# 带分形维数约束的轻量级烟花算法特征选择

1st 曾敏广东科技学院计算机科学学院，中国广东省东莞市。电子邮箱：zm6102@163.com

2nd 莫海苗*合肥工业大学管理学院，中国安徽省合肥市。电子邮箱：mhmhfut@163.com

3rd 梁志明广州医科大学附属第五医院药学部，中国广东省广州市。

4th 王华广东科技学院计算机科学学院，中国广东省东莞市。

arXiv:2303.05516v1 [cs.LG] 9 Mar 2023

摘要——**随着机器人学的应用日益广泛，海量视觉数据导致数据维度急剧增加。尽管深度学习方法能够有效处理这些高维视觉数据，但受计算资源限制，在一些特殊场景中仍依赖传统机器学习方法。然而，这些高维视觉数据给传统机器学习方法带来了巨大挑战。因此，我们提出一种带分形维数约束的轻量级烟花算法特征选择方法（LFWA+FD），并将其用于解决机器人视觉驱动的特征选择问题。该"LFWA+FD"通过简化烟花算法并利用分形维数约束选定特征的维度，着重搜索理想的特征子集，从而减少冗余特征和原始数据中的噪声，提高模型准确率。基于 UCI 两个公开数据集的对比实验结果表明，所提出的方法能够有效选出有助于模型推理的特征子集，并去除原始数据中的大量噪声噪声，从而提升模型性能。**

索引词—**视觉数据处理、特征选择、分形维数、烟花算法。**

## 一、引言

随着各行业对机器人需求的持续增长，开发能够学习并适应环境的机器人变得愈发重要 [1]。然而，打造此类机器人的一大挑战在于处理和解读视觉多模态数据中的高维特征 [2]。视觉多模态数据由多种传感器采集，包括摄像头、麦克风和触觉传感器，其中可能包含颜色、纹理、形状、声音和压力等特征。深度学习方法在处理高维视觉数据方面已展现出有效性 [3]，，但由于计算资源有限，在某些场景中仍需依赖传统机器学习方法。尽管如此，由于数据维度增加，传统机器学习技术在处理高维视觉多模态数据时面临重大挑战。

特征选择 [4] 是机器学习中的关键步骤，旨在从较大的特征集合中选取相关特征子集，以提高模型准确率、减少过拟合并降低计算时间。在处理高维数据集时，特征选择尤为重要，因为使用所有可用特征可能导致过拟合，并降低模型的泛化能力。特征选择技术多种多样，包括过滤方法 [5],包装式方法[6], 和嵌入式方法 [7]。

每种方法都有其优缺点，特征选择方法的选择取决于数据集的特点和研究目标。封装法可以提供更高的准确率，但计算成本较高，且可能导致过拟合。过滤法的计算成本较低，但可能会选出无关特征。嵌入法是一种混合方法，能够在封装法和过滤方法之间取得平衡。近年来，由于进化算法 [8]，[9]，（如烟花算法 [10]，）具有较强的搜索能力，能够有效避免陷入局部最优解并优化不可微问题，因此，基于群智能算法的嵌入式特征选择方法受到了广泛关注。

为满足机器人在计算资源有限的场景中获取大量数据的需求，并解决传统机器学习方法无法适用的问题，我们提出了一种用于特征选择的分形维数约束轻量级烟花算法（LFWA+FD）。

本文的贡献如下。

- 我们提出一种嵌入式特征选择框架，通过分形维数近似特征，并利用 Lite 烟花算法搜索特征子集，以减少数据噪声和数据维度，

本研究部分得到了计算机科学与技术重点学科提升计划（GKY-2020CQXK-2）的资助。**曾敏和莫海苗对本研究的贡献相同。**

从而缓解计算资源限制并提高模型准确率。

- 我们提出了一种轻量级烟花算法，通过构建新的爆炸算子（包括爆炸强度和爆炸半径），降低原始烟花算法的参数调优成本。

## II. 相关工作

### *A.* 基于进化算法的特征选择

工程领域通常采用无监督方法来降低特征噪声，因为这类方法具有过拟合风险低、性能高等优点。无监督特征选择（UFS）主要采用三种技术：包装式方法、过滤式方法和嵌入式方法 [4]。包装式方法和嵌入式方法通常依靠进化算法的全局探索和局部挖掘能力来识别最优特征子集。

包装式方法存在若干缺点，包括计算成本高、容易过拟合，以及需要使用特定的聚类算法。根据特征搜索策略，基于包装式方法的无监督特征选择技术可分为三类：序列方法、仿生方法和迭代方法 [4]。在序列方法中，特征按顺序添加或删除，因此这是一种快速且直接的方法。另一方面，仿生方法引入随机性以避免陷入局部最优，通常基于进化算法的搜索能力，例如粒子群优化（PSO） [11]、、蝙蝠算法（BA） [12], 、人工蜂群算法（ABC）和蚁群优化（ACO） [13]。在迭代方法中，无监督特征选择问题被转化为估计问题，从而无需进行组合搜索。

过滤方法通过分析数据本身来确定最相关的特征，无需聚类算法引导搜索。这些方法根据距离、信息量、独立性和显著性测试等数据属性评估特征 [5]。过滤方法在速度和可扩展性方面具有显著优势。

嵌入式技术结合了过滤方法和包装式方法的优点 [7]。这些方法在过滤阶段根据数据的固有属性，使用度量对特征进行排序或选择。在包装阶段，利用特定的聚类算法比较各种特征子集，以确定最佳选择。嵌入式方法分为两个阶段：首先，过滤法去除无关或含噪特征，仅保留重要特征。然后，将剩余特征和样本数据作为输入参数传递给包装式选择方法，以优化选择过程。这种方法能够降低维度并提高分类准确率。

### *B.* 烟花算法的改进工作

烟花算法（FWA） [10], 由 Tan 等人于2010年首次提出，其灵感来自烟花在夜空中自然绽放，形成火花并照亮周围环境的景象。由于收敛速度快、精度高，并能通过火花爆炸平衡局部挖掘与全局探索，烟花算法常用于函数优化 [14], 模式识别 [15],最优调度 [16], 及其他领域。

根据早期研究，原始烟花算法存在一些设计缺陷 [10]。首先，原始烟花算法爆炸时，每个维度产生的位移都相同。这可能导致种群过于同质化，从而限制算法的探索能力。其次，原始烟花算法采用基于距离的选择技术来挑选子代烟花，导致子代烟花选择效率低下且计算成本较高。第三，原始烟花算法包含多个子种群，包括烟花子种群、爆炸火花子种群、爆炸火花子种群和高斯火花子种群。由于这些子种群之间缺乏信息共享和协调机制，烟花算法的局部挖掘和全局探索能力受到限制。

针对原始烟花算法的缺点，该算法的改进工作主要分为两类 [17]。第一类改进工作侧重于增强变异算子、映射规则、选择技术和爆炸算子（如爆炸强度、爆炸半径和位移操作）。通过融合不同启发式算法的优势来增强烟花算法，则是另一类改进工作 [10]。

第一类改进工作采用三种基本改进策略。首先，利用烟花的有效信息（映射规则，或爆炸火花差异向量的优缺点）来增强烟花算法的局部挖掘和全局探索能力（提高种群多样性）。这一增强技术通过提升种群多样性，有效提高了烟花算法的优化潜力 [18],随机映射规则 [19], [20],和爆炸半径 [21], [22], [23], [24]。其次，由于子代选择效率低、成本高，这类改进方法大多针对烟花算法的子代选择策略进行改进 [25], [26], [27], , 例如“随机精英”策略和锦标赛策略。第三，通过子种群之间的信息传递，改进后的烟花算法在子种群之间建立了强大的协同优化机制 [23], [28],[29], [30], [31]。这不仅能有效提升算法的优化能力，还能提高原始烟花算法各子种群间的信息利用效率，并选出优质子种群，引导种群趋向最优解。

第二类改进工作引入了其他进化算法的优势，例如生物地理学——

优化算法（BOA） [8], 和遗传算法（GA） [9] ，以提升混合算法的性能。通过结合这些进化算法的优势，原始烟花算法的局部挖掘和全局探索能力得到了显著提升。

然而，目前大多数研究都侧重于修复烟花算法的缺陷，而非减少该方法中大量的参数 [10]。原始烟花算法在计算爆炸强度时，需要使用一个常数来控制爆炸火花的数量。

## III. 特征选择框架

### A. 轻量级烟花算法

目前大多数研究都侧重于修复烟花算法的缺陷，而非减少该方法中大量的参数 [10]。为计算爆炸半径，原始烟花算法需要先设定最大爆炸半径阈值。原始烟花算法的参数过多，增加了算法调优的成本。此外，未被选入下一代的子代烟花所属个体将被删除，这会严重浪费这些个体的历史信息。我们通过降低算法参数的复杂度，并充分利用未被选中个体的既有数据，构建了一种自适应爆炸半径，从而平衡烟花算法的局部挖掘能力与全局探索能力。

*1*）爆炸强度：原始烟花算法需要预先指定爆炸火花的最大数量，因此参数过多可能会增加使用难度。公式（1）展示了一种计算爆炸强度的新方法，该方法减少了烟花算法中的参数数量。因此，爆炸火花的数量受种群规模以及每个烟花个体的适应度值限制。

$$S_i = \left\lceil M \frac{f_{\max} - f(x_i)}{f_{\max} - f_{\min} + \xi} \right\rceil \tag{1}$$

其中， $S_i$ 是第*i*个烟花 $x_i$的爆炸强度，烟花种群为 $M$。ceil 函数 $\lceil\rceil$ 用于将 $S_i$限制在整数范围 $[1, M]$内。 $\xi$是一个用于避免分母为零的极小常数。在优化最小化目标函数时， $f_{max}$ 和 $f_{min}$分别表示当前种群中最差位置和最佳位置的适应度值。 $f(x_i)$表示第*i*个烟花的适应度值。

*2*）爆炸半径：由于原始烟花算法在选择下一代烟花时会淘汰未被选中的候选个体，因此这些个体的历史数据将被大量浪费。为了平衡烟花算法的局部挖掘和全局探索能力，本文利用各个个体位置的历史数据构建了一种新的爆炸半径。公式（2）和（3）给出了更新后的爆炸半径计算方法（3）。

$$R_i = \begin{cases} pbest_i - x_i, S_i < S_{Avg} \\ x_{CF} - x_i, S_i \geq S_{Avg} \end{cases} \tag{2}$$

$$S_{Avg} = \frac{1}{M} \sum_{i=1}^{M} S_i \tag{3}$$

其中，烟花种群中第*i*个烟花 $x_i$ 的历史最优位置记为 $pbest_i$，且 $i = 1, 2, ....., M$。 $M$表示烟花种群的规模。从 $pbest = \{pbest_1, pbest_2, ..., pesbt_M\}$ 中选出的最佳烟花个体 $x_{CF}$ 通常称为核心烟花（CF）。 $S_{Avg}$ 表示平均爆炸强度，即所有烟花爆炸火花数量的平均值。

*3*）位移操作：第*i*个烟花 $x_i$ 在爆炸时完成位移，随后 $S_i$ 个爆炸火花随之产生。公式（4）给出了位移函数。

$$ES_k = x_i + \beta \times R_i \tag{4}$$

其中， $k = 1, 2, ..., S_i$。 $x_i$是第*i*个烟花的位置， $ES_k$是第<style id='i'>i个子种群中由第*i*个烟花 $x_i$ 爆炸后产生的第*k*个爆炸火花（ES）。 $\beta$服从均匀分布，并在[0, 1]之间随机生成； $R_i$ 是第*i*个烟花 $x_i$的爆炸半径。

LFWA 使用方程（2）至（4）采用 $x_{CF}$ 和$pbest$ ，以创建一种可根据爆炸强度自适应调整的新爆炸半径。如果烟花 $S_{Avg}$ 的平均爆炸强度低于第*i*个烟花 $x_i$的平均爆炸强度，该烟花就会向 $pbest$学习。否则，烟花会从核心烟花 $x_{CF}$中汲取知识。通过纳入 $x_{CF}$和 $pbest$ 来构建新的爆炸半径，LFWA 可以灵活地改变步长。

*4*）变异因子： 为了避免烟花种群过快地趋近局部最优解，LFWA 采用变异机制来保持烟花种群的多样性。方程（5）展示了 LFWA 的变异策略：随机选择烟花的*n*个维度进行高斯变异。烟花经过高斯变异后，会产生高斯火花（GS）。

$$GS_{ij} = x_{ij} \times (N(0,1) + 1) \tag{5}$$

其中 $j = 1, 2, ....., n$。 $N(0, 1)$ 是一个高斯分布函数，其均值和标准差分别为 0 和 1。 $x_i$ 的总维度为 $d$。

*5*）映射规则：为避免出现越界情况，必须根据公式（6）的映射规则处理烟花、爆炸火花和高斯火花位置的每个维度。

$$x_{ij}^{new} = LB + \beta \times (UB - LB) \tag{6}$$

其中，算法的搜索范围分别具有上界和下界，记为 $UB = 1$和 $LB = 0$。

*6)* 选择策略：LFWA 从由烟花 $x=\{x_1,x_2,...,x_M\}$、$pbest$、$x_{CF}$、爆炸火花 $ES$ 和高斯火花 $GS$ 组成的候选集中，采用“精英-随机”技术选择烟花的后代。换句话说，适应度最佳的核心烟花个体将被选中，作为下一代烟花个体的代表，其余烟花个体则随机选取。

### *B.* 基于*LFWA*的特征选择与推理

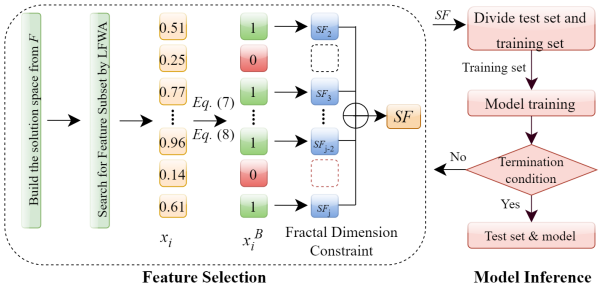


图1. 基于LFWA的特征选择与模型推理框架

特征子集的选择过程可视为一个优化0-1规划问题。特征的总维数也是 $d$。因此，共有 $2^d$种不同的特征子集组合，构成一个解空间。基于LFWA的特征选择方法是一种嵌入式特征选择方法。为了在解空间中找到理想的特征子集，该方法会搜索特征子集所在的位置，从而使模型达到最佳性能。选定特征的维数受分形维数 [32]的约束。

图1展示了基于LFWA的特征选择与模型推理框架。首先，根据特征 $F$构建一个由 $2^d$ 个不同特征子集组成的解空间。然后，基于LFWA的特征选择方法搜索特征子集的位置。换言之，LFWA算法迭代过程中每个烟花个体 $x_i$ 都代表一组决策变量，即特征子集的位置 $x_i^B$。 $x_i^B$ 是 $x_i$ 经由公式（7）二值化后的结果。选定的特征子集由位置 $x_i^B$确定。例如， $x_{ij}^B$=1 表示选中该特征 $F$ 中第*j*维的特征，否则不选中。选定特征的维数受分形维数限制。接下来，将选定特征（SF）划分为测试集和训练集。训练集用于训练模型，直至达到终止条件，例如达到预设的最大迭代次数，此时特征选择结束。使用训练好的模型和测试集进行预测。否则，基于LFWA的特征选择方法将继续搜索新的特征子集。

$$x_{ij}^B=\begin{cases}0, x_{ij}<0.5\\ 1, x_{ij}\geq 0.5\end{cases} \tag{7}$$

其中， $x_{ij}$ 是第*j*维的第*i*个烟花个体 $x_i$的取值，且 $j=1,\ 2,\ ...,\ d$。

分形是指系统的各个部分在某种程度上与整体相似。分形维数（FD） [32] 是描述分形的主要参数，也是一种用于表征分形对相应嵌入空间填充程度的统计量，其大小体现了系统的复杂性。作为反映数据集分布特征的统计量，分形维数已广泛应用于数据挖掘领域。分形维数的计算方法包括盒计数法 [33],Higuchi方法 [34], 小波变换法 [35], 等。盒计数法通过公式（8）计算分形维数。

$$FD=\lim_{n\to\infty}\frac{\ln\sum_i C_{r,i}^2}{\ln r}, r\in[r_1,r_2] \tag{8}$$

其中$C_{r,\ i}$ 是落在第*i*个格点中的数据点数量， $r$ 是格点的半径， $[r_1,r_2]$ 是数据集的无尺度空间。

最后，基于LFWA的特征选择方法对公式（9）的目标函数进行优化。

$$F(x_{ij}^B)=-max(Acc), \sum_{j=1}^{d}x_{ij}^B=\lceil FD\rceil \tag{9}$$

公式（9）中 $\lceil\ \rceil$ 的含义与公式（1）相同。当选定的特征子集作为分类模型（例如K近邻算法（KNN） [36]）的输入时，模型的准确率（Acc）达到最大。

## IV. 实验

### *A.* 参数设置

烟花种群规模设为 5，火花总数设为 50，高斯火花数量设为 5，最大评估次数设为 200，实验独立重复 20 次。

### *B.* 特征约简

表 I 实验中使用的 UCI 数据集说明

| 数据集 | 数据集名称 | Rows | 特征维度 | 类别 |
|---|---|---|---|---|
| 数据集1 | 图像分割 | 2310 | 19 | 7 |
| 数据集2 | Spectf | 267 | 44 | 2 |

数据来源于 UCI数据集*http://archive.ics.uci.edu/ml/datasets .php*。

表 II 分形维数方法的特征约简结果

| 数据集 | 分形维数 | $\lceil FD\rceil$ | 降维率（%） |
|---|---|---|---|
| 数据集1 | 2.3965 | 3 | 84.21 |
| 数据集2 | 2.6869 | 3 | 93.18 |

表 III 对比方法的结果

| 数据集 | 方法 | 特征子集 | 准确率 (%) | △准确率 (%) |
|---|---|---|---|---|
| 数据集1 | FSA+RS | {1, 2, 13} | 84.02 | +9.89 |
| | AFSA+RS | {1, 2, 10} | 87.00 | +6.91 |
| | BGSO+分形维数 | {1, 2, 15} | 77.64 | +16.27 |
| | IDGSO+MFD | {1, 2, 15} | 77.64 | +16.27 |
| | 烟花算法+分形维数 | {2, 12, 16} | 90.62 | +3.29 |
| | **LFWA+分形维数** | {2, 11, 13} | **93.91** | - - |
| 数据集2 | FSA+RS | {3, 20, 38, 43} | 71.23 | +7.76 |
| | AFSA+RS | {19, 26, 42, 43} | 73.08 | +5.91 |
| | BGSO+分形维数 | {2, 26, 41} | 73.08 | +5.91 |
| | IDGSO+MFD | {26, 40, 43} | 73.18 | +5.81 |
| | FWA+分形维数 | {34, 36, 40} | 76.23 | +2.76 |
| | **LFWA+分形维数** | {9, 26, 38} | **78.99** | - - |

表 1 展示了对比实验中使用的 UCI数据集。这些数据集可通过机器人等自动化设备在不同应用场景中获取。

在本小节的实验中，仅使用分形维数方法对原始数据的特征进行降维。特征降维率（$RR$）的实验结果如表 2 所示。 $RR$ 由 RR $= \frac{d-\lceil FD \rceil}{d} \times 100\%$ 计算得出。$d$ 是原始特征的维度。表 2 的结果表明，分形维数方法能够大幅降低原始数据的特征维度，降维率分别为 $RR$=84.21% 和$RR$=93.18%。此外，该方法还能够用更少的特征描述原始数据。

### *C.* 对比实验

在这组实验中，我们使用表 2 中的分形维数来约束选定特征的维度 $SF$。为验证基于分形维数的特征选择方法的有效性，采用以下方法进行对比实验。

- FSA+RS：该方法将人工鱼群算法（FSA）与粗糙集（RS）[37]结合使用。
- AFSA+RS：采用改进人工鱼群算法（AFSA），并结合 RS [38]。
- FSA+RS：采用二进制萤火虫群优化算法（BGSO）[39]，并结合分形维数（FD）。
- IDGSO+MFD：采用改进离散萤火虫群算法（IDGSO），并结合多重分形（MFD）。
- FWA+FD：采用烟花算法（FWA） [10]，并结合分形维数（FD）。
- LFWA+FD（本文方法）：采用 LFWA，并结合分形维数（FD）。

表3中的实验结果表明，与其他对比方法相比，我们的“LFWA+FD”方法表现最佳。与其他方法相比，我们的“LFWA+FD”方法在数据集1上的准确率分别提高了 +9.89%、+6.91%、 +16.27%、 +16.27%和3.29%。同样，我们的“LFWA+FD”方法在数据集2上的准确率提高了 +7.76%、 +5.91%、+5.91%、 +5.81%，以及 +2.76%。因此，这些对比实验结果支持了我们所提出方法的有效性。

### *D.* 消融研究

为分析分形维数约束下基于LFWA的特征选择方法的有效性，我们进行了消融实验。M1是未采用LFWA和分形维数方法的“LFWA+FD”方法。也就是说，M1仅包含KNN分类器，无法进行特征降维，因此将原始特征作为分类器的输入。我们的“LFWA+FD”方法可以实现特征降维，因此将降维后的特征作为分类器的输入。M2方法去除了分形维数，仅保留LFWA和KNN。消融实验结果如表4所示。实验结果表明，我们的方法在数据集1上的性能不如M1和M2，但我们的“LFWA+FD”方法使用的特征更少。在数据集2上，我们的“LFWA+FD”方法比M1高出 +4.85%。但我们的模型表现不如M2，低了-4.04%。M2使用维度更多的特征，以获取更多信息用于模型推理，因此表现更好。总之，我们的“LFWA+FD”方法传输较少的特征用于模型推理，从而降低时间成本，在实时场景中具有重要的应用意义。

## 五、结论

针对原始烟花算法参数众多、调参成本高的问题，我们提出了 LFWA 方法，并将其应用于机器人在不同场景中采集数据后的特征选择问题。基于 UCI 的两个公开数据集进行的对比实验结果表明，所提出的 LFWA 方法优于对比方法。此外，该方法不仅能有效搜索理想的特征子集，还能降低数据维度，并减少原始数据中的大量噪声，从而确保框架的整体性能达到最佳。未来，我们将重点研究烟花算法在特征降噪方面的应用，以及如何对不同传感器在不同场景中采集的多模态数据进行特征融合。

## 参考文献


[1] M. Javaid、A. Haleem、R. P. Singh 和 R. Suman，《机器人技术在推动工业4.0实施方面的显著能力》，认知机器人学，第 1 卷，第 58–75 页，2021。

[2] M. B. Alatise 和 G. P. Hancke，《自主移动机器人与传感器融合方法面临的挑战综述》，*IEEE Access*，第 8 卷，第 39 830–39 846 页，2020。

[3] A. Esteva、K. Chou、S. Yeung、N. Naik、A. Madani、A. Mottaghi、Y. Liu、E. Topol、J. Dean 和 R. Socher，《深度学习赋能的医学计算机视觉》，*NPJ*数字医学，第 4 卷，第 1 期，第 5 页，2021。

[4] S. Solorio-Fern´andez、J. A. Carrasco-Ochoa 和 J. F. Mart´ınez-Trinidad，《无监督特征选择方法综述》，*Artificial Intelli- gence Review*，第 53 卷，第 2 期，第 907–948 页，2020。

表 IV 原始特征与降维特征的比较结果

| 数据集 | 方法 | 特征子集 | 特征维数 | 准确率 (%) | Δ准确率（%） |
|---|---|---|---|---|---|
| 数据集1 | M1 | {1, 2, 3, 4, ..., *d*-1，*d*} | *d* | 95.72 | -1.81 |
| | M2 | {2, 4, 6, 8, 11, 14, 16} | 7 | **97.05** | -3.14 |
| | LFWA+分形维数 | {2, 11, 13} | 3 | 93.91 | - - |
| 数据集2 | M1 | {1, 2, 3, 4, ..., *d*-1,*d*} | *d* | 74.14 | +4.85 |
| | M2 | {2, 5, 6, 7, 11, 13, 15, 16, 18, 21, 23, 26 28, 30, 31, 32, 34, 35, 36, 38, 40, 44} | 22 | **83.03** | -4.04 |
| | LFWA+分形维数 | {9, 26, 38} | 3 | 78.99 | - - |


[5] A. Bommert、X. Sun、B. Bischl、J. Rahnenf¨uhrer 和 M. Lang，《高维分类数据特征选择过滤方法基准测试》，计算统计与数据分析，第 143 卷，第 106839 页，2020。[6] W. L. Al-Yaseen、A. K. Idrees 和 F. H. Almasoudy，《基于差分进化和极限学习机的入侵检测系统包裹式特征选择方法》，模式识别，第 132 卷，第 108912 页，2022。[7] B. H. Nguyen、B. Xue 和 M. Zhang，《数据挖掘中特征选择的群体智能方法综述》，群体与进化计算，第 54 卷，第 100663 页，2020。[8] B. Zhang、M.-X. Zhang 和 Y.-J. Zheng，《一种混合生物地理学优化与烟花算法》，载于*2014*年*IEEE*进化计算大会（*CEC*）。IEEE，2014年，第 3200–3206 页。[9] K. Łapa 和 K. Cpałka，《混合遗传-烟花算法在控制器结构及参数选择中的应用》，载于信息系统架构与技术：第*36*届国际信息系统架构与技术会议论文集——*ISAT 2015*——第一部分。Springer，2016年，第 111–123 页。[10] J. Li 和 Y. Tan，《烟花算法综合综述》，*ACM*计算调查 *(CSUR)*，第 52 卷，第 6 期，第 1–28 页，2019。[11] X.-F. Song 、 Y. Zhang 、 D.-W. Gong 和 X.-Z. Gao，《一种基于相关性引导聚类和粒子群优化的高维数据快速混合特征选择方法》，*IEEE*控制论汇刊，2021。[12] H. Yu、N. Zhao、P. Wang、H. Chen 和 C. Li，《混沌增强同步蝙蝠优化器》，应用数学建模，第 77 卷，第 1201–1215 页，2020。[13] M. Ghosh、R. Guha、R. Sarkar 和 A. Abraham，《一种基于蚁群优化的包裹-过滤式特征选择技术》，《神经计算与应用》，第 32 卷，第 12 期，第 7839–7857 页，2020。[14] R. Cheng、Y. Bai、Y. Zhao、X. Tan 和 T. Xu，《一种通过信息交换改进的函数优化烟花算法》，*Knowledge- Based Systems*，第 163 卷，第 82–90 页，2019。[15] M. Zhang、Y. Yuan、R. Wang 和 W. Cheng，《基于融合特征约简和烟花算法优化多类支持向量机的混合控制图模式识别》，模式分析与应用，第 23 卷，第 1 期，第 15–26 页，2020。[16] L. He、W. Li、Y. Zhang 和 Y. Cao，《一种用于序列相关准备时间流水车间调度的离散多目标烟花算法》，群体与进化计算，第 51 卷，100575，2019年，第 。[17] Z. Zhigang、L. Zhimei、M. Haimiao 和 Z. Min，《烟花算法研究综述》，*arXiv*预印本 *arXiv:2208.06474*，2022。[18] J. Li 和 Y. Tan，《基于定向变异的烟花算法》，载于*2015*年*IEEE*进化计算大会（*CEC*）。IEEE，2015年，第 1265–1271 页。[19] S. Cheng、Q. Qin、J. Chen、Y. Shi 和 Q. Zhang，《烟花算法求解决策空间和目标空间发生偏移的问题之分析》，《国际群体智能研究杂志》*(IJSIR)*，第 6 卷，第 2 期，第 52–86 页，2015。[20] X. Ye、J. Li、B. Xu 和 Y. Tan，《烟花算法中的哪种映射规则更适用于大规模优化》，载于*2018*年*IEEE*进化计算大会（*CEC*）。IEEE，2018年，第 1–8 页。[21] J. Li、S. Zheng 和 Y. Tan，《自适应烟花算法》，载于*2014*年*IEEE*进化计算大会（*CEC*）。IEEE，2014年，第 3214–3221 页。[22] S. Zheng、A. Janecek、J. Li 和 Y. Tan，《烟花算法中的动态搜索》，载于*2014*年*IEEE*进化计算大会（*CEC*）。IEEE，2014年，第 3222–3229 页。[23] S. Zheng、J. Li、A. Janecek 和 Y. Tan，“一种烟花算法协同框架”，*IEEE/ACM*计算生物学与生物信息学汇刊，第14卷，第1期，第27–41页，2015年。[24] H. Pekdemir 和 H. R. Topcuoglu，“增强用于动态优化问题的烟花算法”，载于*2016 IEEE*进化计算大会（*CEC*）。IEEE，2016年，第4045–4052页。[25] Y. Pei、S. Zheng、Y. Tan 和 H. Takagi，“近似方法对增强烟花算法影响的实证研究”，载于*2012 IEEE*系统、人类与控制论国际会议（*SMC*）。IEEE，2012年，第1322–1327页。[26] Y. Jun、H. Takagi 和 T. Ying，“采用基于距离的排斥策略进行多模态优化的烟花算法”，载于*2019 IEEE*进化计算大会（*CEC*）。IEEE，2019年，第2215–2220页。[27] Y. Chen、F. He、X. Zeng、H. Li 和 Y. Liang，“烟花算法的爆炸操作助力珊瑚礁优化实现多模态医学图像配准”，《工程人工智能应用》，第102卷，文章编号104252，2021年。[28] Q. Lv、J. Shi、H. Shi 和 C. Jiang，“一种用于求解本体元匹配的新型紧凑型烟花算法”，《应用智能》，第1–24页，2022年。[29] X. Liu 和 X. Qin，“一种邻域信息利用烟花算法及其在交通流预测中的应用”，《应用专家系统》，第183卷，文章编号115189，2021年。[30] J. Li 和 Y. Tan，“通过动态资源分配和基于适应度的拥挤规避策略增强烟花算法中的交互”，载于*2016 IEEE*进化计算大会（*CEC*）。IEEE，2016年，第4015–4021页。[31] Q. Li、Z. Ma、Y. Zhang、S. Dong、Y. Li 和 M. Lu，“Tan”，*R. Varma*、*D. Huang*、青光眼高级成像研究组，《利用光学相干断层扫描绘制黄斑亚结构以诊断青光眼》，*ARVO*，2006年。[32] S. R. Nayak、J. Mishra 和 G. Palai，“通过分形维数分析表面粗糙度：综述”，《图像与视觉计算》，第89卷，第21–34页，2019年。[33] G.-B. So、H.-R. So 和 G.-G. Jin，“改进用于分形维数估计的盒计数算法”，《模式识别快报》，第98卷，第53–58页，2017年。[34] H. Siamaknejad、W. S. Liew 和 C. K. Loo，“用于确定专注度估计最佳脑电图电极放置的分形维数方法”，《神经计算与应用》，第31卷，第953页，2019年，第945页。[35] M. Sharma、R. B. Pachori 和 U. R. Acharya，“一种利用解析时频柔性小波变换和分形维数表征癫痫发作的新方法”，《模式识别快报》，第94卷，第172–179页，2017年。[36] Z. Pan、Y. Wang 和 Y. Pan，“一种基于判别类的局部自适应k近邻算法”，《基于知识的系统》，第204卷，文章编号106185，2020年。[37] G. T. Reddy、M. P. K. Reddy、K. Lakshmanna、D. S. Rajput、R. Kaluri 和 G. Srivastava，“用于心脏病诊断的混合遗传算法与模糊逻辑分类器”，《进化智能》，第13卷，第185–196页，2020年。[38] X. Y. Luan、Z. P. Li 和 T. Z. Liu，“一种基于粗糙集和改进人工鱼群算法的新型属性约简算法”，《神经计算》，第174卷，第JAN.22PT.A期，第522–529页，2016年。[39] K.、N.、KrishnanandD. 和 Ghose，“用于同时捕获多模态函数多个局部最优点的萤火虫群优化”，《群体智能》，2009年。