



基于重复度分析的森林优化特征选择算法

冀若含, 董红斌

引用本文:

冀若含,董红斌. 基于重复度分析的森林优化特征选择算法[J]. 智能系统学报, 2022, 17(6): 1113–1122.

JI Ruohan,DONG Hongbin. Feature selection using forest optimization algorithm based on duplication analysis[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(6): 1113–1122.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202111060>

您可能感兴趣的其他文章

基于混合身份搜索黏菌优化的模糊C-均值聚类算法

An optimization fuzzy C-means clustering algorithm based on the hybrid identity search and slime mold algorithms

智能系统学报. 2022, 17(5): 999–1011 <https://dx.doi.org/10.11992/tis.202107011>

一种新的最大相关最小冗余特征选择算法

New MRMR feature selection algorithm

智能系统学报. 2021, 16(4): 649–661 <https://dx.doi.org/10.11992/tis.202009016>

RGBD人体行为识别中的自适应特征选择方法

Adaptive feature selection method for action recognition of human body in RGBD data

智能系统学报. 2017, 12(1): 1–7 <https://dx.doi.org/10.11992/tis.201611008>

基于粗糙集相对分类信息熵和粒子群优化的特征选择方法

A feature selection approach based on rough set relative classification information entropy and particle swarm optimization

智能系统学报. 2017, 12(3): 397–404 <https://dx.doi.org/10.11992/tis.201705004>

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>

DOI: 10.11992/tis.202111060

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20220824.0829.002.html>

基于重复度分析的森林优化特征选择算法

冀若含, 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: 森林优化算法是一种基于森林中树木播种思想的演化算法, 其具有良好的特征空间搜索能力, 且实现难度低。但该算法在森林整体的收敛速度和寻优能力上仍存在提升空间, 而且对高维数据集的适应度较差。本文针对上述问题提出了基于重复度分析的森林优化特征选择算法 (feature selection using forest optimization algorithm based on duplication analysis, DAFSFOA)。该算法提出了基于信息增益的自适应初始化策略、森林重复度分析机制、森林重启机制、候选最优树生成策略、综合考虑特征选择数量和分类正确率的适应度函数。实验结果表明, DAFSFOA 在大部分数据集上达到了最高的分类准确率。同时, 对于高维数据集 SRBCT, 在维度缩减率和分类准确率方面, DAFSFOA 对比森林优化特征选择算法 (feature selection using forest optimization algorithm, FSFOA) 都有较大提升。DAFSFOA 比 FSFOA 具有更强的特征空间探索能力, 而且能够适应不同维度的数据集。

关键词: 特征选择; 演化算法; 重复度分析; 信息熵; 信息增益; 重启机制; 森林优化算法; 维度缩减

中图分类号: TP301 文献标志码: A 文章编号: 1673-4785(2022)06-1113-10

中文引用格式: 冀若含, 董红斌. 基于重复度分析的森林优化特征选择算法 [J]. 智能系统学报, 2022, 17(6): 1113–1122.

英文引用格式: JI Ruohan, DONG Hongbin. Feature selection using forest optimization algorithm based on duplication analysis[J]. CAAI transactions on intelligent systems, 2022, 17(6): 1113–1122.

Feature selection using forest optimization algorithm based on duplication analysis

JI Ruohan, DONG Hongbin

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

Abstract: The forest optimization algorithm is an evolutionary algorithm based on the concept of forest tree planting. It has a strong capability for searching for feature space and low implementation difficulty. However, the algorithm still has room for improvement in the convergence speed and merit-seeking ability of the forest as a whole, and it is not well-suited to high dimensional data sets. In this paper, we propose to use a forest optimization algorithm based on duplication analysis (DAFSFOA) to address the above problems. The algorithm proposes an adaptive initialization strategy based on information gain, a forest repetition analysis mechanism, a forest restart mechanism, a candidate optimal tree generation strategy, and an adaptation function that integrates the number of feature selections and the correct classification rate. The experimental results show that DAFSFOA achieves the highest classification accuracy on most datasets. Meanwhile, for the high dimensional dataset SRBCT, DAFSFOA has a large improvement over feature selection using a forest optimization algorithm (FSFOA) in terms of dimensionality reduction rate and classification accuracy. DAFSFOA has a stronger feature space exploration capability than FSFOA and can adapt to datasets with different dimensions.

Keywords: feature selection; evolutionary algorithm; duplication analysis; information entropy; information gain; restart mechanism; forest optimization algorithm; dimensionality reduction

大数据和物联网技术的发展, 使得越来越多

的数据被采集、存储和分析^[1]。目前的数据不仅数量巨大, 而且维度高, 但并不是全部的数据都是有用的数据。数据的规模在变大的同时也包含了大量的冗余、不相关或者弱相关特征, 这些特征与

收稿日期: 2021-11-30. 网络出版日期: 2022-08-24.

基金项目: 黑龙江自然科学基金资助项目 (LH2020F023).

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

数据的主要基本结构没有关联,或者只有松散的弱关联。如果特征不进行处理就输入机器学习模型,不仅会增大模型的时间开销,而且干扰特征的存在还会降低算法的预测精度。通过对数据原特征空间分析,过滤掉冗余和不相关特征,保留相关特征,这就是特征选择。特征选择以提高模型精度和减少模型运算时间为目地,以保持模型原始精度为底线,选择极小特征子集。此外,大量的特征也会导致模型过拟合,在项目实施时模型性能不佳,特征选择可以预防这种现象的发生,使模型更加适应现实环境^[2]。

特征选择是一个复杂的组合优化问题,这是因为随着特征维度的增加特征搜索空间将会呈指数型增加,一个具有 n 维特征的数据集,特征子集(不包含空集)的总数为 $2^n - 1$ ^[3]。因此采用完全搜索策略的计算成本巨大。近几年基于演化算法的启发式搜索策略常用于特征选择领域,因为其不需要有关领域专业知识、强大寻优能力和较为理想的时间成本。森林优化算法(forest optimization algorithm, FOA)^[4],是一种基于森林中树木播种的演化算法。Ghaemi 等^[5]于 2016 年,通过改变局部播种和全局播种两个算子,使 FOA 适应于离散向量,并应用于特征选择,验证了 FSFOA (feature selection using forest optimization algorithm) 在特征选择领域的可行性。对比粒子群算法(particle swarm optimization, PSO) 和蚁群算法(ant colony optimization, ACO), FSFOA 更容易实现,而且需要更少的时间代价就能得出使学习模型性能更好的特征子集。虽然 FSFOA 已经在低、中、高 3 个特征维度的数据集中进行了实验取得了较好的效果,但仍然存在以下问题:

1) FSFOA 在初始化森林的阶段采用随机初始化的策略进行盲目特征选择,特征被选中的概率均为 $1/n$, n 为总特征数^[6]。因此森林树木初始质量较差,森林收敛速度较慢。而且对高维数据集的适应度较差。

2) FSFOA 未对候选种群的数量进行限制。随着演化过程的进行,候选种群的数量将过于庞大,算法空间成本过高。

3) 随着演化的进行种群趋于收敛,森林中会出现大量相同的树木(特征选择向量相同的树木)。重复树木的适应度计算增加了时间成本,降低了算法的搜索能力。

4) 实验表明,在仅考虑准确率作为适应度的情况下,会出现多个适应度相同的最优树。而且只考虑分类准确率为优化目标过于单一,不利于

提高维度缩减率。

因此,为了提升森林整体的收敛速度、增强森林整体的空间搜索寻优能力,本文提出了基于重复度分析的森林优化特征选择算法(feature selection using forest optimization algorithm based on duplication analysis, DAFSFOA)。

近年来,信息论与演化算法相结合的研究工作越来越多^[7-10],信息增益(information gain, IG)可用于初步衡量特征的重要性。通过应用IG,可以提高森林树木的初始质量,过滤掉与分类毫无关系的特征,有利于加速森林整体的演化进程。Xu 等^[11]于 2021 年提出重复度分析的概念,旨在增加种群多样性,调高算法的全局寻优能力和减少重复计算。受以上内容启发,本文设计了基于信息增益和特征维度的自适应森林初始化策略,加快了森林的收敛速度,且适应于不同类型的数据。同时加入了森林树木分析去重机制、森林种群重启机制、候选森林规模限制和候选最优树生成策略,降低了算法的空间和时间成本,并且增强了算法的空间搜索能力。最后改进适应度函数,提升了算法对于高维数据集的寻优能力。在 11 个数据集上测试 DAFSFOA 的性能,对比经典的和近几年提出的特征选择算法,DAFSFOA 在分类准确率和特征维度缩减率上都具有很强的竞争力,同时对高维小样本数据也有很好的适应力。

1 相关工作

特征选择作为一种数据降维手段,能在不改变原始特征物理信息的情况下选择尽量小的特征子集。特征选择常作为数据处理工具,去除干扰特征和选择核心特征。因此许多学者已经对特征选择进行了系统的研究。通常将特征选择方法分为 3 种类型:过滤式(filter)、包裹式(wrapper)和嵌入式(embedding)^[1]。对于过滤式特征选择算法,特征子集的选择与机器学习模型之间没有交互,模型的输出结果不会影响特征子集的选择。在包裹式特征选择算法中,模型的结果例如分类准确率,会直接作为特征子集的适应度函数,评价特征子集的优劣。嵌入式特征选择算法将分类算法或者回归算法的学习过程与特征选择过程合并同时进行,算法学习过程结束的同时产生特征选择结果。包裹式方法往往能取得比过滤式方法更好的效果,但同时也需要付出更大的计算代价。而过滤式方法的计算成本较低,而且通用性更好^[12]。随着研究的进展,也产生了越来越多的混合式特

征选择算法(hybrid method), 混合式特征选择方式结合了过滤式和包裹式方法的优点。

特征子集搜索技术是特征选择的核心, 搜索技术的选择往往会影响特征选择算法的效果。子集搜索技术一般分为3种: 完全搜索、启发式搜索、基于演化算法的搜索^[13]。完全搜索能够保证寻找到最优特征子集, 但是特征选择是个NP难问题, 当面对高维数据时, 完全搜索需要的时间代价过大, 因此特征选择中较少采用完全搜索策略^[14]。启发式搜索常用于特征选择, 例如贪婪搜索。贪婪搜索的典型例子是: 序列正向选择(sequential forward selection, SFS)^[15]、序列反向选择(sequential backward selection, SBS)^[16]。但是这两种搜索方式都存在明显的局限, 都存在“嵌套效应”, 缺少搜索的灵活性, 之前添加或者去除的特征, 在之后步骤中不能从特征子集中去除或者重新加入特征子集。为了克服这个问题, 提出了加L减R法^[17]、顺序反向浮动选择(sequential backward floating selection, SBFS)^[18]和顺序正向浮动选择(sequential forward floating selection, SFFS)^[18]等。加L减R法通过运行L次SFS算法, R次SBS来达到平衡, 但是很难确定L和R的值。演化算法的灵感来源于自然演化中的生物智慧、群体智慧和群体行为, 其具有强大的搜索能力。近年来, 以粒子群算法(PSO)、遗传算法(genetic algorithm, GA)、蚁群算法(ACO)等经典演化算法为基础的变种算法广泛应用于超参数优化^[19]、特征选择^[20]和路径规划^[21]等领域。同时也出现了大量新型演化算法, 如模拟座头鲸气泡网狩猎的鲸鱼算法(whale optimization algorithm, WOA)^[22]、受森林中树木播种启发的森林优化算法(FOA)^[4]。虽然演化算法的应用领域广泛, 但要应用于特征选择也必须进行一系列的改进, 形成针对特征选择领域的演化算法。Dong等^[23]结合信息论知识和粒子群算法, 并舍弃粒子群更新公式中的速度参数, 提出了一种混合特征选择方法: 基于PSO的双全局最优的高维特征选择方法。Agrawal等^[24]结合量子计算的概念提出了基于量子的鲸鱼优化算法(quantum based whale optimization algorithm, QWOA)进行特征选择。该方法利用种群个体的量子位表示法和量子旋转门算子, 提高了经典WOA的特征空间探索和利用能力, 全局寻优能力更强、种群多样性更高。Li等^[25]提出了一种改进的黏性二进制粒子群算法(improved binary particle swarm optimization, ISBPSO)。ISBPSO采用了基于互信息(MI)种群初始化策略获得优质

初始种群, 并将遗传算法作为PSO的子算子用于交换种群信息避免种群过早收敛, 提高了算法跳出局部最优的能力。

本文提出的DAFSFOA主要目标为增加森林中树木的多样性, 扩大森林对特征空间的覆盖, 同时降低算法的计算成本。为达到以上目的, DAFSFOA添加了基于信息增益的自适应森林初始化策略、森林去重和重启机制、候选森林规模限制策略、候选最优树生成策略, 并改进了适应度函数。

2 森林优化特征选择算法

FSFOA是在FOA的基础上改进而来的, 可以看作二进制离散向量的森林优化算法。FOA的灵感来自于森林中树木种群的演化过程。在森林中, 参天大树往往在水源和阳光充足的地方。树木种子寻找最佳栖息地的过程, 也是一个搜索寻优的过程。通过对这一过程的建模, 最终Ghaemi^[4]等于2014年提出了FOA。之后, Ghaemi等^[5]提出了针对离散空间搜索的FOA, 并应用于特征选择。FSFOA主要由初始化森林、局部播种、森林规模限制候选森林生成、全局播种、更新全局最优树五部分组成。FSFOA采用 $X_i = (x_{i0}, x_{i1}, x_{i2}, \dots, x_{iD})$, 表示森林中索引值为i的树木。其中 $x_{i0} \geq 0$, $x_{i,j>0} \in \{1, 0\}$, D表示数据集的维度。树木向量的第0维表示树木的年龄, 第1~D维表示特征选择情况, 0代表未选中该特征, 1代表选中。FSFOA的主要流程如图1所示。




图1 FSFOA流程
Fig. 1 Flowchart of FSFOA

2.1 初始化森林

在 FSFOA 中, 森林中每一棵树木都被表示为如图 2 所示的长度为 $D+1$ 的离散向量。与常规特征选择算法中选择结果表示方法不同的是, FSFOA 中添加了年龄 A_{age} 这一维。树木的年龄这一重要的参数在后续局部播种和森林规模限制阶段有重要的作用。初始化森林就是生

成一定数目的初始树木向量, 树木年龄全部设置为 0, 其余位置随机初始化为 0 或 1。因此, 在初始化森林的阶段每个特征被选中和被删除的概率相同。对于中低维数据集, 这种随机的初始化策略 s 缺点并不明显, 但对于高维数据集, 完全随机初始化森林将给后续种群寻优带来极大困难。




图 2 $N_{ls}=2$ 时局部播种实例

Fig. 2 Example of local seeding at $N_{ls}=2$

2.2 局部播种

局部播种代表了 FSFOA 对特征空间的深度搜索, 模拟了树木在自身附近播种的行为。局部播种算子只针对 $A_{age}=0$ 的树木。 N_{ls} 参数代表了 $A_{age}=0$ 的父代树木可产生的子树数目。进行局部播种的树木随机选中 N_{ls} 个不同的位置进行单点翻转突变, 也即对选中的位置进行取反操作, 选中位置为 0 的置为 1, 为 1 的置为 0。每进行 1 次单点取反将产生 1 棵子树, 并重置父树继续下次单点突变。 N_{ls} 个突变位置将产生 N_{ls} 棵子树, 子树 $A_{age}=0$, 森林中其他所有树木的 A_{age} 增加 1。具体过程如图 2 所示。图 2 中 \checkmark 代表了选中的突变位置。

2.3 森林规模限制

随着演化的进行, 森林中树木会越来越多。因此需要对森林中的总容量进行限制, 森林的容

量为 S_{area} 。 $A_{age} > T_{life}$ (年龄限制) 的树木将会老死, 被森林淘汰, 移除到候选森林。如果森林中树木总数仍大于 S_{area} , FSFOA 将会根据适应度值对森林中的树木进行降序排序, 排名超过 S_{area} 的树木也将移除到候选森林。FSFOA 中的适应度值为分类器的分类准确率, 也即树木选择的特征子集的分类能力。

2.4 全局播种

全局播种代表了 FSFOA 对特征空间的广度搜索。对比局部播种, 全局播种产生的子树与父树的差距更大。全局播种操作可在森林陷入局部最优的时候, 使森林跳出局部最优。候选森林中的树木以 $P_{transfer}$ 的概率被选中进行全局播种。1 棵父树只产生 1 棵子树, 父树随机选择 N_{gsc} 个位置进行多点取反, 并置 $A_{age}=0$, 加入森林中参与演化, 具体如图 3 所示。




图 3 $N_{gsc}=4$ 时全局播种实例

Fig. 3 Example of global seeding at $N_{gsc}=4$

2.5 更新最优树

根据适应度值对森林中的树木进行降序排列, 适应度最高的树被选为最优树, 并将该树的 A_{age} 字段置为 0, 参与后续的森林演化。将最优树的 A_{age} 每次都重置为 0, 也即优秀的树木不会被淘汰, 保证了森林中优秀的树木能够一直参与森林的演化。

3 DAFSFOA 算法

针对引言中提出的 FSFOA 的缺陷, 以提升森林的收敛速度和算法的搜索能力为目标, 本文提

出了 DAFSFOA 算法。为了加快森林收敛速度, DAFSFOA 引入了信息增益对特征进行初筛, 提升了初始种群的质量, 而且针对不同维度的数据集采用了不同的初始化策略缩小了高维数据集的搜索空间。同时, 采用森林树木重复度分析机制和候选森林规模限制策略降低了算法的时间与空间成本。为了提升算法的搜索能力, DAFSFOA 设计了森林重启机制, 防止森林过早收敛陷入局部最优, 同时提出了候选最优解生成策略进一步提升树木多样性, 并且改进了适应度函数, 大大提高了算法的寻优能力。

3.1 基于信息增益的自适应初始化策略

近年来, 特征选择领域常用信息论知识对特征进行初步筛选。信息增益(IG)能够反应特征与分类标签的相关度。信息增益越大, 该特征对于分类的帮助越大。信息增益的定义如式(1)~(4)所示:

$$P(X = x_i) = p_i, i = 1, 2, \dots, n \quad (1)$$

$$H(X) = -\sum_{i=1}^n p_i \log p_i \quad (2)$$

$$H(Y|X) = \sum_{i=1}^n p_i H(Y|X = x_i) \quad (3)$$

$$IG(Y, X) = H(Y) - H(Y|X) \quad (4)$$

$H(X)$ 为随机变量的熵, $H(Y|X)$ 为条件熵, 两者之差就是信息增益。但信息增益并不能反应特征与特征之间的关系, 因此不能全凭信息增益选择特征。本文提出增 1 减 1 法来初始化森林树木。在计算数据集中每个特征的 IG 后, 对森林进行随机初始化, 对初始化后的初代森林中前 50% 的树木, 添加信息增益最大的特征, 并删除信息增益最小的特征。并且对于高纬度小样本的数据集采用不同的初始化策略。当 D (特征维度) $\gg N$ (样本数量) 时, 无法覆盖整个特征空间, 因为样本数量太少此时在初始化森林时选择较少的特征更利于后续收敛。当 $D > 3N$ 时, 初始森林中的树木选择的特征数目应小于等于 $3N$ 。

3.2 候选森林规模的限制策略

FSFOA 中随着森林演化的进行, 森林中越来越多的树被转移到候选森林。候选森林的规模将越来越大, 但保存巨大的候选森林会带来较大的内存开销, 而且劣质树木对于森林的寻优帮助不大。较大的候选森林也会导致在全局播种阶段有过多的新生树木加入到森林中, 也间接加大了算法的计算消耗。因此, 在 DAFSFOA 中的森林规模限制阶段, 本文对候选森林同样进行规模限制。因为候选森林均为较劣质的树木, 所以无需在计算适应度进行排序筛选。本文将候选森林的规模限制设为森林规模限制的两倍, 即 $2S_{area}$ 。当候选森林中树木数量超过限制时, 随机删除树木直到树木数量等于 $2S_{area}$ 。

3.3 重复度分析及森林重启机制

随着演化的进行森林逐渐收敛, 森林中产生大量 A_{age} 不同, 但是所选特征相同的树木。大量重复的树木的存在对森林演化寻优并无帮助, 反而因此消耗了大量的计算资源。因此, 我们需要对森林中的树木进行重复度分析, 每种树木只保留一个个体, 极大地提高了森林中树木的多样性,

有利于算法的全局寻优。如果经过去重操作森林中剩余的树的数量只有森林初始种群数量 $S_{initial}$ 的一半, 此时认为森林种群的多样性过低不利于后续搜索寻优, 因此采用森林重启机制, 采用初始化森林的方法补充森林中的树木, 使森林树木的数量重新达到 $S_{initial}$ 。

3.4 候选最优树生成策略

FSFOA 每轮演化只产生 1 棵最优树, 忽略了森林中树木的统计信息。为了充分利用森林演化过程中的统计信息, 在 DAFSFOA 中提出候选最优树概念, 即统计目前森林中出现过的全部特征, 并根据统计结果生成候选最优树, 将候选最优树的年龄置为 0, 并加入森林参与后续的森林演化。候选最优树的加入不仅增加了森林树木多样性, 而且充分利用了森林演化过程中的统计信息。

3.5 改进的适应度函数

适应度值表现了算法所选择的特征子集的好坏。FSFOA 中的适应度函数设计考虑较为片面, 仅考虑分类准确率(AC), AC 的定义如式(5)所示:

$$AC = \frac{N_{acc}}{M} \quad (5)$$

式中: N_{acc} 为分类正确的实例数; M 为实例总数。在只考虑 AC 的情况下实验结果中出现了很多适应度值相同的树, 不利于最优树的挑选, 而且不利于森林朝着增大 DR 的方向演化, DR 为维度缩减率, 如式(6)所示:

$$DR = \frac{F_{notSelected}}{F_{all}} \quad (6)$$

式中: $F_{notSelected}$ 为对应树未选择的特征数; F_{all} 为特征总数。式(7)为 DAFSFOA 中采用的适应度函数, 为 AC 和 DR 的加权, 避免了不同树适应度值相同的情况。 $\alpha + \beta = 1$ 而且 $\alpha \gg \beta$, 因为特征选择算法的主要目的为提高分类准确率。

$$Fitness = \alpha \times AC + \beta \times DR \quad (7)$$

3.6 DAFSFOA 流程图

图 4 为 DAFSFOA 的算法流程图。DAFSFOA 的演化终止条件为迭代 50 次, 当演化次数超过限制, 则结束算法, 输出森林中目前的最优树也即最优特征子集。

4 实验和结果分析

实验中代码运行环境为 python3.8。硬件环境为 CPU Ryzen7 5800H, 16 GB 内存。

4.1 数据集及对比算法

FSFOA 中使用了 10 个 UCI 数据集和 1 个高维微阵列数据集。数据集的维度和实例数如表 1 所示。




图 4 DAFSFOA 流程图
Fig. 4 Flowchart of DAFSFOA

表 1 数据集简介及 N_{lsc} 和 N_{gsc}
Table 1 Dataset introduction and corresponding N_{lsc} and N_{gsc} values

数据集	特征数	样本数	类数	N_{lsc}	N_{gsc}
Heart-statlog	13	270	2	3	6
Vehicle	18	846	4	4	9
Cleveland	13	303	5	3	6
Dermatology	34	366	6	7	15
Ionosphere	34	351	2	7	15
Sonar	60	208	2	12	30
Glass	9	214	7	2	4
Wine	13	178	3	3	6
Segmentation	19	2310	7	4	9
SRBCT	2308	83	4	460	700
Hepatitis	19	155	2	4	10

为了对比显示 DAFSFOA 算法的性能, 本文采用与 FSFOA 相同的 11 个数据集。除了与 FSFOA 进行实验对比, 本文也与几种经典的特征选择算法和近年提出的新算法进行了对比。**表 2** 列出了文中对比算法的简介。

表 2 文中对比算法
Table 2 Comparative algorithms in the paper

算法名称	数据集划分方式	算法描述
NFSFOA	70%~30%, 10-fold, 2-fold	新的森林优化特征选择算法 ^[26]
FSFOA	70%~30%, 10-fold, 2-fold	森林优化特征选择算法 ^[5]
SFS,SBS,SFFS	70%~30%	前向选择、后向选择、序列浮动前向选择 ^[27]
NSM	10-fold	基于软紧邻间隔的特征选择算法 ^[28]
SVM-FuzCoc	70%~30%	基于 SVM 的模糊互补准则的新型特征选择算法 ^[27]
HGAFS	2-fold	一种基于互信息的混合遗传算法的包裹式特征选择算法 ^[29]
FS-NEIR	10-fold	基于邻域有效信息比率的特征选择算法 ^[30]
UFSACO	70%~30%	一种基于蚁群优化的无监督特征选择算法 ^[31]
PSO(4-2)	10-fold	改进的粒子群优化特征选择算法 ^[32]

注: 10-fold 为十折交叉验证, 2-fold 为两折交叉验证

4.2 具体参数设置

为了突出 DAFSFOA 对于 FSFOA 改进的有效性。除了改进部分, 其他参数保持与 FSFOA 一致。 T_{life} 设为 15, $P_{transfer}$ 设为 0.05, S_{area} 设为 50, 以上 3 个参数与 FSFOA 的设置相同, $S_{initial}$ 在 FSFOA 中未提及具体值, 本文中设为 50^[5]。 N_{lsc} 和 N_{gsc}

也保持和 FSFOA 相同。FSFOA 中指出 N_{lsc} 和 N_{gsc} 与数据集维度有关, 同时实验得出当 $N_{lsc}=D/5$, $N_{gsc}=D/2$ 时, 能达到计算成本和寻优效果的最佳平衡^[5]。参数设置具体如**表 1** 所示。

4.3 分类器和验证方式

本文采用 KNN、rbf-svm、C4.5 三种分类器计

算 AC, 其中 KNN 采用了 $n=1$ 、 $n=3$ 和 $n=5$ 这 3 种不同的参数。C4.5 采用 J48 参数。同时采用 70%~30% 的数据集划分、10 折交叉验证、2 折交叉验证这 3 种不同的数据集划分方式。实验中采用相同的实验条件计算得出森林中每棵树的 AC 和 DR, 得出最优树, AC 和 DR 的计算公式如式(5)、(6)所示。

4.4 实验结果分析

DAFSFOA 与其他算法对比的结果如表 3 所示。对于最高正确率和最高维度缩减率均加粗处理。在 Dermatology、Sonar、Cleveland、Heart-statlog、Hepatitis、SRBCT、Segmentation 这 7 个数据集上, 采用不同的数据集划分方式和分类器, DAFSFOA 都取得最高的准确率。

表 3 DAFSFOA 与对比算法的实验结果

Table 3 Experimental results of DAFSFOA and comparison algorithms

数据集	算法	AC/%	DR/%	分类器	数据集	算法	AC/%	DR/%	分类器
Wine	DAFSFOA	98.89(10-fold)	61.15	J48	Ionosphere	DAFSFOA	98.05(10-fold)	70.59	J48
	NFSFOS	97.25(10-fold)	53.85	J48		NFSFOS	96.62(10-fold)	61.76	J48
	FSFOA	96.06(10-fold)	21.42	J48		FSFOA	93.16(10-fold)	68.57	J48
	FS-NEIR	95.04(10-fold)	61.53	J48		FS-NEIR	92.59(10-fold)	82.35	J48
	DAFSFOA	98.33(10-fold)	53.85	3nn		DAFSFOA	95.28(10-fold)	77.06	3nn
	NFSFOA	95.61(10-fold)	61.54	3nn		NFSFOA	93.83(10-fold)	76.47	3nn
	FSFOA	98.87(10-fold)	42.58	3nn		FSFOA	92.30(10-fold)	61.76	3nn
	NSM	98.00(10-fold)	53.84	3nn		NSM	92.00(10-fold)	88.23	3nn
	DAFSFOA	98.16(70%~30%)	69.23	1nn		DAFSFOA	95.00(10-fold)	79.70	5nn
	NFSFOA	95.61(70%~30%)	61.54	1nn		NFSFOA	93.23(10-fold)	79.41	5nn
	FSFOA	98.07(70%~30%)	50.00	1nn		FSFOA	89.43(10-fold)	54.28	5nn
	SFS	97.69(70%~30%)	35.38	1nn		DAFSFOA	97.27(2-fold)	67.65	rbf-svm
	SBS	94.77(70%~30%)	46.15	1nn		NFSFOA	95.16(2-fold)	58.82	rbf-svm
	SFFS	96.56(70%~30%)	36.92	1nn		FSFOA	94.58(2-fold)	57.14	rbf-svm
Dermatology	DAFSFOA	98.61(70%~30%)	68.46	J48		HGAFS	92.76(2-fold)	82.35	rbf-svm
	NFSFOA	96.73(70%~30%)	61.54	J48		DAFSFOA	98.44(70%~30%)	74.56	1nn
	FSFOA	96.00(70%~30%)	57.14	J48		NFSFOA	95.16(70%~30%)	58.82	1nn
	UFSACO	95.08(70%~30%)	61.53	J48		FSFOA	89.52(70%~30%)	54.28	1nn
	DAFSFOA	97.69(70%~30%)	70.00	5nn		SVM-FuzCoc	89.46(70%~30%)	88.23	1nn
	NFSFOA	95.70(70%~30%)	38.46	5nn		DAFSFOA	96.60(70%~30%)	73.82	J48
	FSFOA	99.20(70%~30%)	30.76	5nn		NFSFOA	99.06(70%~30%)	67.65	J48
	DAFSFOA	96.07(2-fold)	53.85	rbf-svm		FSFOA	95.12(70%~30%)	47.05	J48
	NFSFOA	96.06(2-fold)	37.17	rbf-svm		UFSACO	88.61(70%~30%)	11.17	J48
	HGAFS	98.31(2-fold)	53.85	rbf-svm		DAFSFOA	62.64(70%~30%)	69.23	1nn
Vehicle	DAFSFOA	98.26(10-fold)	71.18	J48		NFSFOA	62.22(70%~30%)	61.54	1nn
	NFSFOA	97.81(10-fold)	73.53	J48		FSFOA	55.55(70%~30%)	71.42	1nn
	FSFOA	96.99(10-fold)	21.42	J48		SVM-FuzCoc	61.01(70%~30%)	46.10	1nn
	FS-NEIR	93.95(10-fold)	70.58	J48		SFS	51.79(70%~30%)	47.70	1nn
	DAFSFOA	99.40(70%~30%)	67.06	1nn		SBS	54.80(70%~30%)	38.50	1nn
	NFSFOA	99.07(70%~30%)	58.82	1nn		SFFS	49.55(70%~30%)	53.80	1nn
	FSFOA	97.27(70%~30%)	45.71	1nn		Vehicle	DAFSFOA	78.00(10-fold)	33.33

续表 3

数据集	算法	AC/%	DR/%	分类器	数据集	算法	AC/%	DR/%	分类器
Dermatology	SFS	94.02(70%~30%)	44.70	1nn	Vehicle	NFSFOA	77.74(10-fold)	44.44	J48
	SBS	91.78(70%~30%)	58.23	1nn		FSFOA	73.04(10-fold)	31.57	J48
	SFFS	93.70(70%~30%)	62.35	1nn		FS-NEIR	70.98(10-fold)	50.00	J48
	SVM-FuzCoc	94.11(70%~30%)	64.70	1nn		DAFSFOA	77.17(70%~30%)	51.11	5nn
	DAFSFOA	98.95(70%~30%)	77.21	J48		NFSFOA	76.77(70%~30%)	55.56	5nn
	NFSFOA	98.15(70%~30%)	70.59	J48		FSFOA	73.98(70%~30%)	50.00	5nn
	FSFOA	90.09(70%~30%)	44.11	J48		PSO(4-2)	85.30(70%~30%)	68.40	5nn
	UFSACO	95.28(70%~30%)	26.47	J48		DAFSFOA	69.38(2-fold)	66.67	rbf-svm
	DAFSFOA	88.51(2-fold)	62.83	rbf-svm		NFSFOA	69.03(2-fold)	66.67	rbf-svm
	NFSFOA	75.94(2-fold)	78.33	rbf-svm		FSFOA	62.41(2-fold)	47.22	rbf-svm
Sonar	FSFOA	65.86(2-fold)	54.09	rbf-svm	Heart-statlog	DAFSFOA	85.22(10-fold)	69.23	J48
	HGAFS	87.02(2-fold)	75.00	rbf-svm		NFSFOA	84.07(10-fold)	61.54	J48
	DAFSFOA	92.06(10-fold)	72.22	J48		FSFOA	85.15(10-fold)	48.07	J48
	NFSFOA	85.18(10-fold)	65.00	J48		FS-NEIR	79.86(10-fold)	46.15	J48
	FSFOA	82.69(10-fold)	52.45	J48		DAFSFOA	85.92(10-fold)	60.00	3nn
	FS-NEIR	75.97(10-fold)	91.66	J48		NFSFOA	83.33(10-fold)	53.85	3nn
	DAFSFOA	98.33(70%~30%)	76.58	1nn		FSFOA	85.18(10-fold)	35.71	3nn
	NFSFOA	76.19(70%~30%)	76.67	1nn		NSM	84.00(10-fold)	69.23	3nn
	FSFOA	85.43(70%~30%)	57.37	1nn		DAFSFOA	85.22(2-fold)	53.85	rbf-svm
	DAFSFOA	95.40(70%~30%)	75.67	5nn		NFSFOA	84.81(2-fold)	76.92	rbf-svm
Glass	NFSFOA	74.60(70%~30%)	68.33	5nn		FSFOA	84.07(2-fold)	50.00	rbf-svm
	FSFOA	86.98(70%~30%)	44.26	5nn		HGAFS	82.59(2-fold)	76.92	rbf-svm
	PSO(4-2)	78.16(70%~30%)	81.26	5nn		—	—	—	—
	DAFSFOA	79.90(10-fold)	37.22	J48	Segmentation	DAFSFOA	97.10(10-fold)	68.16	3nn
	NFSFOA	78.13(10-fold)	33.33	J48		NFSFOA	96.88(10-fold)	52.63	3nn
	FSFOA	75.70(10-fold)	50.00	J48		FSFOA	96.20(10-fold)	30.00	3nn
	FS-NEIR	68.53(10-fold)	22.22	J48		NSM	95.00(10-fold)	63.15	3nn
SRBCT	DAFSFOA	77.23(70%~30%)	42.77	1nn	Hepatitis	DAFSFOA	91.56(10-fold)	64.21	J48
	NFSFOA	75.38(70%~30%)	55.56	1nn		FSFOA	86.45(10-fold)	55.00	J48
	FSFOA	71.88(70%~30%)	40.00	1nn		FS-NEIR	81.11(10-fold)	68.42	J48
	SFS	72.24(70%~30%)	26.66	1nn		DAFSFOA	91.68(10-fold)	63.68	3nn
	SBS	71.77(70%~30%)	37.77	1nn		FSFOA	87.09(10-fold)	42.10	3nn
	SFFS	71.77(70%~30%)	37.77	1nn		NSM	90.00(10-fold)	15.78	3nn
	DAFSFOA	66.83(2-fold)	55.55	rbf-svm		DAFSFOA	92.23(70%~30%)	66.57	J48
	NFSFOA	68.69(2-fold)	33.33	rbf-svm		FSFOA	84.40(70%~30%)	45.00	J48
	FSFOA	68.22(2-fold)	60.00	rbf-svm		UFSACO	78.87(70%~30%)	75.00	J48
	HGAFS	65.51(2-fold)	44.44	rbf-svm		—	—	—	—
Hepatitis	DAFSFOA	99.99(70%~30%)	92.33	1nn		—	—	—	—
	NFSFOA	94.73(70%~30%)	61.48	1nn		—	—	—	—
	FSFOA	94.73(70%~30%)	49.06	1nn		—	—	—	—
	SVM-FuzCoc	98.88(70%~30%)	98.57	1nn		—	—	—	—

DAFSFOA 在高维数据集 SRBCT 上算法性能有巨大的提升, 对比 FSFOA, 其准确率提升了 5.26%, 而且维度缩减率的提升更为巨大。FSFOA 在对应数据集上的准确率高达 94.73%, 但是维度缩减率只有 49.06%, 而 SRBCT 数据集的特征维度有 2308 维, FSFOA 得到的最优树仍然包含了大量特征。而 DAFSFOA 得到的最优树维度缩减率高达 92.33%。对比 FSFOA, DAFSFOA 能够更好地处理高维特征选择问题, 这得益于 DAFSFOA 特殊设计的高维数据集初始化策略。对于同样是高维数据集的 Sonar, DAFSFOA 的表现也要远远好于 FSFOA, 平均 AC 为 93.57%, 最高 AC 为 98.33%, 而 FSFOA 的平均 AC 为 80.24%, 其最高 AC 为 86.98%, 也低于 DAFSFOA 的平均值。当采用 rbf-svm 分类器并采用 2-fold 验证的时候, DAFSFOA 的准确率比 FSFOA 高了 22%, 同时维度缩减率提高了 8%。同时, 对比 2020 年提出的 NFSFOA, DAFSFOA 也具有明显的优势, 在同样条件下, DAFSFOA 得出的最优特征子集分类准确率最高达 98.33%, 而相应的 NFSFOA 只有 74.6%, 但 NFSFOA 产生的最优树的维度缩减率只高出 DAFSFOA 算法 0.09%, DAFSFOA 只牺牲了 0.09% 的 DR, 就达到了 98.33% 的准确率, 可见 DAFSFOA 的性能优势。在维度缩减率方面, DAFSFOA 并不像在分类正确率上表现得如此出众, 但对于大部分数据集 DAFSFOA 都优于 FSFOA。对于一部分数据集, 虽然 DAFSFOA 没有取得最高的维度缩减率, 但在分类准确率上仍有较大优势。例如, NSM 算法在 Ionosphere 数据集上, 采用 10 折交叉验证和 KNN($k=1$) 分类器取得了 88.23% 的维度缩减率, 高于 DAFSFOA。但是 NSM 算法的分类准确率比 DAFSFOA 低了 3.2%。

在大部分数据集中, DAFSFOA 的维度缩减率排行第二, 并且与第一相差很小, 但分类准确率远超其他算法。通过 DAFSFOA 在不同数据集的实验, 可以得出 DAFSFOA 在 AC 和 DR 上对原始的 FSFOA, 均有巨大提升, 而且在大部分数据集中的表现也超过了其他经典的算法和近年来提出的新型特征选择算法。

5 结束语

本文通过对 FSFOA 的深入分析, 提出了 FSFOA 的 4 处不足。以提高森林中个体的多样性、降低树木重复度和提高算法的全局寻优能力为目的, 本文对 FSFOA 算法提出了 5 点改进意见, 即基于信息增益的自适应初始化策略、候选森林规

模限制策略、森林重复度分析及重启机制、候选最优树生成策略、结合维度缩减率的适应度函数, 最终形成了基于重复度分析的森林优化特征选择算法。并通过实验在不同维度的数据集上验证了 DAFSFOA 改进的有效性。DAFSFOA 在 AC 和 DR 两个方面的表现普遍超过了 FSFOA, 尤其是对于高维数据集, DAFSFOA 的表现优于 FSFOA。

参考文献:


- [1] LI Jundong, CHENG Kewei, WANG Suhang, et al. Feature selection: a data perspective[J]. ACM computing surveys, 2018, 50(6): 94.
- [2] XUE Bing, ZHANG Mengjie, BROWNE W N, et al. A survey on evolutionary computation approaches to feature selection[J]. IEEE transactions on evolutionary computation, 2016, 20(4): 606–626.
- [3] DASH M, LIU H. Feature selection for classification[J]. Intelligent data analysis, 1997, 1(1/2/3/4): 131–156.
- [4] GHAEMI M, FEIZI-DERAKHSI M R. Forest optimization algorithm[J]. Expert systems with applications, 2014, 41(15): 6676–6687.
- [5] GHAEMI M, FEIZI-DERAKHSI M R. Feature selection using Forest Optimization Algorithm[J]. Pattern recognition, 2016, 60: 121–129.
- [6] 初蓓, 李占山, 张梦林, 等. 基于森林优化特征选择算法的改进研究 [J]. 软件学报, 2018, 29(9): 2547–2558.
CHU Bei, LI Zhanshan, ZHANG Menglin, et al. Research on improvements of feature selection using forest optimization algorithm[J]. Journal of software, 2018, 29(9): 2547–2558.
- [7] UNLER A, MURAT A, CHINNAM R B. mr2PSO: a maximum relevance minimum redundancy feature selection method based on swarm intelligence for support vector machine classification[J]. Information sciences, 2011, 181(20): 4625–4641.
- [8] CERVANTE L, BING Xue, ZHANG Mengjie, et al. Binary particle swarm optimisation for feature selection: a filter based approach[C]//2012 IEEE Congress on Evolutionary Computation. Brisbane, 2012: IEEE, 2012: 1–8.
- [9] KANNAN S S, RAMARAJ N. A novel hybrid feature selection via Symmetrical Uncertainty ranking based local memetic search algorithm[J]. Knowledge-based systems, 2010, 23(6): 580–585.
- [10] 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.
- [11] XU Hang, XUE Bing, ZHANG Mengjie. A duplication analysis-based evolutionary algorithm for biobjective fea-

- ture selection[J]. *IEEE transactions on evolutionary computation*, 2021, 25(2): 205–218.
- [12] JOHN LU Z Q. The elements of statistical learning: data mining, inference, and prediction[J]. *Journal of the royal statistical society:series A (statistics in society)*, 2010, 173(3): 693–694.
- [13] SUN Zehang, BEBIS G, MILLER R. Object detection using feature subset selection[J]. *Pattern recognition*, 2004, 37(11): 2165–2176.
- [14] DAVIES S, RUSSELL S. NP-completeness of searches for smallest possible feature sets[C]//AAAI Symposium on Intelligent Relevance. Menlo Park: AAAI Press, 1994: 37–39.
- [15] MARCANO-CEDEO A, QUINTANILLA-DOMÍNGUEZ J, CORTINA-JANUCHS M G, et al. Feature selection using Sequential Forward Selection and classification applying Artificial Metaplasticity Neural Network[C]// IECON 2010—36th Annual Conference on IEEE Industrial Electronics Society. Glendale: IEEE, 2010: 2845–2850.
- [16] PENG Hongyi, JIANG Chunfu, FANG Xiang, et al. Variable selection for Fisher linear discriminant analysis using the modified sequential backward selection algorithm for the microarray data[J]. *Applied mathematics and computation*, 2014, 238: 132–140.
- [17] İŞIK \$. Dominant point detection based on suboptimal feature selection methods[J]. *Expert systems with applications*, 2020, 161: 113741.
- [18] SETIAWAN D, KUSUMA W A, WIGENA A H. Sequential forward floating selection with two selection criteria[C]//2017 International Conference on Advanced Computer Science and Information Systems (ICACSIS). Bali: IEEE, 2017: 395–400.
- [19] SINGH P, CHAUDHURY S, PANIGRAHI B K. Hybrid MPSO-CNN: multi-level particle swarm optimized hyperparameters of convolutional neural network[J]. *Swarm and evolutionary computation*, 2021, 63: 100863.
- [20] ZHOU Yu, ZHANG Wenjun, KANG Junhao, et al. A problem-specific non-dominated sorting genetic algorithm for supervised feature selection[J]. *Information sciences*, 2021, 547: 841–859.
- [21] LI Yongbo, SOLEIMANI H, ZOHAL M. An improved ant colony optimization algorithm for the multi-depot green vehicle routing problem with multiple objectives[J]. *Journal of cleaner production*, 2019, 227: 1161–1172.
- [22] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. *Advances in engineering software*, 2016, 95: 51–67.
- [23] DONG Hongbin, PAN Yuyao, SUN Jing. High dimensional feature selection method of dual gbest based on PSO[C]//2020 IEEE Congress on Evolutionary Computation. Glasgow: IEEE, 2020: 1–8.
- [24] AGRAWAL R K, KAUR B, SHARMA S. Quantum based Whale Optimization Algorithm for wrapper feature selection[J]. *Applied soft computing*, 2020, 89: 106092.
- [25] 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.
- [26] XIE Qi, CHENG Gengguo, ZHANG Xiao, et al. Feature selection using improved forest optimization algorithm[J]. *Information technology and control*, 2020, 49(2): 289–301.
- [27] MOUSTAKIDIS S P, THEOCHARIS J B. SVM-Fuz-CoC: a novel SVM-based feature selection method using a fuzzy complementary criterion[J]. *Pattern recognition*, 2010, 43(11): 3712–3729.
- [28] HU Qinghua, CHE Xunjian, ZHANG Lei, et al. Feature evaluation and selection based on neighborhood soft margin[J]. *Neurocomputing*, 2010, 73(10/11/12): 2114–2124.
- [29] HUANG Jinjie, CAI Yunze, XU Xiaoming. A hybrid genetic algorithm for feature selection wrapper based on mutual information[J]. *Pattern recognition letters*, 2007, 28(13): 1825–1844.
- [30] ZHU Wenzhi, SI Gangquan, ZHANG Yanbin, et al. Neighborhood effective information ratio for hybrid feature subset evaluation and selection[J]. *Neurocomputing*, 2013, 99: 25–37.
- [31] TABAKHI S, MORADI P, AKHLAGHIAN F. An unsupervised feature selection algorithm based on ant colony optimization[J]. *Engineering applications of artificial intelligence*, 2014, 32: 112–123.
- [32] XUE Bing, ZHANG Mengjie, BROWNE W N. Particle swarm optimisation for feature selection in classification: novel initialisation and updating mechanisms[J]. *Applied soft computing*, 2014, 18: 261–276.

作者简介：



冀若含,硕士研究生,主要研究方向为演化算法、特征选择。



董红斌,教授,博士生导师,中国计算机学会高级研究员,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项目、工信部基础研究项目、黑龙江省自然科学基金项目等。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。发表学术论文 90 余篇,主编教材 2 部。