

文章编号:1671-6833(2024)05-0052-09

基于改进多因子优化蝙蝠算法的网络入侵检测方法

张震, 张思源, 田鸿朋

(郑州大学 电气与信息工程学院, 河南 郑州 450001)

摘要: 针对高维网络数据存在大量冗余和不相关的特征导致入侵检测准确率低的问题, 提出了一种改进的多因子优化蝙蝠算法(IMFBA)用于数据特征选择, 筛选出具有最大信息量的特征子集, 提高网络入侵检测精度。首先, 在多因子优化框架下设计全局特征选择任务和局部特征选择任务, 并通过基于蝙蝠算法所设计的选型交配和垂直文化传播算子实现不同任务间的信息共享, 从而帮助全局特征选择任务更快锁定最优解空间, 提高算法收敛速度和稳定性。其次, 通过将反向学习策略和差分进化引入蝙蝠算法, 重新设计算法初始解选择阶段及个体更新过程, 弥补其缺少突变机制的不足, 增强解的多样性, 帮助算法摆脱局部最优。最后, 提出一种自适应参数调整策略, 根据潜在最优解质量决定其指导个体更新的权重, 避免在多任务特征选择过程中出现知识负迁移现象, 实现全局搜索与局部开发之间的平衡。实验结果表明: IMFBA 所选特征子集对网络入侵数据集 KDD CUP 99 和 NSL-KDD 分类结果的准确率分别为 95.37% 和 85.14%, 相较于完整特征集提升了 3.01 个百分点和 9.78 个百分点。IMFBA 算法能选择更高质量特征子集并提升网络入侵检测准确率。

关键词: 入侵检测; 网络安全; 特征选择; 蝙蝠算法; 多因子优化

中图分类号: TP181

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2024.05.015

入侵检测系统 (intrusion detection system, IDS)^[1] 作为计算机网络安全领域的一种主动安全防护技术, 广泛部署在各种网络安全防护体系中, 感知恶意入侵行为, 并采取快速有效的对策, 以防止系统被进一步地入侵和传播。但众多的攻击类型和网络流量特征对入侵检测构成了另一个挑战^[2], 冗余和不相关的特征会影响入侵检测系统对网络攻击的分类性能。因此, 为了解决该问题, 众多学者研究和开发了许多方法来提高 IDS 的检测精度和性能。

特征选择作为数据挖掘和机器学习中重要的预处理手段被广泛应用于网络入侵检测中, 其通过从描述数据的完整特征集中筛选出具有最大信息量的特征子集以达到降维和提高分类性能的目的。根据算法和数据处理方式的不同, 可将特征选择方法分为 3 类: 过滤式 (filter)^[3]、嵌入式 (embedded)^[4] 及包裹式 (wrapper)^[5]。过滤式特征选择依赖于某些统计学定义, 滤除不满足标准的特征, 常见的有基于

相关性的特征选择 (correlation-based feature selection, CFS) 和最大相关最小冗余 (max-relevance and min-redundancy, mRMR) 等, 但由于其依赖统计特性的关系, 导致所得特征子集分类准确性普遍不高; 嵌入式特征选择将特征挑选融入分类过程, 特征选择过程无须人为参与, 如基于深度学习的特征选择、树算法重要性 (tree-based feature importance) 等, 但模型缺乏可解释性; 包裹式特征选择将分类结果作为子集评价指标, 能够达到较高的分类准确性, 常见的如正向选择 (forward selection)、群体智能优化算法等。

本文采用基于群体智能优化的包裹式特征选择算法。特征选择最优解问题作为典型的 NP (non-deterministic polynomial) 问题从 n 维数据集中寻找最优解的复杂度高达 2^n 。因此, 常利用群体智能优化算法种群演化多样性与行为指向性的特点^[6], 近似求解特征选择优化问题, 以应对维度灾难 (curse of dimensionality)。如粒子群优化算法 (particle

收稿日期: 2024-03-27; 修订日期: 2024-05-06

基金项目: 国家重点研发计划重点专项 (2018XXXXXXXXXX); 河南省重大公益专项 (201300311200); 河南省重点研发专项 (231111211600)

作者简介: 张震 (1966—), 男, 河南郑州人, 郑州大学教授, 博士, 博士生导师, 主要从事图像处理、模式识别的研究, Email: zhangzhen66@163.com。

引用本文: 张震, 张思源, 田鸿朋. 基于改进多因子优化蝙蝠算法的网络入侵检测方法 [J]. 郑州大学学报 (工学版), 2024, 45 (5): 52-60, 94. (ZHANG Z, ZHANG S Y, TIAN H P. Network intrusion detection method based on improved multifactorial optimization bat algorithm [J]. Journal of Zhengzhou University (Engineering Science), 2024, 45 (5): 52-60, 94.)

swarm optimization, PSO)^[7]、蚱蜢优化算法 (grasshopper optimization algorithm, GOA)^[8]、差分算法 (differential evolution, DE)^[9]、蝙蝠算法 (bat algorithm, BA)^[10]等。根据不同特征选择目标,研究者对群体智能优化算法提出了改进工作,如徐国天等^[11]提出了一种利用改进哈里斯鹰算法进行特征选择的恶意软件检测方法,实验结果证明,所提出的方法取得了很好的检测结果;Li 等^[12]将 K-means 算法与蝙蝠算法相结合进行特征选择,在物联网入侵检测上取得了不错的效果;Abbasi 等^[13]通过设计特征分组策略改进粒子群优化算法进行特征选择,解决勒索软件检测问题。但是,这些方法仍存在易陷入局部最优、收敛速度慢等问题,导致其不能有效选择最优特征来高效检测网络中的恶意流量。

针对以上问题,本文提出了一种改进多因子优化蝙蝠算法 (improved multi-factorial optimization bat algorithm, IMFBA) 进行特征选择。采用基于反向学习策略的初始化和突变机制,增强算法中解的多样性和算法收敛速度。在迭代过程中应用改进的二进制差分进化算子增强算法的局部搜索能力,避免算法陷入局部最优。采用多因子优化范式^[14]改进 BA 算法,通过设计两个相关的特征选择任务,实现任务间的知识转移,帮助算法提升全局搜索能力,从而找到更好的特征子集。

1 相关工作

1.1 蝙蝠算法

BA 是一种实现全局优化的元启发式算法,灵感源于微型蝙蝠的回声定位能力,由 Yang^[15]于 2010 年提出,被研究人员广泛地使用和研究。例如,Ye 等^[16]通过引入曲线递减和速度加权的局部搜索算子提升了蝙蝠算法的搜索精度;Yu 等^[17]提出了一种混沌增强 BA 解决全局优化问题,以提高算法的稳定性和收敛速度;Bangyal 等^[18]利用 Torus walk 改进 BA 以提升算法的局部搜索能力,避免陷入局部最优。

特征选择作为离散优化问题,特征的选择与否更适合用二进制数值表示,并且二进制编码相较于实数编码更为简单和高效。因此,在本文中使用 BA 的改进版本二进制 BA (binary bat algorithm, BBA)^[19]。在 BBA 中描述了蝙蝠在 d 维二进制空间中的运动,在第 t 次迭代中每只蝙蝠以速度 $\mathbf{v}_i^t = (v_{i1}^t, v_{i2}^t, \dots, v_{id}^t)$,在位置 $\mathbf{x}_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{id}^t)$ 随机飞行,其具有静态的频率 f_i 、响度 A_i^t 、脉冲发射率 r_i^t 。蝙蝠的位

置定义为所选特征子集,并通过适应度函数衡量其质量。 \mathbf{x}_i^t 中某一维值为 0 时代表某个特征不存在于特征子集中,而为 1 时表示该特征存在于特征子集中。用所选特征训练分类器后,适应度函数将是分类器的评价指标。

在每次迭代过程中,算法将更新每个个体的内部变量,数学公式如下:

$$f_i = f_{\min} + (f_{\max} - f_{\min}) \cdot \lambda; \tag{1}$$

$$v_{ij}^{t+1} = v_{ij}^t + (x_{ij}^t - g_j) \cdot f_i; \tag{2}$$

$$x_{ij}^{t+1} = \begin{cases} 0, & \text{rand}(0,1) < S(v_{ij}^t); \\ 1, & \text{rand}(0,1) \geq S(v_{ij}^t). \end{cases} \tag{3}$$

式中: $S(\cdot)$ 为 Sigmoid 函数; $\mathbf{g} = (g_1, g_2, \dots, g_d)$ 为当前种群当中 n 个个体中的最优解。随着迭代的进行,响度 A_i^t 、脉冲发射率 r_i^t 必须进行相应的更新,更新规则如下:

$$A_i^{t+1} = \alpha A_i^t; \tag{4}$$

$$r_i^{t+1} = r_i^0 (1 - e^{-\gamma t}). \tag{5}$$

式中: α, γ 为常数且 $0 < \alpha < 1, \gamma > 0$ 。若 r_i^t 小于随机数 $\text{rand}(0,1)$,则就会使用随机游走策略在局部生成每个个体的新解。

$$\mathbf{x}_{\text{new}} = \mathbf{x}_{\text{old}} + \boldsymbol{\varepsilon} A_0^t \tag{6}$$

式中: $\boldsymbol{\varepsilon}$ 为均匀分布在 $[-1,1]$ 的随机向量; A^t 为第 t 次迭代时种群所有个体的响度平均值。

1.2 多因子优化

多任务优化是研究同时解决多个优化问题从而提高解决每个问题的能力,其假设在解决某问题时,存在一些共同的有用知识,有利于解决其他相关联的任务。2015 年,Gupta 等^[20]提出了一种新的多任务优化范式即多因子优化 (multifactorial optimization, MFO),并据此设计了多因子优化算法,该算法通过选型交配 (assortative mating) 和垂直文化传播 (vertical cultural transmission) 等算子实现不同任务间的知识共享,其流程如算法 1 所示。在实践中该方法已被成功用于解决各种不同的优化问题。例如,Feng 等^[21]提出基于多因子范式改进的 PSO 和 DE 算法,经实验证明该算法是 MFO 的一个有效和高效的实现方法。Osaba 等^[22]提出改进的多因子进化算法,有效避免了迭代过程中不同任务间负反馈的问题,并成功应用于解决离散优化问题。

算法 1 选型交配和垂直文化传播。

- ① 从当前种群 P 中随机选择两个父代样本 p_a, p_b ;
- ② 生成一个随机数 $\text{rand}(0,1)$;
- ③ if ($\tau_a == \tau_b$) or ($\text{rand}(0,1) < rmp$) then
- ④ 父代 p_a, p_b 杂交得到两个子代 c_a, c_b ;

- ⑤ else
- ⑥ 父代 p_a 发生轻微突变产生子代 c_a ;
- ⑦ 父代 p_b 发生轻微突变产生子代 c_b ;
- ⑧ End if
- ⑨ if (‘c’有两个父代) then
- ⑩ 生成一个 0 到 1 的随机数 $\text{rand}(0,1)$;
- ⑪ if ($\text{rand}(0,1) < 0.5$) then
- ⑫ ‘c’技能因素为 τ_a ;
- ⑬ else
- ⑭ ‘c’技能因素为 τ_b ;
- ⑮ else
- ⑯ ‘c’模仿其单个父代样本的技能因素;
- ⑰ End if.

MFO 创造了一个多任务的环境,进化出一个单一的个体群体来同时解决多个相关的任务,其中每个任务作为一个独特因素来影响种群的进化。但不同的任务可能具有不同的属性,为解决这一问题,个体被表示在统一的搜索空间中,MFO 通过计算个体的技能因素将种群划分为不同的组,每个个体被分配到与它表现最好的任务相对应的组中。

为了评估种群中的个体,MFO 在解决 k 个任务的种群 P 中对个体 p_i 定义了如下属性。

(1) 因子代价。个体 p_i 在任务 T_j 上的因子代价 Ψ_j^i 定义为其对特定任务上的适应度值。

(2) 因子等级。个体 p_i 在任务 T_j 上的因子等级 r_j^i 为因子代价按升序排列后种群列表的索引值。

(3) 技能因素。个体 p_i 的技能因素 τ_i 定义为个体在所有任务中表现最优的任务的索引,即 $\tau_i = \text{argmin}_{j \in \{1,2,\dots,k\}} \{r_j^i\}$ 。

(4) 标量适应度。个体 p_i 的标量适应度定义为 $\phi_i = 1/\min\{r_1^i, r_2^i, \dots, r_k^i\}$ 。

2 本文方法

2.1 多因子蝙蝠算法

一般情况下,网络入侵检测数据集是极度不平衡的,在尽可能不损害多数类分类性能的情况下,保留对少数类分类有利的特征以提高少数类样本的分类能力,这是本文所设计算法的主要目的之一。在应用多因子优化范式处理该问题时,所设计任务的相关性是影响算法性能的一个重要因素之一,不同的任务在最优解方面应满足一定的共性和互补性。在本文中,基于不同类别的分类性能设计不同任务。任务 1 致力于选择有助于提升整个数据集分类性能的特征子集;任务 2 倾向于选择有利于少数类攻击流量分类的特征子集。由于任务 2 是任务 1 的一部

分,因此,两个任务具有一定程度的共通性,两个任务在迭代的过程中共享信息,以寻找到更好的特征子集。

而应用多因子优化范式改进蝙蝠算法的关键问题是 Gupta 等^[20]所提出的多因子优化算法与传统的群体智能优化算法在解的更新迭代机制方面有很大的差异,尤其是选型交配作为个体间进行多任务隐形知识转移的关键组成部分,需要新的设计方案。具体来说,定义了随机配对概率 rm_p 来控制选型交配的过程。如果一个随机数小于 rm_p ,式(7)将用于更新速度。否则,使用式(2)更新速度。

$v_{ij}^{t+1} = v_{ij}^t + (x_{ij}^t - g_j) \cdot f_i + (x_{ij}^t - g_j^*) \cdot f_i \cdot \beta_i$ 。(7)
式中: $\mathbf{g}^* = (g_1^*, g_2^*, \dots, g_d^*)$ 表示第 t 次迭代时与个体 i 执行不同任务的个体中的全局最优解; f_i 由式(1)定义; $\beta_i = (\beta_1, \beta_2, \dots, \beta_n)$ 为控制 \mathbf{g}^* 对个体更新影响力的系数。Yang 等^[23]提出了基于粒子个体进化信息的自适应参数调整策略,降低了优化器对于新引入参数的敏感性,经过实验证明,通过应用自适应参数调整策略,算法在优化问题上表现更好。因此,本文设计了自适应调节参数 β_i ,以控制式(7)中 \mathbf{g}^* 对每个个体更新的影响。具体而言,如果指导个体 i 更新的两个最优解 \mathbf{g}, \mathbf{g}^* 的适应度值相差较大,则 β_i 应该很小,以防止不同任务间出现负迁移,导致算法性能受损。若其适应度值相差较小,则 β_i 应该较大,以增强 \mathbf{g}^* 对个体更新的影响,以更好实现不同任务间的知识共享,同时避免个体过快地靠近 \mathbf{g} 。具体公式如下:

$$A = |\text{Fit}_{\tau_i}(\mathbf{g}) - \text{Fit}_{\tau_i}(\mathbf{x}_i)|; \quad (8)$$

$$B = |\text{Fit}_{\tau_i}(\mathbf{g}^*) - \text{Fit}_{\tau_i}(\mathbf{x}_i)|; \quad (9)$$

$$\beta_i = 0.6 - 0.2 \left(\frac{\pi - \arccos\left(1 - 2 \cdot \frac{\min(A,B)}{\max(A,B)}\right)}{\pi} \right). \quad (10)$$

式中: $\text{Fit}(\cdot)$ 为适应度函数,通过本文所设计的参数调整策略,可以在算法迭代过程中自适应地调整每个个体的 β_i 。在早期阶段,个体间的差异较大,通过这种设置能帮助个体快速地寻找到有潜力的区域;而在后期阶段,当个体间差异变小时能够有效地开发有潜力的区域,避免陷入局部最优。这符合对个体更新过程的期望。

而垂直文化传播过程与算法 1 中保持一致,更新后的个体随机模仿指导其更新的个体的某项任务,从而实现不同任务间解决方案的交换。通过垂直文化传递,算法中的任务通过不断地从其他任务中获得有希望的解决方案,从而能够找到更好的解

决方案。算法2中描述了包含选型交配和垂直文化传播算子的多因子蝙蝠算法的迭代过程。

算法2 多因子蝙蝠算法。

输入:个体数量 NP 、维度 D 、任务数量 K 、最大迭代次数 N_i ;

输出:所有任务的最优解。

- ① 初始化种群 NP ;
- ② 计算每个个体对所有任务的适应度值;
- ③ 计算每个个体的技能因素 τ ;
- ④ 更新所有任务的全局最优解;
- ⑤ while $1 \leq t \leq NP$ do
- ⑥ for $i = 1$ to NP do
- ⑦ 根据式(1)更新 f_i ;
- ⑧ if ($\text{rand}(0,1) < rmp$) do
- ⑨ 根据式(7)和式(3)更新 v_i, x_i ;
- ⑩ 根据垂直文化传播选择新个体执行的任务;
- ⑪ else
- ⑫ 根据式(2)和式(3)更新 v_i, x_i ;
- ⑬ End if
- ⑭ if $r_i' < \text{rand}(0,1)$ then
- ⑮ 根据式(6)更新 x_i ;
- ⑯ End if
- ⑰ 计算更新后新解 x_{new} 的适应度函数 $\text{Fit}(x_{\text{new}})$;
- ⑱ if $\text{Fit}(x_i) \leq \text{Fit}(x_{\text{new}})$ and $\text{rand}(0,1) < A_i^t$ then
- ⑲ $x_i = x_{\text{new}}$;
- ⑳ $\text{Fit}(x_i) = \text{Fit}(x_{\text{new}})$;
- ㉑ 根据式(4)、式(5)更新 A_i^t, r_i^t ;
- ㉒ End if
- ㉓ if $\text{Fit}(g) \leq \text{Fit}(x_{\text{new}})$ then
- ㉔ $g = x_{\text{new}}$;
- ㉕ $\text{Fit}(g) = \text{Fit}(x_{\text{new}})$;
- ㉖ End if
- ㉗ End for
- ㉘ $t = t + 1$;
- ㉙ End while。

2.2 突变机制

2.2.1 反向学习

反向学习 (opposition-based learning, OBL)^[24] 是一种优化策略,其提供了一种高效的双向并发搜索方式。根据当前解 x 生成其反向解 \tilde{x} ,并根据其适应度选择两者中的最佳解,以提高算法解的多样性和增强种群中的个体。其定义如下:

$$\tilde{x} = (lb + ub) - x. \quad (11)$$

式中: lb 和 ub 为 x 的下界和上界值,例如,在特征选

择过程中 $lb = 0, ub = 1$ 。将其推广到多维搜索空间,其表示如下:

$$\tilde{x}_j = (lb_j + ub_j) - x_j, j \in \{1, 2, \dots, d\}. \quad (12)$$

在本文所设计的算法中,将 OBL 应用于算法的初始化阶段,这是因为初始化阶段的解是随机形成的,可能初始解与全局最优解相差甚远,从而导致算法的收敛速度过慢。通过在初始阶段应用 OBL,帮助算法在初始阶段尽可能找到更有希望的解。与此同时,为了避免算法在迭代过程中陷入局部最优解,设计了基于 OBL 的解更新机制,若 g 在给定的 $Miter$ 次迭代中没有变化,则采用 OBL 更新种群中的所有解,以避免算法陷入局部最优。

2.2.2 二进制差分突变

在每次迭代更新位置后,本文将差分进化算法的突变机制应用于所提出的算法中,进一步增强算法跳出局部最优解的能力。由于传统的差分进化算法只能解决连续优化问题,在本文所解决的特征选择问题中,需要设计一种适用于多任务的二进制差分进化算法。

在本文所设计的算法中,个体的位置由二进制字符串表示,因此通过逻辑操作来实现突变机制,其中“+”表示或运算,“ \oplus ”表示异或运算,则个体突变方式如下:

$$x_{ij}^{t+1} = \begin{cases} x_{r1}^t + (x_{r2}^t \oplus x_{r3}^t), & \text{rand}(0,1) < F; \\ x_{r1}^t, & \text{rand}(0,1) \geq F. \end{cases} \quad (13)$$

对于个体 i 在第 t 次迭代中,如果 $\text{rand}(0,1) < P$ 且与个体 i 优化相同任务的个体不少于 4 个,进行该突变操作。其中, $r1, r2, r3$ 为随机选择的与 i 具有相同技能因素的个体; F 为收缩系数,且 $F \in (0,1)$,通过该系数决定个体在该突变算子中的更新方式。

2.3 本文算法整体流程

本文算法的流程如图1所示,通过两个步骤完成特征选择过程。步骤1中,根据数据集中不同类别样本所占百分比确定哪些类为少数类,并以少数类的分类准确率为评价指标构建任务2的适应度函数,同时任务1以整体准确率构建适应度函数。步骤2中,首先将初始化种群的个体随机分配给两个任务,生成两个子群,在每个子群中通过 OBL 对初始解进行优化以提高初始解的质量。然后通过本文所设计的多因子优化蝙蝠算法完成两个任务间的知识转移,从而通过任务2帮助任务1选择出更好的特征子集,同时在该过程中利用基于 OBL 的解更新机制和二进制差分进化算子来避免算法陷入局部最优,保持种群的多样性。其中,步骤2的输入为步骤

1 中生成的两个任务,输出为任务 1 所选的特征子集。

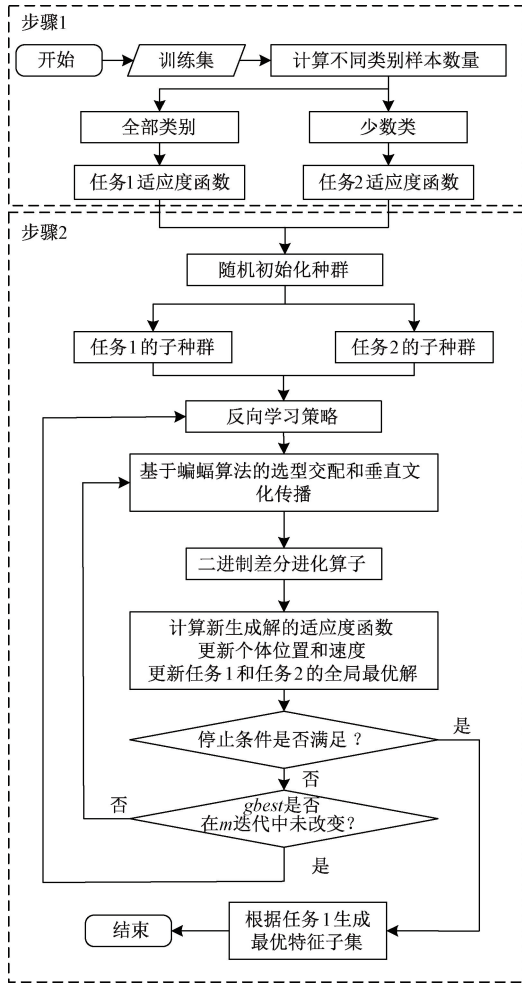


图 1 IMFBA 框架
Figure 1 IMFBA framework

3 实验与分析

在本节中,通过几个实验来评估所提算法在特征选择过程中的有效性。本文所有实验均在配备英特尔酷睿 i7-13700KF 芯片和 32 GB 运行内存的计算机上进行。评价指标:准确率 Acc 、精确率 P 、检出率 DR 、 $F1$ 值、虚警率 FPR 等,所有评价指标的数学含义详见文献[25]。

3.1 数据集和适应度函数

本文采用被广泛应用于评估各种入侵检测方法的 KDD CUP 99 数据集的下采样子集和 NSL-KDD 数据集^[26]进行实验来验证算法在网络入侵检测方面的有效性。表 1、表 2 总结了训练数据集和测试数据集中不同种类数据的分布情况。由表 1、表 2 可以看出,Probe、R2L、U2R 这些恶意流量数据在数据集中占比极小,但这些攻击流量的正确分类却很重要。

表 1 KDD CUP 99 数据集分布情况
Table 1 KDD CUP 99 dataset distribution

类别	训练数据集		测试数据集	
	数量	占比/%	数量	占比/%
Normal	17 129	29.99	12 183	32.52
DoS	35 700	62.51	21 705	57.94
Probe	3 107	5.44	1 880	5.02
R2L	1 126	1.97	1 468	3.92
U2R	52	0.09	228	0.61

表 2 NSL-KDD 数据集分布情况
Table 2 NSL-KDD dataset distribution

类别	训练数据集		测试数据集	
	数量	占比/%	数量	占比/%
Normal	67 343	53.45	9 711	43.07
DoS	45 927	36.45	7 458	33.08
Probe	11 656	9.25	2 421	10.73
R2L	995	0.79	2 754	12.22
U2R	52	0.04	200	0.89

在本研究中,采用决策树算法作为分类器来评价所选的特征子集的性能。式(14)和式(15)为特征选择过程中任务 1 和任务 2 的适应度函数:

$$Fit_1 = \alpha \cdot ACC + (1 - \alpha) \frac{|(D - S)|}{D}; \quad (14)$$

$$Fit_2 = \alpha \cdot ACC_{\min} + (1 - \alpha) \frac{|(D - S)|}{D}。 \quad (15)$$

式中: ACC 、 ACC_{\min} 分别为整体分类准确率和少数类分类准确率; D 为数据集的特征总数; S 为所选特征的数量; α 为反映分类正确率和所选特征数量权重的参数。

3.2 参数设定

表 3 所示为本文算法的实验参数设置情况,由于随机配对概率 rpm 和给定迭代次数 $Miter$ 是本文所设计算法特征选择过程中的两个关键参数,在图 2 中通过对两个参数不同值的组合的实验来评估其影响。其中对 rpm 测试了 5 个值(0.4, 0.5, 0.6, 0.7, 0.8),对 $Miter$ 测试了 5 个值(15, 20, 25, 30, 35),共 25 个参数组合。结果表明,在 rpm 为 0.6、 $Miter$ 为 30 时,实验结果最佳。此外,种群大小和最大迭代次数也是影响特征选择的重要参数,理论上两者越大越可能在迭代过程中找到最优解。在本文所设计的实验中,综合考虑算法性能和计算成本,将种群规模和最大迭代次数均设置为 100。

3.3 本文方法的有效性

本节将本文所提出的方法(IMFBA)与传统蝙蝠算法(BA)、本文设计的多因子蝙蝠算法(MFBA)、应用本文设计的突变机制改进的蝙蝠算

表 3 参数设置

Table 3 Parameter settings

参数	数值
种群规模	100
最大迭代次数	100
α	0.99
Miter	30
rmp	0.6





图 2 两个参数 25 种组合的实验结果

Figure 2 Results of 25 combinations of two parameters


表 4 入侵检测性能对比

Table 4 Performance comparison of Intrusion Detection

算法	准确率 <i>Acc</i>		精确率 <i>P</i>		检出率 <i>DR</i>		<i>F1</i>		虚警率 <i>FPR</i>	
	KDD CUP 99	NSL-KDD	KDD CUP 99	NSL-KDD	KDD CUP 99	NSL-KDD	KDD CUP 99	NSL-KDD	KDD CUP 99	NSL-KDD
FULL	92.36	75.36	97.08	88.17	89.12	61.14	92.93	72.21	0.93	5.84
BA	93.66	82.87	97.21	90.65	91.46	72.16	94.25	80.35	1.78	3.07
IBA	94.59	83.77	97.91	90.82	92.39	73.65	95.07	81.34	0.82	3.05
MFBA	94.93	84.00	98.29	90.27	92.90	75.83	95.52	82.42	0.85	5.21
IMFBA	95.37	85.14	98.57	92.38	93.53	76.19	95.98	83.51	0.80	3.03



(a) KDD CUP 99



(b) NSL-KDD

图 3 不同类分类性能

Figure 3 Performance of different class

法 (IBA) 及完整特征集 (FULL) 的分类性能相比较, 以证明对 BA 算法所做改进的有效性。结果如表 4 所示。相较于完整数据集, 通过选择特征子集进行分类的结果在各项指标上的均有显著提升, 其中, IBA 应用本文所设计的突变机制解决了 BA 算法易陷入局部最优解的问题, 因此在分类结果上优于 BA。IMFBA 所选特征子集对网络入侵数据集 KDD CUP 99 和 NSL-KDD 分类结果准确率分别为 95.37% 和 85.14%, 相较于完整数据集提升了 3.01 个百分点和 9.78 个百分点。结合图 3 所示不同类别检测结果可知, 通过多因子优化范式改进的 MFBA 虽然在绝大多数评价指标和少数类样本分类上优于 IBA, 尤其是对 Probe 类攻击的检测正确率达到了 93.35% 和 88.22%, 但在多数类上检测性能有所下降, 这是由于 MFBA 缺乏突变机制导致其在特征选择过程中仍然会陷入局部最优。因此, 本文结合上述两种改进策略提出 IMFBA, 实验结果表明, 在整体性能和不同类别分类准确率上均优于 IBA 和 MFBA。综上所述, 本文中对于蝙蝠算法所做的所有改进是行之有效的。

3.4 本文方法与其他特征选择算法的对比

为了进一步评价本文所提出方法,本节实验中将其与文献[8]中的 LRGOA 算法、文献[12]中的 K-means 改进 BA、文献[27]中的 cSG 算法和一些用于特征选择的群体智能优化算法如粒子群优化算法

(PSO)、人工蜂群算法(artificial bee colony, ABC)等进行了比较,实验结果如表 5 所示。为了更全面地评估本文方法的效果,从算法迭代过程中的收敛性和所选特征数量两个方面进行比较,结果如图 4 所示。

表 5 不同方法的性能对比

Table 5 Performance comparison of different methods							
数据集	算法	准确率 Acc/%	精确率 P/%	检出率 DR/%	F1/%	虚警率 FPR/%	特征数
KDD CUP 99	PSO	93.22	98.46	90.37	94.24	0.88	20
	ACO	93.34	97.16	90.64	93.79	1.06	20
	ABC	94.08	97.86	91.73	94.70	1.03	21
	文献[8]	94.94	98.21	93.06	95.56	1.23	18
	文献[12]	95.06	98.05	93.10	95.51	0.84	19
	文献[27]	95.12	98.05	93.16	95.54	0.85	19
	IMFBA	95.37	98.57	93.53	95.98	0.80	21
NSL-KDD	PSO	82.78	85.01	72.16	78.26	3.18	22
	ACO	82.58	85.83	71.91	78.26	3.32	18
	ABC	83.36	91.44	73.41	81.44	3.50	18
	文献[8]	84.28	91.65	75.09	82.55	3.58	19
	文献[12]	84.90	92.46	75.99	83.42	3.32	21
	文献[27]	84.82	92.17	75.83	83.21	3.32	20
	IMFBA	85.14	92.38	76.19	83.51	3.03	22

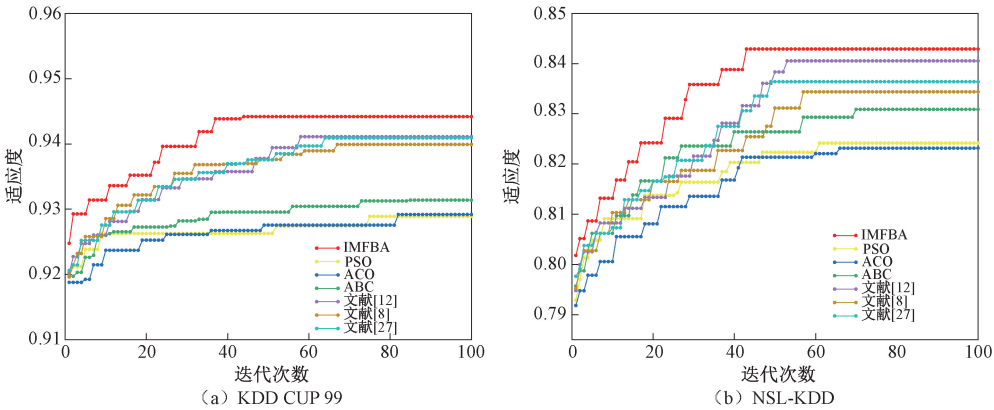


图 4 不同方法的收敛性对比

Figure 4 Convergence comparison of different methods

从表 5 实验结果可以看出,本文所提出的特征选择方法在绝大多数评价指标方面优于现有方法,检测准确率达到了 95.37%和 85.14%,虽然相比于其他方法所选的特征数更多,但其通过选择贡献更大的特征来区分攻击流量,从而在保持更高的检出率的同时,保持更低的虚警率。图 4 验证了所提出算法的优势,在更少的迭代次数中找到具有更好适应度值的特征子集。从图 4 中可以看出,由于采用反向学习初始化策略,IMFBA 的初始解质量更高,而且本文方法大约在 45 次和 40 次收敛,收敛速度

更快且具有更高的适应度值,验证了本文所设计 IMFBA 增强了算法解的多样性,避免了算法陷入局部最优解,提升了算法的收敛速度。综上所述,相较于其他特征选方法,IMFBA 能够更有效地选择高质量的特征子集。同时,选择了一些从现实世界中统计出的 UCI 数据集,以更加全面地验证本文所提出算法的有效性,所选数据集信息如表 6 所示,实验结果如表 7 所示,在绝大多数数据集上本文所提出的算法取得更好的效果,如图 5 所示,本文算法

在所有数据集上实现了准确率提升和数据维度缩减。

表 6 UCI 数据集基本信息

Table 6 Basic information of UCI datasets		
数据类别	数量	特征数
Australian	690	14
biodeg	1 055	41
Climate	540	18
flags	194	28
hepatitis	157	19
sonar	208	60

表 7 UCI 数据集上的准确率对比

Table 7 Accuracy comparison on UCI datasets						
算法	准确率/%					
	Australian	biodeg	Climate	flags	hepatitis	sonar
PSO	68.78	87.98	96.79	76.10	92.81	95.11
ACO	68.25	87.94	96.95	76.02	92.06	95.13
ABC	68.77	87.63	96.83	76.83	92.94	95.16
文献[8]	69.64	88.14	97.52	77.80	95.31	95.58
文献[12]	69.28	88.27	97.61	77.32	95.62	95.12
文献[27]	69.72	88.26	97.51	77.45	95.22	95.32
IMFBA	69.93	88.26	97.98	77.85	95.62	96.28




图 5 IMFBA 在 6 个数据集上的实验结果

Figure 5 Experimental results of the IMFBA on 6 datasets

4 结论

(1) 本文提出一种改进蝙蝠算法进行特征选择的入侵检测方法,该方法通过对蝙蝠算法添加突变机制和应用适应性改进的多因子优化范式,来选择有利于攻击流量分类的最优特征子集。

(2) 实验采用 6 个常用的 UCI 数据集以及公开的入侵检测数据集 KDD CUP 99 和 NSL-KDD 验证本文所提出方法的有效性,相较于原始数据集和其他特征选择方法,本文算法所选的特征子集都具有更好的表现。

参考文献:

[1] 张昊,张小雨,张振友,等. 基于深度学习的入侵检测模型综述[J]. 计算机工程与应用, 2022, 58(6): 17-28.

ZHANG H, ZHANG X Y, ZHANG Z Y, et al. Summary of intrusion detection models based on deep learning[J]. Computer Engineering and Applications, 2022, 58(6): 17-28.

[2] 刘翔宇,芦天亮,杜彦辉,等. 基于特征选择的物联网轻量级入侵检测方法[J]. 信息安全, 2023, 23(1): 66-72.

LIU X Y, LU T L, DU Y H, et al. Lightweight IoT intrusion detection method based on feature selection[J]. Netinfo Security, 2023, 23(1): 66-72.

[3] BOMMERT A, SUN X D, BISCHL B, et al. Benchmark for filter methods for feature selection in high-dimensional classification data[J]. Computational Statistics & Data Analysis, 2020, 143: 106839.

[4] KHAIRE U M, DHANALAKSHMI R. Stability of feature selection algorithm: a review[J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34(4): 1060-1073.

[5] 王艳丽,梁静,薛冰,等. 基于进化计算的特征选择方法研究概述[J]. 郑州大学学报(工学版), 2020, 41(1): 49-57.

WANG Y L, LIANG J, XUE B, et al. Research on evolutionary computation for feature selection[J]. Journal of Zhengzhou University (Engineering Science), 2020, 41(1): 49-57.

[6] SHAFIQ M, TIAN Z H, BASHIR A K, et al. CorrAUC: a malicious bot-IoT traffic detection method in IoT network using machine-learning techniques[J]. IEEE Internet of Things Journal, 2021, 8(5): 3242-3254.

[7] NGUYEN B H, XUE B, ANDREAE P, et al. A new binary particle swarm optimization approach: momentum and dynamic balance between exploration and exploitation[J]. IEEE Transactions on Cybernetics, 2021, 51(2): 589-603.

[8] 李雯婷,韩迪,叶符明. 基于改进蚱蜢优化算法的特征选择机制[J]. 计算机工程与设计, 2022, 43(11): 3168-3176.

LI W T, HAN D, YE F M. Feature selection mechanism based on improved grasshopper optimization algorithm

- [J]. *Computer Engineering and Design*, 2022, 43(11): 3168–3176.
- [9] 林达坤, 黄世国, 林燕红, 等. 基于差分进化和森林优化混合的特征选择[J]. *小型微型计算机系统*, 2019, 40(6): 1210–1214.
- LIN D K, HUANG S G, LIN Y H, et al. Feature selection based on hybrid differential evolution and forest optimization[J]. *Journal of Chinese Computer Systems*, 2019, 40(6): 1210–1214.
- [10] 崔雪婷, 李颖, 范嘉豪. 全局混沌蝙蝠优化算法[J]. *东北大学学报(自然科学版)*, 2020, 41(4): 488–491, 498.
- CUI X T, LI Y, FAN J H. Global chaotic bat optimization algorithm[J]. *Journal of Northeastern University (Natural Science)*, 2020, 41(4): 488–491, 498.
- [11] 徐国天, 刘猛猛. 基于改进哈里斯鹰算法同步优化特征选择的恶意软件检测方法[J]. *信息网络安全*, 2021, 21(12): 9–18.
- XU G T, LIU M M. Malware detection method based on improved Harris Hawks optimization synchronization optimization feature selection[J]. *Netinfo Security*, 2021, 21(12): 9–18.
- [12] LI J Q, ZHAO Z F, LI R P, et al. AI-based two-stage intrusion detection for software defined IoT networks[J]. *IEEE Internet of Things Journal*, 2019, 6(2): 2093–2102.
- [13] ABBASI M S, AL-SAHAF H, MANSOORI M, et al. Behavior-based ransomware classification: a particle swarm optimization wrapper-based approach for feature selection[J]. *Applied Soft Computing*, 2022, 121: 108744.
- [14] YI J, ZHANG W, BAI J R, et al. Multifactorial evolutionary algorithm based on improved dynamical decomposition for many-objective optimization problems[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 334–348.
- [15] YANG X S. A new metaheuristic bat-inspired algorithm [M]//GONZÁLEZ J R, PELTA D A, CRUZ C, et al. *Nature inspired cooperative strategies for optimization*. Berlin: Springer, 2010: 65–74.
- [16] YE Y, ZHAO X J, XIONG L. An improved bat algorithm with velocity weight and curve decreasing[J]. *The Journal of Supercomputing*, 2022, 78(10): 12461–12475.
- [17] YU H L, ZHAO N N, WANG P J, et al. Chaos-enhanced synchronized bat optimizer[J]. *Applied Mathematical Modelling*, 2020, 77: 1201–1215.
- [18] BANGYAL W H, HAMEED A, AHMAD J, et al. New modified controlled bat algorithm for numerical optimization problem[J]. *Computers, Materials & Continua*, 2022, 70(2): 2241–2259.
- [19] MIRJALILI S, MIRJALILI S M, YANG X S. Binary bat algorithm[J]. *Neural Computing and Applications*, 2014, 25(3): 663–681.
- [20] GUPTA A, ONG Y S, FENG L. Multifactorial evolution: toward evolutionary multitasking[J]. *IEEE Transactions on Evolutionary Computation*, 2016, 20(3): 343–357.
- [21] FENG L, ZHOU W, ZHOU L, et al. An empirical study of multifactorial PSO and multifactorial DE[C]//2017 IEEE Congress on Evolutionary Computation (CEC). Piscataway: IEEE, 2017: 921–928.
- [22] OSABA E, MARTINEZ A D, GALVEZ A, et al. DMFEA-II: an adaptive multifactorial evolutionary algorithm for permutation-based discrete optimization problems[C]//Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion. New York: ACM, 2020: 1690–1696.
- [23] YANG Q, CHEN W N, GU T L, et al. An adaptive stochastic dominant learning swarm optimizer for high-dimensional optimization[J]. *IEEE Transactions on Cybernetics*, 2022, 52(3): 1960–1976.
- [24] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C]//International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06). Piscataway: IEEE, 2005: 695–701.
- [25] DAVAHLI A, SHAMSI M, ABAEI G. Hybridizing genetic algorithm and grey wolf optimizer to advance an intelligent and lightweight intrusion detection system for IoT wireless networks[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2020, 11(11): 5581–5609.
- [26] TAVALLAEI M, BAGHERI E, LU W, et al. A detailed analysis of the KDD CUP 99 data set[C]//2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications. Piscataway: IEEE, 2009: 1–6.
- [27] EWEES A A, GAHEEN M A, YASEEN Z M, et al. Grasshopper optimization algorithm with crossover operators for feature selection and solving engineering problems[J]. *IEEE Access*, 2022, 10: 23304–23320.