降维的一种有效方法, 能够在保留关键信息的同时, 减少计算复杂度并提升任务效率^[1]。

近年来, 进化算法因其优秀的全局搜索能力, 在特征选择任务中得到广泛应用。如遗传算法 (GA, ge-

netic algorithm)、粒子群优化算法 (PSO, particle swarm optimization) 和多目标进化算法 (MOEA, multi-objective evolutionary algorithm) 等方法在特征子集优化方面表现出色^[2]。然而, 现有的进化算法大多集中在单目标优化上, 通常关注最小化分类错误率, 而忽视了特征子集的冗余性和计算复杂度问题^[3]。传统单目标特征选择方法在面对高维数据时, 难以在保持分类性能的同时, 显著减少特征数量, 从而限制了其实用性。

越来越多的研究者开始将特征选择任务转化为多目标优化问题, 涉及多个目标的平衡, 如最大准确率和最

收稿日期: 2025-03-13; 修回日期: 2025-04-29。

作者简介: 雷明月 (2001-), 女, 硕士研究生。

引用格式: 雷明月, 金利英. 基于强化学习的多目标特征选择算法研究[J]. 计算机测量与控制, 2026, 34(3): 201-207, 215.

小化特征数量^[4-5]。在多目标特征选择中,不同的特征子集可能会产生相似或相同的分类结果。因此,寻求分类精度与特征子集大小之间的平衡变得至关重要。目前,多目标算法被广泛应用在特征选择上,经典的多目标特征选择算法包括非支配排序遗传算法(NSGA-II, non-dominated sorting genetic algorithm II)^[6]、粒子群优化算法(MOPSO, multi-objective particle swarm optimization)^[7]、强帕累托进化算法 2(SPEA2, strength pareto evolutionary algorithm 2)^[8]、多目标进化算法(MOEA/D, multi-objective evolutionary algorithm based on decomposition)^[9]等。但是传统的 NSGA-II 算法容易在高维空间中陷入局部最优;MOPSO 算法虽然具有较强的收敛性能,但由于粒子多样性控制不足,常常过早收敛,难以覆盖解空间;SPEA2 算法通过精英策略和 pareto 排序维持多样性,在处理复杂非线性约束时,难以避免局部最优解,限制其性能。MOEA/D 算法强调分解和子任务并行,但其领域搜索策略对种群多样性的维持存在一定限制。

近年来,有学者引入了新型的改进策略,例如,文献[10]提出一种多目标粒子群算法(PSO)的多标签特征算法,引入自适应变异算子和局部学习策略,提升了搜索能力,但是在处理大规模数据时依赖较高的计算开销。文献[11]提出了一种集成自适应算子选择机制的多目标二元遗传算法(MOBGA-AOS),利用交叉算子有效搜索,但是算子相关参数不能自适应调整。文献[12]结合了基于帕累托优势的双存档机制,通过多目标人工蚁群算法的收敛引导和多样性引导搜索增强了多样性,然而两种档案的维护需要大量的计算时间。这些方法虽有一定进展,但在收敛性,种群多样性之间仍难以取得理想平衡。

因此本文提出了一种基于强化学习的双种群迁徙算法—QSNSGA-II(Q-learning-based Double Population NSGA-II),通过引入双种群迁徙思想^[13]和强化学习的思想对 NSGA-II 算法进行改进,种群策略的引入增强了种群的多样性和算法的全局搜索能力,将强化学习(Q-learning)引入到双种群 NSGA-II 框架中,创新性地实现了对迁徙参数的动态调整。本文选择双种群策略而非多种群策略,主要基于以下两点原因:首先,双种群能够在保持种群多样性的同时降低计算复杂度,其次,双种群通过精英种群和随机种群的协同优化,能够有效平衡全局搜索和局部搜索能力,并有效防止陷入局部最优解。相关研究表明,双种群策略在高维数据优化问题中具有显著优势^[14]。

本文根据 UCI 数据库中的数据集来对这个算法进行验证,同时和单种群 NSGA-II 算法,按照迁徙经验设置的双种群 SNSGA-II 算法,以及 MOPSO 算法,

SPEA2 算法和 MOEA/D 算法来进行对比,通过实验验证,本文提出的 QSNSGA-II 算法,能够在高维数据集上更快的收敛,并有效保持较高的分类准确率和较低的特征选择数量。通过引入强化学习和双种群策略,QSNSGA-II 解决了现有算法在高维数据中的局限性,并在特征选择任务中取得了更好的性能。

1 基于强化学习的多目标特征选择框架

本章介绍了一种基于强化学习的多目标特征选择算法,该算法结合了双种群策略和强化学习技术,通过动态调整优化过程中的关键参数,在特征选择任务中同时优化分类错误率和特征选择比例。本文在优化过程中,将分类错误率(ER, error rate)和特征选择比例(FSR, feature selection ratio)作为目标函数,通过强化学习与多目标优化方法对特征子集进行优化,寻找满足分类性能和特征压缩率平衡的 Pareto 最优解集。

1.1 目标函数设计

在本文中,针对特征选择问题,我们设计了两个优化目标:分类错误率(ER, error rate)和特征选择比例(FSR, feature selection ratio)。分类错误率指的是分类错误率衡量所选特征子集在分类任务上的预测性能,最小化 ER,即可提升分类任务的准确性。错误率 f_1 的计算公式为:

$$f_1 = 1 - \frac{\sum_{i=1}^n 1(y_i = \hat{y}_i)}{n} \quad (1)$$

$1(y_i = \hat{y}_i)$ 是指示函数,若 $(y_i = \hat{y}_i)$ 为真,则值为 1,否则为 0。 n 为测试集样本的数量。

特征选择比例(FSR, feature selection ratio)指的是已选择特征的数量与原始特征总数的比值。最小化 FSR,在保证分类性能的前提下减少数据维度,提升模型简洁性。特征选择比例 f_2 用于衡量选中特征的比例。假设每个个体(解)包含一个二进制向量 selected_features,其中每个元素表示是否选择相应的特征其公式为:

$$f_2 = \frac{\sum_{j=1}^m 1(\text{selected_features}_j = 1)}{m} \quad (2)$$

其中: m 为总特征数(即特征空间的维度), $1(\text{selected_features}_j = 1)$ 是指示函数,若第 j 个特征被选择,则为 1,否则为 0。

多目标优化问题目的是寻找最优特征子集 S ,使以下多目标问题达到 Pareto 最优,通过优化这两个目标 $\min_{S \subseteq F} \{ER(S), FSR(S)\}$,平衡特征分类性能和特征压缩率,最终生成一个 Pareto 最优解集。

1.2 算法概述

1.2.1 强化学习模型设计

迁徙操作的三项关键参数 p 、 q 、 m 的合理设定直

接影响算法性能。其中, p 表示迁徙代数, 即每隔 P 代进行一次种群迁徙, q 表示迁徙间隔, 即每经过 q 代进行一次种群交互, m 表示迁徙个体数, 即每次迁徙操作中替换的个体数量。这些参数的合理设置能够有效的平衡算法的收敛性和多样性。为此, 本文采用了一种强化学习框架, 通过智能体 (Agent) 与环境之间动态且持续的交互过程, 运用强化学习算法对迁徙参数 p 、 q 、 m 进行自适应的动态调整与优化。智能体根据种群的当前状态, 包括收敛性和多样性指标, 选择最优动作来更新迁徙参数, 从而在进化过程中提升算法性能。在本研究中, 特征选择过程被建模为一个强化学习问题。具体来说, 我们设计了一个强化学习模型, 通过优化特征选择策略来提高分类性能。该模型的设计状态包括状态空间, 动作空间和奖励函数的定义。其设计过程如下。

1) 状态空间:

状态空间反映了当前种群的整体状态, 包括种群的收敛性 (SPAD)^[15] 和多样性 (VAR)^[16]。每一代迭代中, 算法通过评估这些指标来获取当前种群的状态, 并将其映射为有限的离散状态集合。收敛性 (SPAD) 通过种群个体间的标准差来衡量, 多样性 (VAR) 通过种群内个体间的方差来衡量。为了更精确地表示状态, 本文参考了文献 [17] 中的状态空间设计, 定义状态 S_t 如下:

$$S_t = \left(\frac{SPAD_1^t}{SPAD_1^0}, \frac{SPAD_2^t}{SPAD_2^0}, \frac{SPAD_1^t}{SPAD_1^0}, \frac{SPAD_2^t}{SPAD_2^0} \right) \quad (3)$$

其中: $SPAD_1^0$ 、 $SPAD_2^0$ 、 VAR_1^0 、 VAR_2^0 分别表示初始种群 1、初始种群 2 的收敛性和多样性值; $SPAD_1^t$ 、 $SPAD_2^t$ 、 VAR_1^t 、 VAR_2^t 表示在执行操作后的当前种群 1、种群 2 的收敛性和多样性值。根据这些比值大小, 状态可以分为三类: 比值减少, 比值不变, 比值增加。根据种群 1 和种群 2 的 SPAD 和 VAR 比值组合, 两个种群共有 4 个比值, 总共 $3 \times 3 \times 3 \times 3 = 81$ 种组合方式。

2) 动作空间:

动作空间的动作设计主要针对迁徙参数的调整, 如迁徙代数 p , 迁徙间隔 q , 迁徙个体数 m 这三个迁徙参数大小的更改, 每个参数有 3 种可能的调整 (增加, 减少, 不变), 动作空间共有 $3^3 = 27$ 种动作。每个动作地调整量由事先设定地调整比例决定, 例如: $\Delta p = \pm 1$, $\Delta q = \pm 1$, $\Delta m = \pm 1$, 其中 Δp 、 Δq 、 Δm 的选择是根据强化学习的状态反馈机制进行动态调整的。对于 p 参数, 因其代表迁徙参数, 无法减少或保持不变, 故仅能增加。在本文设计中, 迁徙参数的动作空间设计是基于以下考虑: 迁徙代数 p 只能增加, 而迁徙间隔 q 和迁

徙个体数 m 可以根据当前的种群情况进行微调。通过这种方式, 智能体能够灵活调整这些参数, 以达到提高种群性能的目标。

步长是强化学习中的一个重要超参数, 决定了每次模型更新是迁徙参数的调整幅度。在强化学习的过程中, 选择合适的步长对算法的收敛速度和稳定性至关重要。本文选择的步长为 ± 1 。小步长的调整使得算法能够逐步优化参数, 如果步长过长, 可能会导致算法在收敛过程中发生冲突, 从而影响解的质量。

3) 回报函数:

回报函数衡量当前种群的进化质量, 主要基于收敛性 (SPAD) 和多样性 (VAR) 的变化。通过比较当前值与初始值, 奖励算法提升收敛性或多样性。当收敛性或多样性改善 (比值下降) 时, 回报为正, 激励当前策略。当收敛性或多样性恶化 (比值上升) 时, 回报为负, 惩罚当前策略。保持不变则无奖励或惩罚。回报函数 R 的计算公式如下:

$$R = R_1 + R_2 + R_3 + R_4 \quad (4)$$

每一项的奖励 R_x 基于当前比值:

$$R_x = \begin{cases} 0, & \text{if } \frac{SPAD_1^t}{SPAD_1^0} = 1 \\ 0.5, & \text{if } \frac{SPAD_1^t}{SPAD_1^0} < 1 \\ -1, & \text{if } \frac{SPAD_1^t}{SPAD_1^0} > 1 \end{cases} \quad (5)$$

1.2.2 多目标 NSGA-II 优化策略

为了在特征选择过程中同时优化多个目标 (如分类性能和特征子集的大小), 我们将强化学习与多目标 NSGA-II 算法结合。本文采用双种群策略, 具体来说, 我们使用了两个不同的初始种群: 分别为精英种群 (population1) 和随机种群 (population2)。精英种群通过非支配排序选择最优个体, 保持解的收敛性, 随机种群通过随机选择个体, 增强解的多样性。两个种群通过迁徙操作进行信息交互, 即每经过 q 代, 从精英种群中选择 m 个最优个体 (elite1) 替换随机种群中的 m 个随机个体 (rand2), 从而促进种群间的协同进化。

迁徙操作的规则基于文献 [18] 中的方法, 其中随机生成的两个初始种群通过迁徙比例控制交替交换, 即在前 50 代中, 每隔一定代数, 精英种群的前 m 个精英个体与随机种群的 m 个个体进行交换。交换后, 形成新的精英种群和随机种群, 接着各自独立进行 NSGA-II 算法的进化。在每次交换后, 所选择的要进行交换的小群体占总群体个数的百分比定义为迁徙比例。双种群策略既结合了精英种群的优越性和随机种群的多样性, 通过迁徙操作的协同进化, 使得整个进化进程既保持了高质量解的收敛性, 又保持了种群的多样性。

1) 非支配排序:

NSGA-II 通过对个体进行非支配排序来评估每个解的优劣。非支配的核心思想是将当前解与其他解进行比较, 如果一个解在所有目标上都不劣于另一个解, 则前者被认为是优越的。我们在特征选择问题中利用非支配排序, 将每个特征子集的分类性能和特征数量作为目标, 进行多目标优化。

2) 拥挤度比较:

为了保持解的多样性, NSGA-II 还使用了拥挤度比较操作, 避免选择过于相似的解。这对于特征选择尤为重要, 因为过多的冗余特征会导致解空间的拥挤。通过拥挤度比较, 可以保留那些在多个目标上表现良好的解, 同时避免过度优化某一目标而忽略其他目标。

3) 强化学习与 NSGA-II 结合:

在每代中, 强化学习模型根据当前解的奖励信号调整选择特征的策略。通过在 NSGA-II 的多目标框架下进行优化, 强化学习模型不仅通过奖励引导特征选择过程, 还能通过与 NSGA-II 算法的交互, 推动探索不同的特征子集, 从而在分类性能和特征数量之间找到最优的平衡点。

1.3 算法流程及伪代码

基于强化学习的多目标特征选择算法 (QSNSGA-II) 具体步骤如下所示。

- 1) 初始化: 初始化种群, Q 表, 迁徙参数 p , q , m 以及强化学习参数 (学习率 α , 折扣率 γ , 探索率 ϵ 等);
- 2) 训练过程: 使用 Q-learning 代理探索和调整迁徙参数, 通过 NSGA-II 进化算法优化种群, 评估种群性能 (分类错误率 ER 和特征选择比例 FSR);
- 3) 迁徙操作: 基于种群的最优个体和随机个体进行交互, 增强解集多样性;
- 4) 更新 Q 表: 根据当前状态, 动作和奖励, 更新 Q 表, 优化动作选择策略;
- 5) 输出: 经过 G 代迭代后, 返回 Pareto 最优解集及其性能指标。

以下是基于强化学习的多目标特征选择算法的伪代码:

输入: 初始种群参数

输出: Pareto 最优特征子集

- 1) 初始化: 初始化双种群 population1, population2, 设置 Q 学习参数和迁徙参数
- 2) for $g = 1$ to G :
- 3) 计算当前种群状态 state
- 4) ϵ -greedy 策略选择动作 action
- 5) 动态调整迁徙参数 (p, q, m)

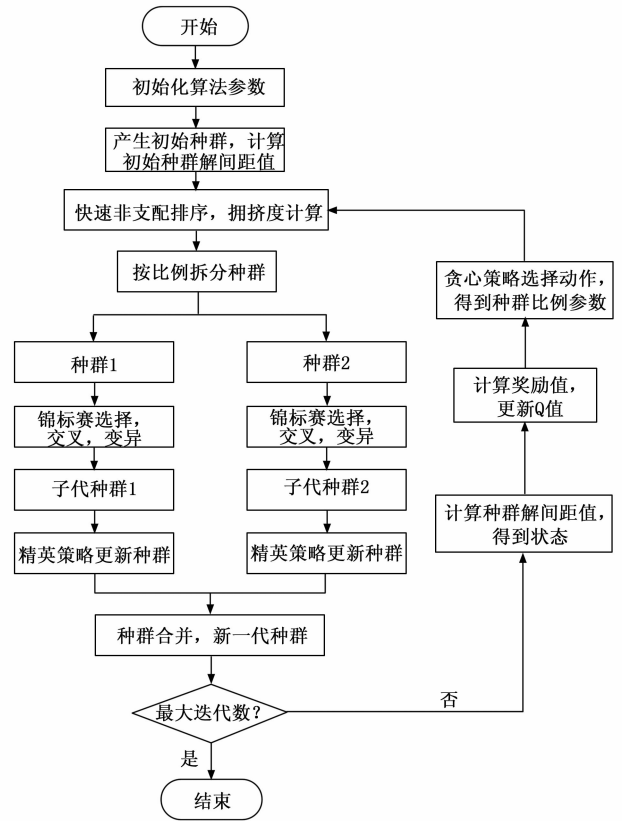


图 1 基于强化学习的多目标特征选择算法流程图

6) NSGA-II 进化双种群

7) If $g \% q = 0$ then 执行种群迁徙

8) 计算奖励 R 并更新 Q 值

9) 记录当前代的适应度:

fitness_history[g] ← (平均错误率, 平均特征比例)

10) end for

11) 输出 Pareto 最优解集及其性能指标 (Acc, NMI)

2 实验结果与分析

本文所有实验均在搭载 Intel i5-11320H 处理器、主频 3.2 GHz 的设备上进行, 操作系统为 64 位 window10。实验的编程环境与平台采用 MATLAB 软件, 所有算法都在此平台上运行, 确保实验结果不受偶然因素的干扰。

2.1 数据集

为了验证本文提出的算法在特征选择方面的有效性, 选取了 UCI^[19] 数据库中的 7 个数据集进行对比实验, 数据集包括 3 个小维数据集、2 个中维数据集和 2 个高维数据集。在特征选择问题中, 如果数据集中的特征数量分别处于 $[0, 19]$, $[20, 49]$, $[50, \infty]$ 的范围内, 则对应为小维、中维和高维数据集^[20], 本文所使用的数据集的相关信息, 包括样本数, 特征维数和类数如表 1 所示。

表1 数据描述

数据集	样本数	维数	类数
Pima	768	8	2
Glass	214	9	6
Sonar	208	60	2
Wine	178	13	3
Musk1	166	606	2
WBDC	569	30	2
Robotnavigation	5 456	25	4

2.2 评价指标

本文采用分类准确率 (Acc) 和标准互信息 (NMI) 作为评价本文算法及对比算法性能的指标。

分类准确率 (Acc) 是评估分类任务效果的关键指标之一, 表示模型正确预测的样本在总样本中所占的比例。分类准确率的定义如式所示:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

其中: 真正例 (TP) 表示被正确归类为正类的样本数量; 真负例 (TN) 为真负例表示被正确归类为负类的样本数量; 假正例 (FP) 表示错误地被归类为正类的样本数量; 而假负例 (FN) 则表示错误地分类为负类的样本数量。标准互信息 (NMI) 是用来评估两个变量之间的相似性的指标, 尤其适用于聚类和分类结果之间的比较。在特征选择问题中, NMI 可以用来衡量所选特征子集与目标标签之间的依赖关系。NMI 的计算是基于互信息 (MI, mutual information), 并通过归一化处理来减小数据集大小对指标的影响, 使得 NMI 值在 $[0, 1]$ 范围内, 其中 1 表示完全依赖, 0 表示完全独立。NMI 值越接近 1, 说明两个变量之间的相似性越高, 越接近 0, 则相似性越低。标准互信息的定义如式所示:

$$NMI(X, Y) = \frac{MI(X, Y)}{\sqrt{H(X) \cdot H(Y)}} \quad (7)$$

其中: $H(X)$ 和 $H(Y)$ 分别是变量 X 和 Y 的熵, 表示每个变量的不确定性:

$$H(X) = - \sum_{x \in X} p(x) \log p(x) \quad (8)$$

$$H(Y) = - \sum_{y \in Y} p(y) \log p(y) \quad (9)$$

2.3 对比算法与参数设置

为了验证本文算法的有效性, 我们将本文算法和其它的多目标算法进行对比, 将 QSNSGA-II 与 SNSGA-II^[13]、NSGA-II^[21]、SPEA2^[22]、MOPSO^[23]、MOEA/D^[24], 进行对比分析, 在相同实验环境基础上, 每个数据集按 80% 的比例划分为训练集, 20% 的比例划分为测试集。实验中, 使用 KNN 分类器来预测分类精度,

且 K 值固定为 5。对于各个对比算法, 所有算法的迭代次数都设置为 100 次, 种群规模同样设定为 100, 确保其他参数一致。其余各种对比算法也保持相同的参数, 每个对比算法都使用默认参数, $P_c = 0.8$, $P_m = 0.2$, 对于 MOPSO 算法, c_1 和 c_2 设定为 1.5 和 1.5, $\omega = 0.4$, 对于 MOEA/D 算法, $T = 10$, 为了减少实验随机性带来的影响, 我们对每种算法在每个数据集上都进行了 20 次独立的运行, 并将这些运行结果的平均值作为最终的评估依据。

2.4 实验结果

表 2 和表 3 列出了所有算法在 20 次独立运行测试的 Acc 指标和 NMI 指标结果。实验结果显示, 本文提出的 QSNSGA-II 算法在 Acc 和 NMI 两个指标上均优于传统方法, 例如, 在 Robotnavigation 数据集上, QSNSGA-II 算法得到的分类准确率达到 98.423%, NMI 值在 Wine 数据集上可以达到 85.1315%, 说明本算法不仅提升分类性能, 还提高了特征选择的准确性和稳定性。

特别是在在高维数据 Sonar 数据集和 Musk1 数据集上, QSNSGA-II 算法表现出色, Acc 值分别为 84.636% 和 91.1585%, NMI 值达到了 53.12% 和 63.335%, 其中, 在 Sonar 数据集上, SPEA2 算法的 NMI 值为 6.465%, 算法性能远远低于本文所提出的算法, 这表明, 本文提出的 QSNSGA-II 算法能够在高维数据中快速收敛, 保持较高的分类准确率和较高的 NMI 值。证明了本文所提算法在高维数据集上的有效性。

综上所述, 相较于其他算法, 本文提出的 QSNSGA-II 算法能够通过强化学习动态调整迁徙参数 p 、 q 、 m , 从而优化特征选择过程。强化学习的自适应调整机制使得算法能够根据当前种群的状态 (包括收敛性和多样性) 动态调整迁徙参数, 从而避免了传统算法在高维数据中常见的收敛过慢或陷入局部最优的情况, 此外, 双种群协同进化策略增强了种群的多样性, 避免了局部最优解的困境, 提高了全局搜索能力, 从而进一步提升了分类准确率和 NMI 指标。

表 4 列出了所有算法在特征选择后的特征数量对比, 从表中可以看出, QSNSGA-II 在大多数数据集上选择的特征数量显著少于其他对比算法。例如, 在 Sonar 数据集上, QSNSGA-II 算法选择了 7 个特征数量, 远低于 MOPSO 算法的 58 个和 MOEA/D 算法的 76 个特征数量。在 Musk1 数据集上, QSNSGA-II 算法选择了 11 个特征数量, 远低于 MOPSO 的 60 个特征数量。这些实验结果表明, QSNSGA-II 算法通过强化学习和双种群协同进化策略, 能够在高维数据集中选择出最具代表性的特征, 从而显著减少了特征数量。

表 2 所有算法在 UCI 数据集上的 Acc 值

Acc	QNSNSGA-II	NSGA-II	SNSGA-II	MOPSO	SPEA2	MOEA/D
Pima	0.823 5	0.720 24	0.753 92	0.678 25	0.734 68	0.643 455
Glass	0.745 01	0.731 41	0.707 99	0.717 22	0.692 75	0.659 045
Sonar	0.846 36	0.810 965	0.834 135	0.821 955	0.589 02	0.757 315
Wine	0.945 21	0.903 145	0.857 1	0.897 885	0.909 1	0.882 93
Musk1	0.911 585	0.905 775	0.908 415	0.907 885	0.796 845	0.832 635
WBDC	0.967 41	0.959 755	0.963 75	0.890 725	0.891 63	0.904 89
Robotnavigation	0.981 43	0.979 285	0.964 225	0.960 76	0.919 81	0.966 75

表 3 所有算法在 UCI 数据集上的 NMI 值

NMI	QNSNSGA-II	NSGA-II	SNSGA-II	MOPSO	SPEA2	MOEA/D
Pima	0.215 8	0.089 175	0.157 135	0.121 65	0.145 115	0.040 7
Glass	0.164 05	0.074 3	0.096 1	0.091 9	0.080 7	0.177 1
Sonar	0.531 2	0.368 73	0.368 38	0.372 22	0.064 65	0.236 99
Wine	0.851 315	0.754 195	0.758 065	0.539 055	0.777 67	0.478 53
Musk1	0.633 35	0.607 565	0.616 06	0.615 27	0.287 57	0.368 46
WBDC	0.783 485	0.775 99	0.772 42	0.514 72	0.574 475	0.529 38
Robotnavigation	0.744 435	0.736 795	0.604 945	0.620 505	0.350 285	0.584 345

表 4 所有算法在 UCI 数据集上选择的特征数量

特征数量	QNSNSGA-II	NSGA-II	SNSGA-II	MOPSO	SPEA2	MOEA/D
Pima	1	5	5	3	2	6
Glass	2	4	3	5	3	5
Sonar	7	14	10	58	34	76
Wine	2	3	3	4	6	4
Musk1	11	34	36	60	25	81
WBDC	3	5	6	4	5	6




图 3 所有算法在 Musk1 数据集上的 pareto 前沿

最后我们在 MATLAB 软件里面进行仿真实验，以高维数据集 Sonar 数据集和 Musk1 数据集为例，经过仿真后得到如图所示的 pareto 前沿，从图 1 和图 2 中可以看出，本文所提算法在高维数据上具有更好的效果，所提算法在特征数量较少，分类准确率较低的区域搜索到了其他算法未搜索到的解，多样性更好，且收敛性也更佳。




图 2 所有算法在 Sonar 数据集上的 pareto 前沿

2.5 实际分类任务表现

为了进一步验证特征选择的效果，我们在选定的特

征子集上测试了不同分类器（如和 KNN、SVM 随机森林）的性能。每个分类器的具体设置如下：KNN 分类器使用了 5 个邻居，并应用默认的欧式距离度量；SVM 分类器使用了线性核函数，并设置了正则化参数为 1 和核函数的参数为 0.1，确保在高维数据集上能够平衡训练和测试误差；随机森林分类器设置了最大树深度为 10，树的数量为 50，特征子采样比例设置为 0.8，以增强其对特征选择的适应性。为了确保实验结果的可信度，我们进行了 5 次独立的计算，计算了每次实验的平均值。

以两个高维数据集 Musk1 和 Sonar 数据集为例，由表 5 和表 6 可知，QNSNSGA-II 算法选择的特征子集在实际分类任务中表现优异。例如，在 Musk1 数据集上，KNN 分类器上，QNSNSGA-II 的分类准确率为 97.89%，SVM 分类器上的分类准确率为 78.95%，随机森林分类器的分类准确率为 91.58%。在 Sonar 数据集上，KNN 分类器上，QNSNSGA-II 的分类准确率为 92.68%，SVM 分类器上的分类准确率为 78.05%，随

机森林分类器上的分类准确率为 85.37%。由此可见, 本文提出的 QNSNSGA-II 算法在高维数据集上表现出了较好的性能。

表 5 所有算法在 Musk1 数据集上不同分类器上的 Acc 值

算法	KNN	SVM	随机森林
QNSNSGA-II	0.978 9	0.789 5	0.915 8
NSGA-II	0.914 7	0.736 8	0.873 7
SNSNSGA-II	0.884 2	0.747 4	0.894 7
MOPSO	0.894 7	0.621 1	0.905 3
SPEA2	0.842 1	0.715 8	0.842 1
MOEA/D	0.789 5	0.768 4	0.852 6

表 6 所有算法在 Sonar 数据集上不同分类器上的 Acc 值

算法	KNN	SVM	随机森林
QNSNSGA-II	0.926 8	0.780 5	0.853 7
NSGA-II	0.878 0	0.756 1	0.818 0
SNSNSGA-II	0.804 9	0.731 7	0.829 3
MOPSO	0.731 7	0.756 1	0.634 1
SPEA2	0.536 6	0.658 5	0.414 6
MOEA/D	0.731 7	0.707 3	0.756 1

3 结束语

本文提出了一种基于强化学习和双种群策略的多目标特征选择算法 (QNSNSGA-II), 旨在解决高维数据集下特征选择过程中分类准确率和特征数量优化的平衡问题。通过引入强化学习框架, 智能体能够根据当前种群的收敛性和多样性指标, 动态调整关键迁徙参数 (p 、 q 、 m), 选择最优动作以优化进化过程。同时, 结合双种群协同进化的策略, 充分利用种群间的信息交互, 提高了解的多样性与质量。

实验结果表明, 本文算法在 7 个 UCI 数据集上的测试中表现优异, 尤其在高维数据集上, Pareto 前沿分布更加集中, 显著提升了解的质量和覆盖范围。在分类性能方面, 分类准确率 (Acc) 和标准互信息 (NMI) 均表现出较高的稳定性, 验证了算法在特征选择任务中的有效性。与其他几种传统算法相比, 本文算法不仅在分类准确率方面更具优势, 同时能够选择更少的特征子集, 达到降维和优化性能的双重目标。尽管如此, 实验中也发现了算法在部分低维数据集上的收敛性能有待进一步优化的问题。

综上所述, 本文提出的算法有效解决了特征选择中的多目标优化问题, 兼顾了分类准确率和特征选择比例的平衡, 在高维数据集上的优异表现展示了其应用潜力, 同时为进一步研究提供了改进方向, 但是在低维数据集上的表现不是很好, 未来的研究方向包括: 进一步优化算法在低维数据集上的收敛性能, 同时探索更多强

化学习策略在特征选择中的应用, 将算法应用于更多实际上的工程问题。

参考文献:

- [1] 高 麟, 周 宇, 邝得互. 进化双层自适应局部特征选择 [J]. 计算机应用, 2024, 44 (5): 1408-1414.
- [2] HAN F, CHEN W T, LING Q H, et al. Multi-objective particle swarm optimization with adaptive strategies for feature selection [J]. Swarm and Evolutionary Computation, 2021, 62: 100847.
- [3] ZHUANG S, TANG Y. Self-adaptive Multi-objective differential evolution for feature selection in classification [C] //2024 6th International Conference on Internet of Things, Automation and Artificial Intelligence (IoTAAD), IEEE, 2024: 603-609.
- [4] ANUSHA M, SATHIASEELAN J G R. Feature selection using k-means genetic algorithm for multi-objective optimization [J]. Procedia Computer Science, 2015, 57: 1074-1080.
- [5] AMOOZEGAR M, MINAEI-BIDGPLI B. Optimizing multi-objective PSO based feature selection method using a feature elitism mechanism [J]. Expert Systems with Applications, 2018, 113: 499-514.
- [6] MUKHOPADHYAY A, MAULIK U. An SVM-wrapped multiobjective evolutionary feature selection approach for identifying cancer-microRNA markers [J]. IEEE Transactions on Nanobioscience, 2013, 12 (4): 275-281.
- [7] YONG Z, DUN-WEI G, WAN-QIU Z. Feature selection of unreliable data using an improved multi-objective PSO algorithm [J]. Neurocomputing, 2016, 171: 1281-1290.
- [8] CHUASUWAN E, EIAMKANITCHAT N. The feature selection for classification by applying the significant matrix with SPEA2 [C] //2013 International Computer Science and Engineering Conference (ICSEC), IEEE, 2013: 359-364.
- [9] NGUYEN H B, XUE B, ISHIBUCHI H, et al. Multiple reference points MOEA/D for feature selection [C] //Proceedings of the Genetic and Evolutionary Computation Conference Companion, 2017: 157-158.
- [10] YONG Z, DUN-WEI G, XIAO-YAN S, et al. A PSO-based multi-objective multi-label feature selection method in classification [J]. Scientificreports, 2017, 7 (1/2/3/4): 376.
- [11] YU X, HAOKAI Z, JIAYU L, et al. Adaptive crossover operator based multi-objective binary genetic algorithm for feature selection in classification [J]. Knowledge-Based Systems, 2021, 227.

(下转第 215 页)