一种用于智能情绪识别的新型开发与探索型 GWO-SVM 算法

Xucun Yan、Zihuai Lin，*IEEE*高级会员，Zhiyun Lin 和 Branka Vucetic，*IEEE*终身会士

arXiv:2301.01887v1 [eess.SP] 5 Jan 2023

摘要—**情绪识别或检测广泛应用于精神分裂症和自闭症等疾病的医患互动中，其中最典型的技术是语音检测和面部识别。然而，从这些基于行为的情绪识别方法中提取的特征并不可靠，因为人类可能会掩饰自己的情绪。长期录制语音或追踪面部表情也并非高效。因此，我们旨在找到一种可靠且高效的情绪识别方案，可用于实时非行为类情绪识别。通过在轻量级嵌入式系统中实现基于单通道心电图（ECG）的情绪识别方案，可以解决这一问题。然而，现有方案的准确率相对较低。例如，采用最小二乘支持向量机（SVM）时，准确率约为82.78%。因此，我们提出了一种可靠且高效的情绪识别方案——基于开发与探索型灰狼优化器的支持向量机（X-GWO-SVM），用于基于心电图的情绪识别。X-GWO-SVM算法使用两个数据集进行情绪识别：一个是原始的自行采集的iRealcare数据集，另一个是广泛使用的基准WESAD数据集。留一被试交叉验证得出的iRealcare数据集平均准确率为93.37%，WESAD数据集平均准确率为95.93%。本研究表明，X-GWO-SVM算法可用于情绪识别；与先前研究中采用的其他监督式机器学习方法相比，该算法具有更高的可靠性。该算法可在轻量级嵌入式系统中实现，其效率远高于现有的基于深度神经网络的解决方案。**

关键词—**情绪识别、物联网、智慧健康、心电信号、GWO、支持向量机。**

一、引言

物HE联网的应用多年来持续增长。预计到2025年，联网的物联网设备将约有270亿台 [1]。目前，物联网是技术创新的主要推动力之一，也是最具社会和经济转型潜力的领域之一 [2]–[4]。通过由传感器和执行器组成并连接到无线网络的网络 [5]–[14], ，操作人员可以远程收集数据。或者，也可以对执行器进行编程，使其根据传感器报告的数值自动运行。

基于物联网无线传感与联网的情绪识别或检测自问世以来便备受关注

Xucun Yan、Zihuai Lin 和 Branka Vucetic 任职于澳大利亚新南威尔士州悉尼大学电气与信息工程学院，邮编 2006（电子邮箱：xucun.yan@sydney.edu.au；zi- huai.lin@sydney.edu.au；branka.vucetic@sydney.edu.au）。

Zhiyun Lin 任职于中国深圳 518055 的南方科技大学电气与电子工程系，以及中国深圳 518066 的鹏城实验室（电子邮箱：linzy@sustech.edu.cn）。通讯作者：Zhiyun Lin

可广泛应用于人机交互界面，以及精神分裂症和自闭症等疾病的医患互动中。大多数情绪检测方法基于语音检测和人脸识别等行为 [15], [16]。然而，从上述基于行为的情绪识别中提取的特征不足以识别情绪，因为情绪引发的行为可能会被人类社交伪装所掩饰 [17]。例如，基于面部表情的情绪识别很容易被扑克脸误导。使用脑电图（EEGs）[18]–[20], 、肌电图（EMGs）和心电图（ECGs） [21], 等生理信号，是识别情绪的另一种方法，因为生理信号是反映中枢神经系统的重要方式之一，而情绪正是在中枢神经系统中进行处理的 [22]。

与以往的情绪识别方法相比，利用生理线索进行情绪识别有两项优势。第一，自动反应产生的生理信号难以伪装。第二，可穿戴情绪监测能够持续记录生理信息。这与语音识别不同，后者可能仅在个体说话时记录数据。然而，利用多通道生物信号识别人类情绪并不适合实际应用，因为受试者在日常生活活动中可能会受到妨碍 [23]。已有研究证明，心电信号是一种具有可接受识别能力的生理通道 [17]。

然而，根据 [24]–[27],，与面部情绪识别等其他方法相比，基于单通道心电的情绪检测准确率在不同数据集上的波动很大。一方面，近期利用心电信号进行情绪识别的研究主要依赖相对简单的监督学习技术 [28], ，例如随机森林（RF）、支持向量机（SVM）、K近邻（K-NN）等。然而，这些方法的准确率相对较低（例如，使用最小二乘支持向量机时，准确率约为82.78%[17] ）。另一方面，基于单通道心电的情绪识别目前最高准确率，在可穿戴压力与情感检测（WESAD）数据库上达到96.9% [29] ，在用于研究个体及群体的多模态情感、人格特质和情绪状态的数据集AMIGOS上达到88.2% [29] [27], ；该方法采用了自监督卷积神经网络（CNN）模型。面部情绪识别在MMI面部表情数据库上的准确率为92.07% [30], 在日本女性面部表情数据库上的准确率为94.91% [30] ，所采用的模型是嵌入了循环

神经网络（RNN）的卷积神经网络（CNN） [26]。然而，这些基于深度神经网络的技术，例如卷积神经网络（CNN）、RNN等，虽然往往能取得较高的准确率，但结构复杂、计算效率低，无法在实时运行的轻量级嵌入式系统中实现。因此，有必要寻求一种简单的监督学习方案，使其能够在轻量级嵌入式系统中基于单通道心电准确、稳定且高效地识别情绪。

为实现这一目标，本文旨在开发一种新颖的、兼具开发与探索能力的 GWO-SVM（X-GWO-SVM），用于基于心电图的情绪识别。其目标是在降低计算量的同时实现良好的分类准确率（媲美复杂神经网络），从而使其能够应用于轻量级嵌入式系统。该构想源于这样一个事实：支持向量机算法可用于解决单通道心电图情绪识别问题，并可在轻量级嵌入式系统中实现。然而，由于难以找到合适的超参数，同时又要避免训练数据过拟合，现有支持向量机方法在基于心电图的情绪识别任务中无法实现良好的分类准确率。

一般而言，超参数选择属于非凸优化问题。因此，人们引入了许多启发式算法来解决这一问题，例如遗传算法（GA）、粒子群优化（PSO）和灰狼优化器（GWO） [31]–[34] 。与 PSO 及一系列搜索算法相比，GWO 在减少计算量方面表现更佳（例如，在特征子集选择中 [35]）。此外，研究表明，与 PSO 和 GA 相比，GWO 方法对初始化的敏感度更低，稳定性更好 [35]。然而，正如 [36],所述，传统的基于 GWO 的支持向量机（ GWO-SVM ）技术仍容易陷入局部解。

本文提出了一种改进方法，即 X-GWO-SVM 方法。该方法首次将 GWO-SVM 思路用于解决基于心电图的识别问题。本文结果表明，在心电图情绪识别应用中，该方法的识别准确率高于现有的支持向量机和 PSO-SVM 技术。通过增强探索能力，该方法能够有效避免算法陷入局部解；通过增强开发能力，则可加快收敛速度。本文使用两个数据集进行情绪识别：一个是未经处理的自行采集的 iRealcare 数据集，另一个是广泛使用的基准 WESAD 数据集，并采用 X-GWO-SVM 算法。在 iRealcare 数据集上，留一被试交叉验证得到的平均准确率为 93.37%，F1 分数为 93.38%；在 WESAD 数据集上，平均准确率为 95.93%，F1分数为 95.56%。

本文的主要贡献总结如下：

1) 我们使用自主研发的仅有一个心电图通道的可穿戴物联网心电贴片，通过播放不同视频采集四种情绪，即快乐、紧张、平静和兴奋。2) 我们设计了一种新颖的 X-GWO-SVM 算法，用于在内部学习支持向量机的超参数。该算法通过增强探索能力，有效避免陷入局部解；并通过增强开发能力，加快收敛速度。

3) 这种新颖的 X-GWO-SVM 算法能够准确、高效地识别基于单通道心电图信号的情绪，并可部署在实时运行的轻量级嵌入式系统中。与现有的简单机器学习方法相比，它提高了准确率；与一些新型深度神经网络相比，则大幅降低了复杂度。因此，与其他耗时较长的情绪识别方法相比，其效率也有所提升。

本文其余部分的安排如下。第二节介绍我们的数据库和扩展数据集。第三节介绍模型的构建。在第四节和第五节中，我们分别展示结果并进行讨论，最后在第六节讨论未来可能的研究方向。

II. 数据集

心电信号由P波、T波和QRS波群组成，分别代表心电图脉搏的三个阶段。在心房收缩期，P波是收缩脉搏。QRS波群表示心室去极化。T波表示心室复极 [37]。心电图设备记录心脏活动引起的电变化，这些变化由电极通过皮肤采集一段时间。已有研究证明，心电信号是一种适用的生理通道，具有可接受的识别能力 [17] ，可用于识别情绪。因此，本研究使用单通道心电信号。为验证X-GWO-SVM的通用表征能力，我们使用了两个心电信号数据集：一个是包含5名受试者的原始自行采集的iRealcare数据集，另一个是广泛使用的基准WESAD数据集，包含15名受试者。

*A. iRealcare*数据集描述

数据采集是情绪检测中最重要的步骤之一。在此阶段，必须明确定义不同的情绪。如果定义不清晰，分类阶段可能会混淆不同的情绪，并对分类性能造成负面影响。然而，情绪通常瞬间产生，持续时间很短。持续时间越长，心电信号中包含的无关数据就越多。因此，很难正确标记相应的情绪类别。

为避免上述问题，我们自行采集了一个高质量数据集，每种情绪的采集时长较短，并确保数据采集和标注流程准确。心电信号由一款名为 iRealcare [38]–[42] 的低成本可穿戴物联网心电贴片记录，采样率为 128 Hz。iRealcare 物联网心电传感器采集的数据可通过低功耗蓝牙（BLE）传输至智能手机应用程序（APP），随后上传至云端。我们可以从云端获取原始心电信号。记录了快乐、紧张、平静和兴奋四种情绪的信号。除平静外，每种情绪均由外部环境刺激诱发，这与已发表的数据集通过音频或视频刺激受试者的方式类似 [43]。平静描述的是正常状态，

在这种状态下，记录心电信号时没有任何外部刺激。受试者观看喜剧片、观看惊悚电影和进行锻炼时，分别记录快乐、紧张和兴奋状态下的信号。通常，正如前文所述，记录时长应较短。因此，每种情绪的记录时长范围为 3.22 至 6.16 分钟。

需要指出的是，我们只记录受试者实际处于相应情绪状态的时段，并忽略过渡期。显然，在这种外部刺激设置下，不同情绪的定义明确，受试者也很容易进入特定情绪状态。考虑到不同受试者之间的差异，本研究纳入了 5 名受试者，并记录了每名受试者的四种情绪类型。每名受试者的平静样本为 192–229 个，兴奋样本为 99–141 个，快乐样本为 156–236 个，紧张样本为 166–205 个。有关 iRealcare 数据库的更多信息见表 I，数据分段详情见第三节-A2。

B. WESAD 数据集描述

该数据集可通过 [43], 获取，包含 15 名受试者（年龄为 24–35 岁）观看视频片段以及进行公开演讲和心算任务的记录。数据集通过腕戴式设备（包括以下传感器：光电容积描记法、加速度计、皮肤电活动和体温）和胸戴式设备（包括以下传感器：心电图、加速度计、肌电图、呼吸和体温）进行记录。该数据集融合了多种生理参数，可有效识别人体情绪，因为这些参数反映了人体的本能反应。然而，该数据集不适用于实际应用，并且可能妨碍受试者进行日常生活活动 [23]。因此，本文仅研究该数据集中的单通道心电信号。心电信号由 RespiBAN Professional 通过三导联配置采集，采样率为 $700Hz$ 。受试者标注了三种情绪（基线、压力和愉悦） [43]。受试者观看有趣的视频片段时采集愉悦状态下的信号。要求受试者进行公开演讲时采集压力状态下的信号。基线状态下的信号采集于受试者坐在/站在桌旁阅读杂志时。每名受试者有 9 个愉悦样本、15–18 个压力样本和 28–29 个基线样本。数据分段详情见第三节-A2。

III. 方法

A. 预处理

通常，心电信号呈非线性，且信号幅度较低。心电信号的频率范围为 $0.05Hz$ 至 $100Hz$ ，动态范围低于 $4mV$ [44]。因此，采集到的心电信号容易受到干扰等外部因素的影响。为获取低干扰的心电信号，我们对原始心电信号进行预处理。在数据采集和传输阶段，心电信号主要受到基线漂移、电源线干扰和电极接触噪声的影响。基线漂移由身体运动和呼吸引起。它会使整个心电信号在水平轴上向下或向上偏移。基线漂移的频率约为 $0.5Hz$ ，会影响心电信号的分析。电源线干扰的特征频率为 50 或 $60Hz$，可能由附近设施产生的电磁场以及电源线的电磁干扰引起。由于 iRealcare 传感器使用 BLE 而非电缆，因此电源线干扰不会影响从该传感器采集的心电信号。皮肤受到拉伸时阻抗发生变化，会产生电极接触噪声。其频率通常在 1 至 $10Hz$ [45] 之间。

1) 滤波：采用有限冲激响应（FIR）滤波器滤除上述噪声。它是一种可靠且简单的滤波器。此外，FIR 滤波器是线性滤波器，因此其输出不会失真 [46]。有限冲激响应滤波器通过基于窗函数的方法构建，例如汉明窗、矩形窗、汉宁窗和布莱克曼窗。这些不同的窗函数用于设计具有截止频率的低通滤波器和高通滤波器。对于我们的带通有限冲激响应滤波器，截止频率分别设为 $3Hz$ 和$100Hz$。

2) 分段与划分：对于 iRealcare 数据集，上述 20 组数据经过降噪后，按每段 200 个数据点（1.56 秒）进行无重叠分段，然后划分为训练集和测试集。各段之间不重叠，以避免训练数据与测试数据之间可能发生的数据泄漏。需要注意的是，窗口大小（200 个数据点）的选择是基于经验的。此前使用这些数据集的研究采用了各种不同的窗口大小。例如， [43] 在 WESAD 数据集上采用了 5 秒的窗口，而 [47] 则在同一数据集上采用了 1 秒的窗口。具体而言，训练集由 16 组数据组成，每组包含四种情绪；测试集则由 4 组数据组成。与 iRealcare 数据集类似，WESAD 数据集也经过有限冲激响应滤波器滤波，并按每段 14000 个数据点（20 秒）进行无重叠分段，然后将 12 名受试者作为训练集，其余 3 名受试者作为测试集。

图1展示了从 iRealcare数据集 中随机选取的200个心电信号数据样本所构成的四种情绪片段。可以看出，处于平静情绪时，受试者的心率相对较慢。然而，仅凭原始心电信号很难识别其他三种情绪。因此，有必要设计一种高效的特征提取方法。

3）离散余弦变换（*DCT*）：本文采用 DCT 方法提取心电信号在频域中的主要信息 [48]。该方法对输入心电信号进行压缩处理，在保留重要信息的同时，仅保留一小部分系数作为特征向量。DCT 的主要优点是计算速度快，适用于数据压缩 [49]。为提升性能，在识别之前采用 Z-分数归一化技术，以应对电极在皮肤表面移动所引起的轻微运动伪影扰动。

D CT 使用不同频率的 N 余弦函数之和 同

表 I IREALCARE 数据库的数据资料。

ID	平静时长/分钟 （片段编号）	兴奋时长/分钟 （片段编号）	快乐时长/分钟 (片段编号)	紧张时长/分钟 (片段编号)	总时长/分钟 (片段编号)
1	5 (192)	3.22 (123)	6.16 (236)	4.33 (166)	18.71 (717)
2	5.23 (200)	3.63 (139)	5.42 (208)	4.48 (172)	18.76（719）
3	5.37（206）	3.69（141）	4.91（188）	5.35（205）	19.32（740）
4	5.98（229）	3.65（140）	4.51（173）	4.7（180）	18.84（722）
5	5.06（194）	2.59 (99)	4.07 (156)	4.66 (178)	16.39 (627)
Sum	26.63 (1021)	16.78 (642)	25.08 (961)	23.52 (901)	92.01 (3525)

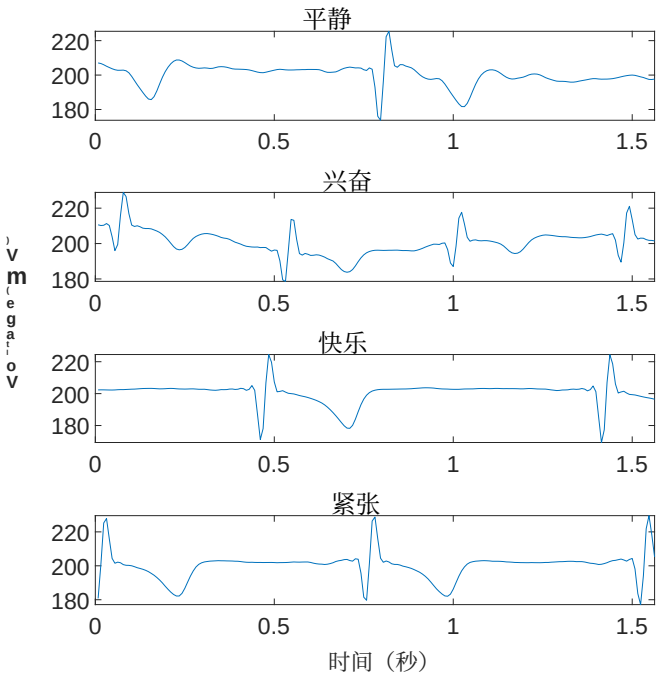

图 1. **来自四种情绪的 ECG 片段，每段包含 200 个采样点（1.56 秒）**

来表示有限的数据样本。它将时域信号转换为频域信号。式（1）给出了数据序列 $x(n)$ 的离散余弦变换公式，它是不含共轭部分的傅里叶变换。

$$y(k) = w(k)\sum_{n=1}^{N} x(n)\cos[\frac{\pi}{2N}(2n-1)(k-1)], \quad (1)$$
$$k = 1, ..., N,$$

其中

$$w(k) = \begin{cases} \frac{1}{\sqrt{N}} & , k = 1 \\ \sqrt{\frac{2}{N}} & , 2 \le k \le N \end{cases} \quad (2)$$

且 N 是数据序列 [50]的长度。

在进行离散余弦变换时，每个心电图片段中的数据样本都会转换到频域，生成一系列长度为 N 的离散余弦变换系数。随后，根据绝对值将生成的离散余弦变换系数按降序排列。绝对值较大的离散余弦变换系数被视为显著特征，并输入所提出的 X-GWO-SVM 方案。可选取维度为 u （$u \le N$）的降序离散余弦变换系数作为提取出的特征。提取特征的适当维度 u 将在第 IV 节中通过比较不同取值下的分类性能进行讨论。图 2 展示了上述心电图片段（见图 1）中维度为 $u = 95$ 的相应提取特征，即绝对值最大的 95 个系数。需要注意的是，第一个系数的能量最高（以红色突出显示），其中包含最显著的特征。为观察其余系数的细节，我们放大了每种情绪下其余系数（第 2_{nd} 至第 95_th 个系数）。与原始心电信号相比，经过特征提取后，不同片段中的四种情绪得以清晰区分。

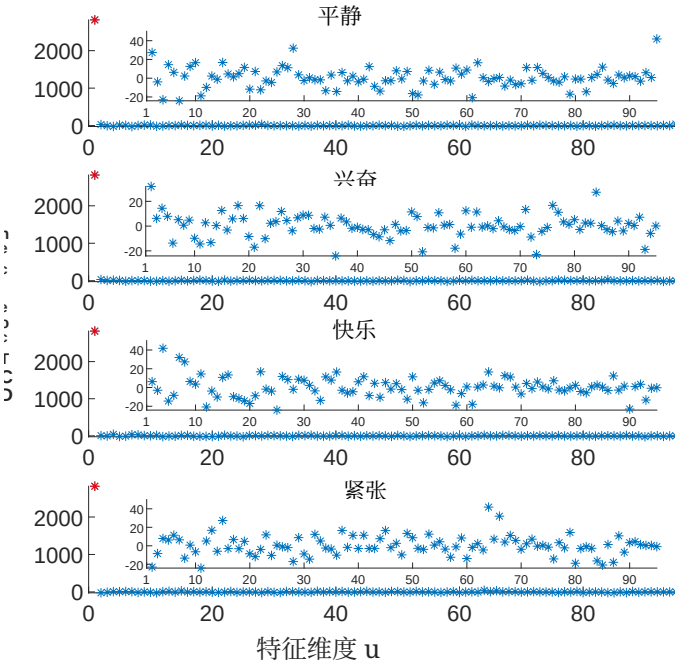

图 2. **从心电图片段中提取的特征，维度为 95**

B. 基于灰狼优化器的开发与探索型支持向量机

本研究首次提出 X-GWO-SVM 方法，用于心电图情绪识别。所提出方法无需超参数的特性，为径向基函数支持向量机（RBF-SVM）的学习提供了一种新途径。一般而言，使用 RBF-SVM 对非线性可分数据进行分类，需要两个超参数，即

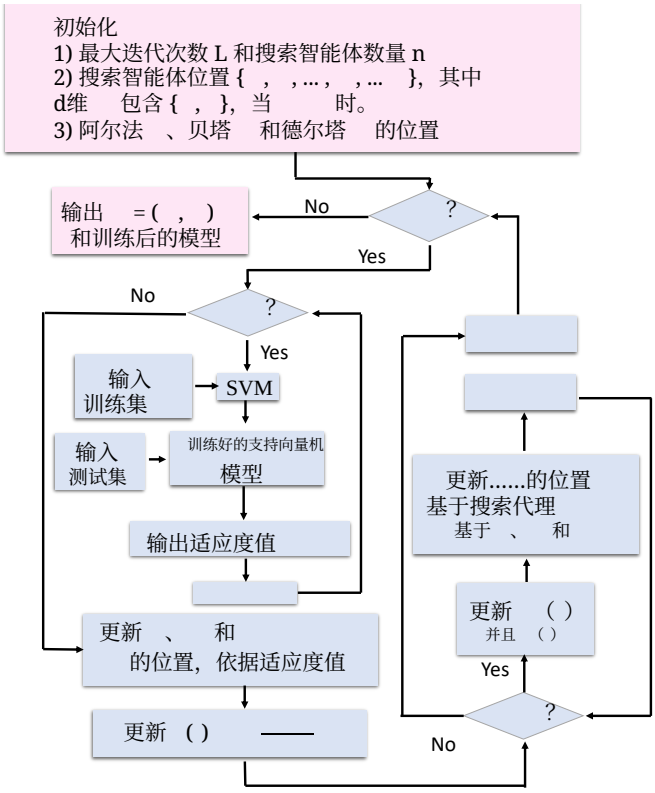

图 3. **X-GWO-SVM算法流程图。搜索智能体（狼）的总数用 n 表示。** C_o 和 γ_o 是最终最优解中存储的组成部分 ξ_1。

需要考虑惩罚系数 C 和空间参数 γ。引入 C 和 γ 后，RBF-SVM 的目标函数由方程（3）和（4）表示：

$$\begin{aligned} &\min \tfrac{1}{2}||\mathbf{w}||^2 + C\sum_{i=1}^{P}\epsilon_i, \\ s.t.\quad &y_i(\mathbf{w}^T\Psi(\mathbf{x}_i)+b)-1+\epsilon_i \geq 0 \\ &\forall i = 1,2,...,P, \end{aligned} \tag{3}$$

$$\mathbf{K}(\mathbf{x}_i,\mathbf{x}_j) = e^{-\gamma\|\mathbf{x}_i-\mathbf{x}_j\|^2} = \Psi(\mathbf{x}_i)^T\Psi(\mathbf{x}_j), \tag{4}$$

其中， P 为训练样本的数量； ϵ_i 为松弛变量，用于放宽线性支持向量机的约束；$\mathbf{w}^T\Psi(\mathbf{x}_i)+b$ 为决策函数； y_i 为类别标签；$\mathbf{x}_i$ 为样本； C 为惩罚参数，用于控制间隔大小与松弛变量惩罚之间的权衡； γ 为空间参数，用于控制新特征空间 [51], [52] 中的数据分布。显然，RBF-SVM 的超参数（C 和 γ）调优是必要但复杂的。因此，所提出的方法通过强调 α狼的重要性，并以非线性方式更新 GWO 中使用的系数向量，能够在内部学习超参数。此外，该方法在用于心电图情绪识别时，识别准确率高于现有的 GWO-SVM 和 PSO-SVM 技术；同时，它能通过提高探索能力有效避免算法陷入局部解，并通过增强开发能力加快收敛。

图 3 展示了我们的 X-GWO-SVM 方法，该方法受到灰狼活动的启发。灰狼分为 4 种类型，分别为阿尔法（α）、贝塔（β）、德尔塔（δ）和欧米伽（ω），用于模拟领导层级。这些狼不断搜寻猎物（在我们的案例中即最优解），而狩猎（优化）过程则分别由适应度最高、第二高和第三高的解 α、 β 和 δ 引导。ω 狼跟随这三只狼。搜索智能体（狼）的总数由 n 表示。C_o 和 γ_o 是搜索得到的最优解 ξ_1 的两个元素。X-GWO-SVM 方法包含以下 10 个步骤。

1) 初始化 X-GWO-SVM 相关参数，即最大迭代次数 L；搜索智能体数量n； α (ξ_1)、 β (ξ_2) 和 δ (ξ_3) 的位置；搜索智能体（狼）的位置 η_1， η_2，..... η_i，..... η_n。$\eta_i \in \mathbb{R}^d$ 和 $\xi_i \in \mathbb{R}^d$ 是 d 维向量。在本例中， d 等于 2，表示搜索所需的两个最优超参数（C 和 γ）。

2) 如果当前迭代次数 t 小于最大迭代次数 L，则转到后续步骤；否则，直接转到步骤 9)。

3) 对每个智能体，使用当前位置元素 $\eta_i = (C_i,\ \gamma_i)$ 训练径向基函数支持向量机。

4) 对每个智能体，使用测试集预测训练好的径向基函数支持向量机，并根据式 (5) 将其损失作为适应度值输出：

$$loss(\eta_i) = \frac{1}{M}\sum_{i=1}^{M}(y_i - h_i)^2, \tag{5}$$

其中， M 是测试样本数量， h_i 表示第 i_{th} 个测试样本的预测值。

5）将所有适应度值按升序排序，并将对应于前三个适应度值的位置分别赋值为 ξ_1、 ξ_2 和 ξ_3。数学表达式如下：

$$\xi_1(t) = \underset{\eta_i(t),i=1,...,n}{\arg\max}\ loss(\eta_i(t)), \tag{6}$$

$$\xi_2(t) = \underset{\eta_i(t);\eta_i(t)\neq\xi_1(t)}{\arg\max}\ loss(\eta_i(t)), \tag{7}$$

$$\xi_3(t) = \underset{\eta_i(t);\eta_i(t)\neq\xi_1(t),\xi_2(t)}{\arg\max}\ loss(\eta_i(t)). \tag{8}$$

6）根据公式（9）更新探索-开发调节函数 $\phi(t)$：

$$\phi(t) = -2\frac{t-L+1}{-t+L}. \tag{9}$$

7）对于每个搜索代理，根据以下公式更新其位置 η_i ：

$$\begin{aligned} \eta_i(t+1) = &\frac{1}{4}\xi_1(t) + \frac{1}{4}\sum_{i=1}^{3}[\xi_i(t) \\ &- b_i(t)\odot|c_i(t)\odot\xi_i(t) - \eta_i(t)|], \end{aligned} \tag{10}$$

$$b_i(t) = 2\phi(t)r_i(t) - \phi(t)\mathbf{1}, \quad c_i(t) = 2s_i(t), \tag{11}$$

其中， $\odot$和 $|\cdot|$ 分别表示哈达玛积运算和逐元素绝对值运算； t 为迭代次数； $\mathbf{1} \in \mathbb{R}^2$ 及其所有元素均为 $\mathbf{1}$； $b_i \in \mathbb{R}^2$ 和 $c_i \in \mathbb{R}^2$ 为系数向量。

系数 $r_i \in \mathbb{R}^2$ 和 $s_i \in \mathbb{R}^2$ 为随机向量，其元素的范围为 0 到 1。8）累加迭代次数并返回步骤 2）。9）输出最优参数 $\xi_1 = (C_o, \gamma_o)$ 和训练好的支持向量机模型。10）根据测试集计算模型的分类准确率，并结束 X-GWO-SVM 算法。

我们将在以下两个小节中展示所提出的 X-GWO-支持向量机算法在探索能力和开发能力方面的改进。

1) 探索：通常，$\phi(t)$ 的各分量会在迭代过程中从 2 线性递减至 0 [53], ，以模拟狼群逼近猎物的过程。在我们的设计中，$\phi(t)$ 的各分量从 2 至 0 非线性递减，在接近 2 时下降较慢，在接近 0 时下降较快（参见公式（9））。图4（a）展示了当最大迭代次数 L 设为 100 时，$\phi(t)$ 的各分量在迭代过程中从 2 线性（蓝色星号）和非线性（黑色圆圈）递减至 0。显然，对于所设计的非线性递减方法，我们可以观察到，在黑色虚线左侧（迭代时间 = 94）下降较慢，旨在探索更大的范围，并与传统的线性方式相比增强探索能力。

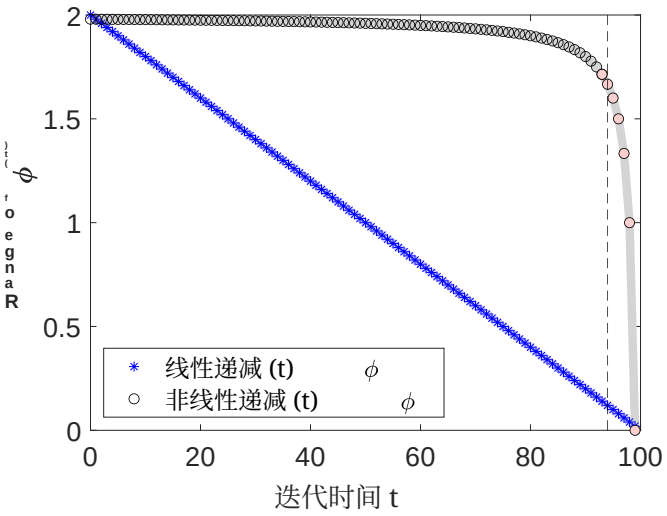

(a)

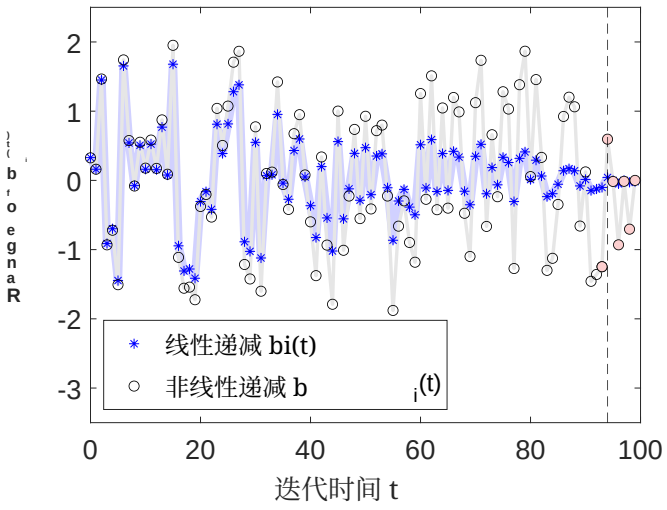

(b)

图4. **(a)** $\phi(t)$ **的分量在迭代过程中从 2 线性（蓝色圆圈）和非线性（黑色圆圈）递减至 0。(b) 基于** $\phi(t)$ **的分量，** $b_i(t)$ **的相应分量在线性（蓝色圆圈）和非线性（黑色圆圈）情况下随迭代递减。**两种情况下的最大迭代次数 L 均设为 100。黑色虚线位于第 94_{th} 次迭代处。红色实心圆用于清楚标示非线性情况下第 $\phi(t)$ 次迭代后 $b_i(t)$ 和 94_{th} 的变化。

如 [53]中所述，$b_i(t)$ 取大于1或小于-1的随机值，以促使搜索代理远离猎物，从而强调探索，并使X-GWO-SVM算法能够进行全局搜索。需要注意的是，在 $\phi(t)$ 的作用下，$b_i(t)$ 的波动范围也会减小。$b_i(t)$ 的各分量是在区间 $[-\phi(t) \ \ \phi(t)]$, 内取值的随机数，而 $\phi(t)$ 的各分量则会在迭代 [53]过程中从2非线性递减至0。图4（b）显示了应用线性和非线性 $\phi(t)$ 时 $b_i(t)$ 的变化。蓝色和灰色阴影分别表示应用线性 $\phi(t)$ 和非线性 $\phi(t)$ 时 $b_i(t)$ 的变化趋势。显然，在黑色虚线左侧，即$|b_i(t)| > 1$，应用非线性 $\phi(t)$ 时 $b_i(t)$ 的取值（黑色圆圈）范围大于应用线性 $\phi(t)$ 时 $b_i(t)$ 的取值（蓝色星号）。换言之，在非线性情形下，适应度最高位置的下一搜索范围会平缓衰减，直到迭代达到阈值——本图中为94，从而确保较大的探索范围。

2）开发（收敛）：在 [53], 更新位置时，权重 α、β 和 δ 狼都相同。而对于我们提出的方法，在更新位置时，我们会为 α 狼赋予更大的权重（参见公式（10）），以突出 α 狼的重要性。因此，前一次迭代中适应度最高的解可以得以保留，并持续影响后续更新步骤，从而确保更快地收敛。

从图4（a）可以看出，对于所设计的非线性递减方法，黑色虚线右侧的衰减速度明显更快。为了清晰地跟踪 $\phi(t)$ 的收敛情况，在 94_{th} 次迭代后，非线性情形采用红色填充圆圈标示。随着迭代次数不断增加，收敛速度趋于加快，而对于传统的线性递减方法，$\phi(t)$的各分量则从2到0均匀递减。

如前所述，$b_i(t)$ 的值受 $\phi(t)$ 的值影响。因此，在图 4 (b) 中可以观察到类似现象：在黑色虚线右侧，即 $|b_i(t)| < 1$，$b_i(t)$ 的值比线性情况收敛得快得多。换言之，迭代时间达到 94 后，非线性情况下最优位置的下一搜索范围会大幅缩小。

总而言之，所提出的 X-GWO-SVM 算法无需对 SVM 进行超参数调优即可获得良好的准确率。此外，该算法通过引入最优位置 α 改进了位置更新方式，突出了 α 狼的重要性，并使最优解的影响延续至

下一次迭代。我们还通过非线性递减 $\phi(t)$ 的值，增强了开发能力。该算法通过提高探索能力增强了全局搜索能力，并通过提高开发能力加快了收敛。

C. 测量指标

可以通过标准统计指标评估各种方法的分类性能：准确率（ACC）和 F1分数（F1），其定义如下：

$$\mathrm{ACC} = \frac{\mathrm{TP}+\mathrm{TN}}{\mathrm{TP}+\mathrm{FP}+\mathrm{TN}+\mathrm{FN}}, \tag{12}$$

$$\mathrm{F1} = 2\frac{\mathrm{PRE}\times\mathrm{REC}}{\mathrm{PRE}+\mathrm{REC}}, \tag{13}$$

$$\mathrm{REC} = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}}, \quad \mathrm{PRE} = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}}, \tag{14}$$

其中，真阳性（TP）表示被正确预测为当前类别的样本数；真阴性（TN）表示被正确预测为其他类别的样本数；假阳性（FP）表示被错误判定为当前类别的样本数；假阴性（FN）表示被错误判定为其他类别的样本数。准确率是衡量每个数据集中测试样本总数中被正确预测比例的总体指标，体现了方法正确分类情绪的能力。另一方面，F1分数能够更准确地反映类别分布不均衡时的理想模型。我们的目标是最大化这两项指标，以此作为模型有效性的衡量标准。

IV. 结果

A. 特征维度选择

如第三节A3所述，确定合适的特征提取数量十分必要。因此，我们在 iRealcare 数据集上采用 X-GWO-SVM 方法，在 20 至 135 的范围内以 5 为步长进行特征重要性选择。每项仿真结果均通过随机选择训练和测试样本重复 10 次。

图7展示了针对 iRealcare数据集，采用 X-GWO-SVM算法进行10折交叉验证时，准确率随特征维度变化的情况。显然，识别准确率呈现出先上升、后期下降的趋势。特征维度为95时，平均准确率最高，达到 93.37%。此外，其对应的箱线图（以橙色填充）方差相对较低，表明该特征维度具有较好的稳定性。在特征维度为95时取得最具判别力的结果后，我们将其应用于其他对比方法。

B. 探索-开发调节函数的选择

正如我们所证明的，探索-开发调节函数 $\phi(t)$在第三节 III-B 节中，我们在此进行的实验采用了多种探索-开发调节函数，以证明我们在 X-GWO-SVM 算法中选择的 $\phi(t)$ 最优。这些函数的表达式见方程 (15) 至 (19)，相应的探索-开发调节函数绘于图 6 中。应当

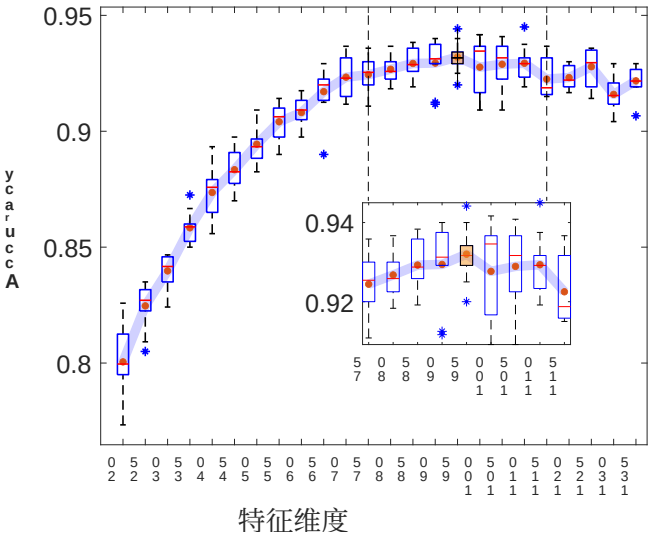

图5. **针对 iRealcare数据集，采用 X-GWO-SVM算法进行10折交叉验证时，准确率随特征维度变化的情况。**蓝色阴影表示采用 X-GWO-SVM算法进行10折交叉验证时，不同特征维度对应的平均准确率变化趋势。结果采用箱线图表示，箱体顶部和底部分别表示10折交叉验证结果的第75和第25百分位数；箱体内的红色直线表示中位数，红点表示均值；蓝色星号表示离群值。最具判别力的结果以橙色填充。

注意到，作为基准的传统线性探索-开发调节函数表示为方程 (15)。此外，我们在方程 (9) 中为 X-GWO-SVM 提出的函数，在方程 (18) 中改写为 $f_{\phi 4}(t)$。

$$f_{\phi 1}(t) = 2 - \frac{2t}{L}, \tag{15}$$

$$f_{\phi 2}(t) = \frac{4}{1+e^{t-L}} - 2, \tag{16}$$

$$f_{\phi 3}(t) = \frac{-4}{1+e^{-t}} + 4, \tag{17}$$

$$f_{\phi 4}(t) = -2\frac{t-L+1}{-t+L} = \phi(t), \tag{18}$$

$$f_{\phi 5}(t) = 2\cos(\frac{\pi}{2tL}). \tag{19}$$

根据图 6，我们可以观察到，$f_{\phi 2}$ 和 $f_{\phi 3}$均由 Sigmoid函数变形而来，并分别在迭代开始和结束时从 2 急剧下降至 0。函数 $f_{\phi 4}$ 和函数 $f_{\phi 5}$分别基于函数 $\frac{1}{x}$ 和余弦函数，逐步缓解了这种下降趋势。

–

为评估探索-开发调节函数的效果，我们对所提出的 X-GWO-SVM 应用 10 折交叉验证，并基于上述五种函数改变探索-开发调节函数。iRealcare数据集和 WESAD 数据集上对探索-开发调节函数的评估结果分别如表 II 和表 III 所示。显然，对于 iRealcare数据集，结合 $f_{\phi 4}$ 的 X-GWO-SVM 准确率（93.37%）和 F1分数（93.38%）均为最高。此外，最低的方差和相当短的训练时间表明其具有较高的稳定性，且

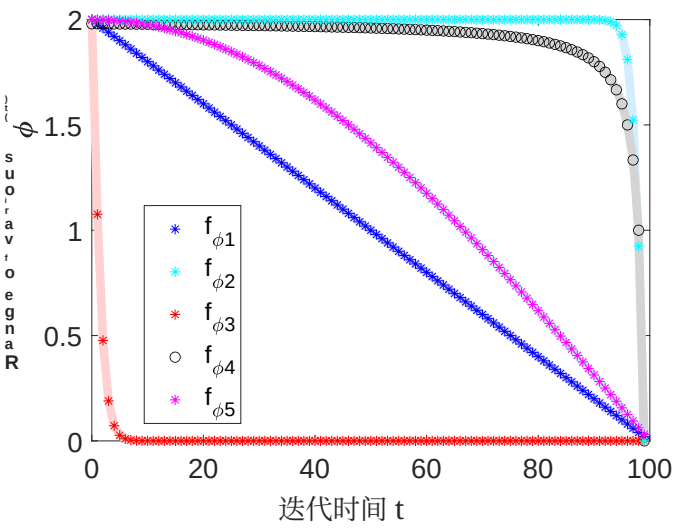

图 6. $\phi(t)$ **在不同探索-开发调节函数下的分量变化。**

计算时间较短。对于 WESAD 数据集的结果也可得出类似结论：X-GWO-SVM 与 $f_{\phi4}$ 组合取得了最高准确率（95.93%）和 F1分数（95.56%）。至此，我们确定了最优特征维度为 95，最优探索-开发调节函数为 $f_{\phi4}$。因此，后续对所提出的 X-GWO-SVM 的评估均基于这两项设置。

表 II 使用五种探索-开发调节函数的 X-GWO-SVM 在 iRealcare 数据集上的结果。

探索-开发调节函数	平均准确率	准确率方差	平均F1分数/%	训练时间/s
$f_{\phi1}$	92.90	9.66E-05	92.91	429.98
$f_{\phi2}$	93.05	6.10E-05	93.08	402.80
$f_{\phi3}$	83.26	1.40E-02	83.50	509.66
f$_{\phi4}$	**93.37**	**2.84E-05**	**93.38**	**380.16**
$f_{\phi5}$	92.93	3.31E-05	92.94	368.14

表 III：X-GWO-SVM 在 WESAD 数据集上使用五种探索-开发调节函数的结果。

探索-开发调节函数	平均准确率	准确率方差	平均F1分数/%	训练时间/s
$f_{\phi1}$	95.29	1.62E-04	95.07	856.31
$f_{\phi2}$	95.79	7.48E-05	95.44	828.31
$f_{\phi3}$	95.29	1.62E-04	95.07	825.14
f$_{\phi4}$	**95.93**	**5.61E-05**	**95.56**	**813.58**
$f_{\phi5}$	95.79	7.48E-05	95.44	835.40

C. 所提方法的分类性能 *odel*

*1）iRealcare*数据集的分类性能：有人可能会怀疑，X-GWO-SVM 的改进中只有一项能够带来显著的性能提升。因此，我们研究了另外三种方法：1）使用 GWO-SVM 方法，不采用任何针对 GWO 的改进；2）使用基于非线性 $\phi(t)$ 的灰狼优化器（N-GWO-SVM）方法，仅使用非线性递减值 $\phi(t)$；3）使用 PSO-SVM 方法，其中使用传统的 PSO算法搜索最优超参数。

表IV至表VII展示了上述基于超参数优化器的技术的分类性能。报告的度量指标包括准确率、F1分数、准确率变化以及各方案的训练时长。所有指标均根据每种方案进行的10次重复分类试验计算得出（表IV至表VII中的各行）。

表 IV 基于超参数优化器的方案在 iRealcare数据集上评估所得四种情绪的平均准确率。

方案	平静/%	兴奋/%	快乐/%	紧张/%
PSO-SVM	83.20	84.87	**95.40**	91.13
GWO-SVM	84.07	97.67	94.73	91.40
N-GWO-SVM	84.60	97.93	94.33	91.27
X-GWO-SVM	**86.03**	**98.03**	95.07	**94.33**

表 IV 显示，对于平静（84.07% 对 83.20%）、兴奋（97.67% 对 84.87%）和紧张（94.73% 对 91.13%），GWO-SVM 的表现显著优于 PSO-SVM；而 N-GWO-SVM 仅在平静（84.60%）和兴奋（97.93%）方面略有提升。除快乐方面的表现略低于 PSO-SVM 方案（95.07% 对 95.40%）外，所提出的 X-GWO-SVM 方案在性能上显著优于其他方案。它在平静、兴奋和紧张方面的准确率最高，分别为 86.03%、98.03% 和 94.33%。表 V 展示了平均 F1 分数的类似结果。所提出的 X-GWO-SVM 方案在性能上显著优于其他方案。

表 V 基于超参数优化器的方案在 IREALCARE 数据集上评估得到的四种情绪的平均 F1 分数。

方案	平静/%	兴奋/%	快乐/%	紧张/%
PSO-SVM	85.29	82.46	91.07	94.45
GWO-SVM	84.19	97.87	90.77	93.57
N-GWO-SVM	84.59	97.99	91.03	93.36
X-GWO-SVM	**87.73**	**98.31**	**91.23**	**96.24**

表 VI 基于超参数优化器的方案在 iRealcare数据集上评估的四种情绪准确率的平均方差。

方案	平静	兴奋	快乐	紧张
PSO-SVM	**6.00E-04**	7.17E-02	3.00E-04	3.00E-04
GWO-SVM	5.00E-04	2.00E-04	4.00E-04	1.10E-03
N-GWO-SVM	1.60E-03	2.00E-04	1.4E-04	3.00E-04
X-GWO-SVM	6.01E-04	**6.04E-05**	**1.38E-04**	**7.65E-05**

表 VI 中的方差结果也支持类似的结论。与传统的 PSO-SVM 方案或 GWO-SVM 方案相比，除平静状态下的方差（6.01E-04 对 6.00E-04）外，我们提出的方法在兴奋（6.04E-05）、快乐（1.38E-04）和紧张（7.65E-05）状态下也表现出最低的准确率方差，表明其具有良好的稳定性。

表 VII 展示了 10 折交叉验证结果的平均准确率、平均方差和平均训练时间。值得注意的是，所提出的 X-GWO-SVM 方案具有最高的

表 VII 基于超参数优化器的方案在 iRealcare数据集上对四种情绪进行评估所得的准确率、F1 分数、方差和训练时间的均值。

方案	平均准确率/%	平均F1分数/%	平均方差	训练时间/s
PSO-SVM	88.65	88.32	1.82E-02	8824.80
GWO-SVM	91.97	91.60	5.50E-04	446.24
N-GWO-SVM	92.03	91.74	5.25E-04	446.42
X-GWO-SVM	**93.37**	**93.38**	**2.19E-04**	**380.16**

类别准确率均值（93.37%）、最高的类别F1分数均值（93.38%）、最低的类别方差均值（2.19E- 04）以及最短的超参数训练时间（380.16s）。结果表明，该方案具有较高的可靠性、稳定性和效率。

表 VIII 非参数分类方法与所提方法在 iRealcare 数据集上的平均准确率、平均F1分数和方差。

算法	平均准确率/%	平均F1分数/%	均值（方差）
RF	81.71	82.35	**1.56E-04**
K-NN	82.48	81.22	7.35E-04
X-GWO-SVM	**93.37**	**93.38**	2.19E-04

为证明我们提出的 X-GWO-SVM 方案的重要性，我们还在 iRealcare数据集上使用相似特征考察了其他非参数分类方法，例如随机森林和 K近邻。结果如表 VIII 所示。所有结果均根据每种方案的 10 次重复分类试验计算得出。从结果可以明显看出，X-GWO-SVM 方案的准确率表现最高。事实上，随机森林比 X-GWO-SVM 更稳定，但其准确率和 F1分数远低于所提出的方案（分别为 81.71% 对 93.37%、82.35% 对 93.38%）。此外，在可靠性和稳定性方面，X-GWO-SVM 完全优于 K近邻。总体而言，与现有方法相比，所提出的 X-GWO-SVM 策略在 iRealcare数据集上更加稳定，也更能有效实现较高的平均准确率。

2) WESAD 数据集的分类性能：为证明所提出的 X-GWO-SVM 方法的可靠性和稳定性，我们进一步在 WESAD 数据集上评估该方法的准确率和 F1分数，并与其他现有方法进行比较。按照第 IV-B 节所述，在 X-G WO-SVM 方法下以 500 为步长，在 4000 至 10000 的范围内进行特征维度选择，得出的最佳特征维度为 5000。

图7展示了在 WESAD 数据集上，使用 X-GWO-SVM 算法进行 10折交叉验证时，准确率随特征维度的变化情况。显然，识别准确率的变化趋势与图 6 相似，即先上升而后下降。最高平均准确率在特征维度为 5000 时，准确率为 95.93%。相应的箱线图显示，最高准确率为 96.30%，最低准确率为 94.44%，平均 F1分数为 95.56%。此外，相应的箱线图还显示其平均方差较低（5.49E-05），表明该特征维度具有稳定性。在这种情况下，平均训练时间为 113.07 秒。

表 IX 对比了本文提出的分类方案与已发表的、针对 WESAD 数据集上单通道心电图情绪识别方法的最先进方法。采用相同的测试数据集，确保了比较具有说服力且可行。从表 IX 可以看出，本文提出的分类方法优于所有简单的机器学习方法，例如随机森林、K近邻、线性判别分析和决策树。尽管其表现略逊于自监督卷积神经网络，但本文提出的 X-GWO-SVM 技术在分类性能上可与深度神经网络相媲美。然而，考虑到计算复杂度，本文提出的方法比自监督卷积神经网络简单得多、效率也更高。我们的算法已成功部署到轻量级嵌入式系统中，对每个包含 200 个点的 iRealcare 样本和每个包含 14000 个点的 WESAD 样本，预测时间分别为 2.659 毫秒和 4.648 毫秒。关于这些结果的详细信息将在 V-C3 节中讨论。总的来说，本文提出的 X-GWO-SVM 方法在 WESAD 数据集上取得了可与基于神经网络的深度学习分类器相媲美的准确率和 F1 分数（图 7 和表 IX），并且在其他现有技术中表现出压倒性优势。

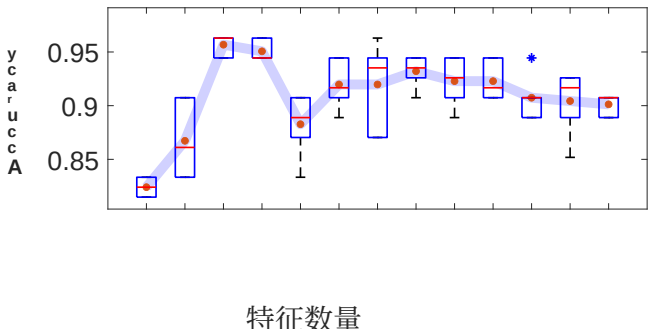

图7。**在 WESAD 数据集上使用 X-GWO-SVM-SVM 算法进行 10折交叉验证时，准确率随特征维度的变化情况。**

表 IX WESAD 数据集上各种基于单通道心电图的情绪识别方法比较

参考文献	Year	方法	准确率/%	F1/%
Schmidt 等人 [43]	2018	RF	82.78	79.64
		K-NN	79.19	75.39
		线性判别分析	85.44	81.31
		AdaBoost 决策树	83.37	80.20
		决策树	80.17	77.01
Lin 等人 [47]	2019	CNN	83.00	81.00
Sarkar 等人 [29]	2020	自监督卷积神经网络	96.90	96.30
		全监督卷积神经网络	93.20	91.20
所提出的工作	——	**X-GWO-SVM**	**95.93**	**95.56**

五、讨论

本文首次提出 X-GWO-SVM 算法，并首次将其用于基于单通道心电图的情绪识别。通过设计合适的探索—开发调节函数和更新技术，我们能够利用所提出的方法提升探索能力和开发能力。本文使用了两个心电图数据集：

一个是原始的自行采集的 iRealcare 数据集，另一个是可靠的 WESAD 数据集。X-GWO-SVM 技术能够有效避免算法陷入局部解，因此，在心电图情绪识别方面，其识别准确率高于现有的 GWO-SVM 和 PSO-SVM 技术。

该算法能够基于单通道心电图信号实现准确、稳定且高效的情绪识别，填补了 GWO-SVM研究在基于心电图的情绪识别方面的空白，并且具有临床应用潜力。

A. 数据集评估

尽管 iRealcare数据集中的受试者数量有限，但由于每种情绪的数据采集时间充足，因此每位受试者的样本数量也足够。诚然，WESAD 数据集包含更多受试者；然而，该数据集要达到较高准确率所需的样本长度为 14000，这大幅减少了实际样本数量。例如，对于愉悦状态，每位受试者有 9 个样本；对于压力状态，每位受试者有 15–18 个样本；对于基线状态，每位受试者有 28–29 个样本。相比之下，iRealcare数据集达到较高准确率所需的样本长度仅为 200。因此，iRealcare数据集的样本数量远多于 WESAD 数据集。

造成上述情况的原因可能与外部刺激的提供方式以及数据记录方式有关。对于 iRealcare数据集，受试者分别在观看喜剧片、观看惊悚片和进行锻炼时，记录快乐、紧张和兴奋状态下的心电信号。需要注意的是，情绪通常会瞬间产生，并持续较短时间。因此，我们只记录受试者实际处于相应情绪状态的时段，并忽略过渡期。显然，在这种外部刺激设置下，不同情绪的定义很明确，受试者也很容易进入特定情绪状态。然而，对于 WESAD 数据集，受试者观看有趣的视频片段时采集愉悦状态下的信号；受试者被要求进行公开演讲和心算任务时采集压力状态下的信号；受试者坐在或站在桌旁阅读杂志时采集基线状态下的信号。事实上，受试者往往需要一些时间才能从一种情绪状态转变到另一种状态。然而，WESAD 数据集中也记录了这一过渡期。因此，样本长度需要足够长，以确保纳入的不只是过渡期。时间越短，样本中只包含过渡期的可能性就越大。

总而言之，尽管 iRealcare 数据集的受试者数量有限，但其实际样本数量远多于 WESAD 数据集。此外，由于 WESAD 数据集有专属的情绪过渡期，iRealcare 数据集的样本长度选择比 WESAD 数据集更加灵活。我们采用广泛使用的 WESAD 数据集作为基准，进行进一步比较，以验证所提出的 X-GWO-SVM 算法。

B. 探索-开发调节函数选择的评估

我们研究探索-开发调节函数对情绪识别性能的影响。在这项研究中，我们选取了可能的基函数，用于控制各探索-开发调节函数的重要性，如方程 (15) 至 (19) 所示。表 II 和表 III 分别展示了五种探索 - 开发调节函数在 iRealcare 数据集和 WESAD 数据集上的情绪识别性能。这项分析深入揭示了与情绪识别结果相关的探索-开发调节函数的影响。此外，这项分析有助于我们筛选出最合适的探索-开发调节函数，从而实现最佳性能。

正如第二节 III-B 所述，探索-开发调节函数在迭代开始和结束时相对于迭代时间的下降速率，体现了所提出的 X-GWO-SVM 的探索能力和开发能力。从表 II 和表 III 可以看出，对于探索-开发调节函数 $f_{\phi 3}$（该函数基于 Sigmoid函数 构造），由于探索和开发均不足，模型在情绪识别上的表现较差。然而，对于那些位于基准函数 $f_{\phi 1}$ 之上的探索 - 开发调节函数，模型表现明显更好。有趣的是，当探索-开发调节函数下降过快（$f_{\phi 2}$）或过慢（$f_{\phi 5}$）时，性能会有所下降。与其他函数相比，函数 $f_{\phi 4}$ 在情绪识别方面取得了最高性能，因为它具有最适合 X-GWO-SVM算法 的发散与收敛性能。此外，$f_{\phi 4}$在两个数据集上的表现均优于其他函数，这也表明其具有良好的稳定性。

总之，上述分析表明，对于所有探索-开发调节函数，当函数在初始阶段的下降速率过大或过小时，例如 $f_{\phi 3}$ 或 $f_{\phi 2}$，情绪识别准确率会因探索不足或过度探索而下降，从而使 X-GWO-SVM 更容易陷入局部解。同样，当函数在末尾阶段的下降速率过大或过小时，例如 $f_{\phi 2}$ 或 $f_{\phi 3}$，性能也会因开发不足或过度开发而下降；在这种情况下，算法将难以正确找到全局解。因此，我们得出结论：对于所提出的 X-GWO-SVM 算法所采用的探索-开发调节函数，探索与开发之间存在权衡。采用恰当的探索-开发调节函数 $f_{\phi 4}$ ，可避免陷入局部解。

C. X-GWO-SVM 的可靠性、稳定性和效率评估

本节从可靠性、稳定性和效率三个方面讨论 X-GWO-SVM 在情绪识别中的性能。

1）可靠性：在我们的研究中，仅将探索-开发调节函数 $f_{\phi 4}$ 与 GWO-SVM 融合，即采用 N-GWO-SVM 时，分类准确率和 F1分数均有所提高（参见表 IV、表 V 和表 VII）。这一改进表明，引入非线性探索-开发调节函数能够提升识别性能。同样，当强调 α 狼的重要性时，即采用 X-GWO-SVM，分类准确率和 F1分数进一步提高，这表明改进对 X-GWO-SVM 同样重要。

X-GWO-SVM 的分类性能优于其他基于超参数优化器的系统，例如 PSO-SVM 和 GWO-SVM。这表明，与现有常见的基于超参数优化器的方案相比，所提出的算法具有较高的可靠性。此外，在简单机器学习方法中，例如随机森林、K近邻、决策树和线性判别分析，X-GWO-SVM 的准确率和 F1分数最高（表 VIII 和表 IX）。我们的分析表明，与简单的机器学习方法相比，X-GWO-SVM 更能有效避免局部解。对于卷积神经网络等深度学习神经网络，除一种更复杂的单一自监督卷积神经网络 [29] 外，X-GWO-SVM 仍然能够胜过它们。尽管 X-GWO-SVM 的准确率和 F1分数略低于自监督卷积神经网络，但考虑到效率（将在 V-C3 节讨论），我们的算法仍具有竞争力。

2）稳定性：通过计算所提出方法和现有方法的方差，评估各方法的稳定性。所有仿真结果均采用 10 折交叉验证。与第 V-C1 节中的讨论类似，在现有常见的基于超参数优化器的方案中，X-GWO-SVM 是最稳定的算法。此外，在 iRealcare 数据集和 WESAD 数据集上得到的相似结果也表明了所提出方法的稳定性。

3）效率：我们的工作通过 MATLAB R2021b 版和 Python 3.7 实现，用于特征提取、模型训练和预测。对于 MATLAB，计算在一台配备第 11 代 Intel(R) Core(TM) i7-11800H（2.2GHz、32GB RAM）的笔记本电脑上进行。使用我们提出的方法，对一个包含 200 个点（1.56s）的 iRealcare 样本和一个包含 14000 个点（20s）的 WESAD 样本进行分类，计算时间分别约为 0.355ms 和 0.778ms。对于 Python，计算在配备四核 ARM Cortex-A57 MPCore 处理器（1.43GHz、4GB RAM）的 JETSON NANO 上进行。使用我们提出的方法，对一个包含 200 个点（1.56s）的 iRealcare 样本和一个包含 14000 个点（20s）的 WESAD 样本进行分类，计算时间分别约为 2.659ms 和 4.648ms。

与自监督卷积神经网络这一深度神经网络相比，所提出的 X-GWO-SVM 简单得多。两步式自监督架构包含深度卷积块和若干全连接层， [29], 而这些可能无法在轻量级嵌入式系统中实现。相比之下，我们的算法已成功部署到 JETSON NANO 上。JETSON NANO 是一款嵌入式系统模块和开发套件；在该平台上，每个 200 点的 iRealcare 样本的预测时间为 2.659 ms，每个 14000 点的 WESAD 样本的预测时间为 4.648 ms。这为将搭载所提出算法的心电贴片嵌入设备提供了一种途径，从而实现基于心电信号的情绪识别边缘计算。

此外，以训练时间为评估指标，X-GWO-SVM 是现有常见超参数优化器方案中效率最高的算法。表 VII 中还可以发现另一个有趣的现象：所有基于GWO-SVM的技术的训练时间都短于 PSO-SVM 研究，这与 [35]的结论一致。

D. 局限性与未来方向

本研究可能存在的局限性是，我们仅考察了四种探索-开发调节函数，即 $f_{\phi 2}$、 $f_{\phi 3}$、 $f_{\phi 4}$ 和 $f_{\phi 5}$。此外，我们收集的数据集仍不充分，其他已发表的数据集（例如 AMIGOS [27], 奥格斯堡生物信号工具箱（AuBT） [54], 等）尚未通过所提出的 X-GWO-SVM 算法进行验证。未来，我们将采用其他探索-开发调节函数应用于所提出的算法，以探索它们在情绪识别中的有效性。此外，我们的方法还将用于考察更多已发表的数据集。

此外，通过[29], 中报告的结果和结论，我们还发现深度学习在情绪识别方面具有竞争力，这可能进一步提升我们所提出策略的性能。因此，在未来的工作中，我们将尝试寻找一种有效的深度学习方法，并嵌入 GWO 方法，以进一步提升情绪识别性能。

VI. 结论

本文提出了一种 X-GWO-SVM 技术，以提升基于单通道心电图的情绪识别中的探索与开发能力。为对不同情绪进行分类，本研究使用了两个可靠的数据集：一个可信的 WESAD 数据集，以及一个原始的自行采集 i Realcare 数据集。根据 iRealcare 数据集 5 名受试者和 WE-SAD 数据集 15 名受试者的 10 折交叉验证结果，X-GWO-SVM 算法能够有效利用单通道心电信号进行情绪识别。该算法的表现优于以往采用各种监督式机器学习技术的研究。它还提供了一种在轻量级嵌入式系统中实现的方法，其效率远高于现有的深度神经网络方案。该方法有望应用于临床环境，也填补了 GWO-SVM研究在基于心电图的情绪识别方面的空白。在未来的工作中，我们将采用无线电感知技术，例如 [42],[55]–[58],，取代可穿戴设备进行情绪识别。我们还将开发隐私保护算法 [59]–[62], 以保护用户隐私。

参考文献

[1] https://iot-analytics.com/number-connected-iot-device s/

[2] J. Leng、Z. Lin 和 P. Wang，“面向智慧医院的物联网系统实现”，2020年IEEE/ACM第五届物联网设计与实现国际会议 (IoTDI)，254–255，2020年。[3] D. Zhai、H. Chen、Z. Lin、Y. Li 和 B. Vucetic，“先累积后传输：全双工无线供电物联网系统中的多用户调度”，IEEE物联网期刊，第 5 卷，第 4 期，2018年8月。[4] J. Wang、B. Li、G. Wang、Z. Lin、H. Wang 和 G. Chen，“物联网网络中具有直达链路的 MIMO SWIPT中继系统的最优功率分配”，《Physical Communication》，第 43 卷，2020年12月。[5] Z Lin、B Vucetic，“采用机会调度的无线网络编码功率与速率自适应”，2008年IEEE信息论国际研讨会，21 25 - T Ding、[6] M Ding、G Mao、Z Lin、AY Zomaya、D L´opez-P´erez，“采用动态 TDD 的密集小蜂窝网络性能分析”，IEEE《车辆技术汇刊》67 (10)，9816-9830，2018年。[7] P Wang、G Mao、Z Lin、X Ge、BDO Anderson，“具有性能保证的基于网络编码的无线广播”，IEEE《无线通信汇刊》14 (1)，532-544，2014年。[8] K Pang、Z Lin、Y Li、B Vucetic，“通过短环消除设计分布式网络信道码”，IEEE《无线通信快报》2 (1)，62-65，2012年。[9] J. Yue；Z. Lin；B. Vucetic；G. Mao；M. Xiao；B. Bai；K. Pang，“无线中继网络中的网络码分复用”，IEEE《无线通信汇刊》，第14卷，第10期，第5736-5749页，2015年10月。[10] J. Yue、Z. Lin、B. Vucetic、G. Mao、T. Aulin，“无线传感器网络中分布式Raptor码的性能分析”，IEEE《通信汇刊》61 (10)，2013年，4357-4368[11] P. Wang、G. Mao、Z. Lin、M Ding、W. Liang、X. Ge、Z. Lin，“最大似然译码下 Raptor 码的性能分析”，IEEE《通信汇刊》64 (3)，2016年，906-917[12] K. Pang、Z. Lin、Y. Li、B. Vucetic，“真实无线中继网络的联合网络信道码设计”，第六届Turbo码与迭代信息国际研讨会，2010年，429-433。[13] Z. Lin、A. Svensson，“新型速率兼容重复卷积码”，IEEE《信息论汇刊》46 7 2651 2659 ( )，-[14] Z. Lin，“无线网络中的网络编码方案设计”，CRC Press Taylor & Francis。图书，ISBN：9781032067766，2022[15] June F. Yu、E. Chang、Y.-Q. Xu 和 H.-Y. Shum，“通过语音情绪检测丰富多媒体内容”，载于太平洋-环太平洋多媒体会议论文集，2001年，第550–557页。[16] L. C. De Silva、T. Miyasato 和 R. Nakatsu，“利用多模态信息进行面部情绪识别”，载于*1997*年信息、通信与信号处理国际会议论文集。主题：信息系统工程与无线多媒体通信趋势，第1卷，1997年，第397–401页。[17] Y.-L. Hsu、J.-S. Wang、W.-C. Chiang 和 C.-H. Hung，“音乐聆听中的自动心电图情绪识别”，*IEEE*《情感计算汇刊》，第11卷，第1期，第85–99页，2017年。[18] X. Yan、D. Yang、Z. Lin 和 B. Vucetic，“用于癫痫发作检测的显著低维时频特征”，*IEEE*《神经系统与康复工程汇刊》，第30卷，677，2022年 668页。– 。[19] W. Meng、Y. Cai、L. T. Yang 和 W.-Y. Chiu，“基于脑电波、面向医疗物联网的混合式情绪感知监测系统”，*IEEE*物联网期刊，第8卷，第21期，第16 014–16 022页，2021年。[20] Y. Du、J. Liu、X. Wang 和 P. Wang，“通过多目标神经架构搜索实现面向物联网的基于稳态视觉诱发电位的情绪识别”，*IEEE*物联网期刊，第1–1页，2022年。[21] M. U. Zahid、S. Kiranyaz、T. Ince、O. C. Devecioglu、M. E. Chowdhury、A. Khandakar、A. Tahir 和 M. Gabbouj，“使用一维卷积神经网络检测低质量动态心电图中的 R 峰”，*IEEE*《生物医学工程汇刊》，第69卷，128，2021年 1，第119页。– 。[22] J. T. Cacioppo、L. G. Tassinary 和 G. Berntson，心理生理学手册。剑桥大学出版社，2007年。[23] F. Agrafioti、D. Hatzinakos 和 A. K. Anderson，“用于情绪检测的心电图模式分析”，*IEEE*《情感计算汇刊》，第3卷，第1期，第102–115页，2012年。[24] Z. Cheng、L. Shu、J. Xie 和 C. P. Chen，“一种面向可穿戴应用的新型基于心电图的负面情绪实时检测方法”，载于*2017*年安全、模式分析与网络科学国际会议 *(SPAC)* 论文集，2017年，第296–301页。

[25] D. Reney和N. Tripathi，《一种高效的人脸与情绪检测方法》，载于《2015年第五届通信系统与网络技术国际会议论文集》，2015年，第493–497页。[26] B. C. Ko，《基于视觉信息的面部情绪识别简述》，Sensors，第18卷，第401–401页，2018年。[27] L. Shu、J. Xie、M. Yang、Z. Li、Z. Li、D. Liao、X. Xu和X. Yang，《利用生理信号进行情绪识别的综述》，Sensors，第18卷，第7期，第2074–2074页，2018年。[28] M. A. Hasnul、N. A. A. Aziz、S. Alelyani、M. Mohana和A. A. Aziz，《基于心电图的情绪识别系统及其在医疗保健中的应用——综述》，Sensors，第21卷，第15期，第5015–5015页，2021年。[29] P. Sarkar和A. Etemad，《用于情绪识别的自监督心电图表征学习》，IEEE《情感计算汇刊》，第1–1页，2020年。[30] N. Jain、S. Kumar、A. Kumar、P. Shamsolmoali和M. Zareapoor，《用于面部情绪识别的混合深度神经网络》，《模式识别快报》，第115卷，第101–106页，2018年。[31] J. Wainer和P. Fonseca，《如何调节径向基函数支持向量机的超参数？对18种搜索算法的实证评估》，《人工智能评论》，第54卷，第4771–4797页，2021年。[32] J. Zhou、S. Huang、M. Wang和Y. Qiu，《混合遗传算法–支持向量机和灰狼优化–支持向量机模型在预测地震诱发土壤液化潜势方面的性能评估：一项多数据集研究》，《计算机辅助工程》，第1–19页，2021年。[33] B. Li、C. Luo和Z. Wang，《GWO-SVM算法在受电弓电弧检测中的应用》，IEEE Access，第8卷，173 873，2020 173 865页。[34] Y. Wei、N. Ni、D. Liu、H. Chen、M. Wang、Q. Li、X. Cui和H. Ye，《一种改进的灰狼优化策略增强型支持向量机及其在预测第二主要……中的应用》，《工程数学问题》，2017年，第1–12页。[35] E. Emary、H. M. Zawbaa、C. Grosan和A. E. Hassenian，《基于灰狼优化的特征子集选择方法》，载于《非洲-欧洲工业发展会议论文集》，A. Abraham、P. Kr¨omer和V. Snasel编。施普林格国际出版公司，2015年，第1–13页。[36] Z. Zhou、R. Zhang、Y. Wang、Z. Zhu和J. Zhang，《基于改进灰狼算法优化支持向量机的色差分类》，《Optik》，第170卷，第17–29页，2018年。[37] C. Li、C. Zheng和C. Tai，《利用小波变换检测心电图特征点》，IEEE《生物医学工程汇刊》，第42卷，第1期，第21–28页，1995年。[38] L. Meng、K. Ge、Y. Song、D. Yang和Z. Lin，《基于卷积神经网络的可穿戴心电信号监测与分析》，IEEE仪器与测量汇刊，第70卷，第1–11页，2021年。[39] Z. Chen、Z. Lin、P. Wang和M. Ding，《Negative-resnet：嘈杂动态心电信号分类方案》，《神经计算与应用》，第33卷，第14期，第8857–8869页，2021年。[40] P. Wang、Z. Lin、X. Yan、Z. Chen、M. Ding、Y. Song和L. Meng，《用于实时心血管疾病检测的基于深度学习的可穿戴心电图监测仪》，arXiv预印本 arXiv:2201.10083，2022年。[41] X. Yan、Z. Lin和P. Wang，《基于小波卷积神经网络的无线心电图监测》，载于《2020年IEEE无线通信与网络会议研讨会（WCNCW）论文集》，2020年，第1–6页。[42] M. Liu、Z. Lin、P. Xiao和W. Xiang，《基于深度学习、利用Wi-Fi信道状态信息监测人体生物特征信号》，arXiv预印本 arXiv:2203.03980，2022年。[43] P. Schmidt、A. Reiss、R. Duerichen、C. Marberger和K. Van Laerhoven，《介绍WESAD：用于可穿戴压力与情感检测的多模态数据集》，载于《第20届ACM多模态交互国际会议论文集》，2018年，第400–408页。[44] A. Velayudhan和S. Peter，《心电信号噪声分析及不同去噪技术综述》，IOSR电子与通信工程期刊，第1卷，第1期，第40–44页，2016年。[45] R. Kher，《去除心电信号噪声的信号处理技术》，《生物医学工程研究》，第3卷，第101期，第1–9页，2019年。[46] R. Pal，《给定规格下FIR和IIR滤波器的设计比较，以及消除IIR滤波器的相位失真》，载于《2017年计算、通信与控制进展国际会议（ICAC3）论文集》，2017年，第1–3页。[47] J. Lin、S. Pan、C. S. Lee和S. Oviatt，《一种利用生理信号进行情感识别的可解释深度融合网络》，载于《第28届ACM信息与知识管理国际会议论文集》

, 2019, 第2069–2072页。

[48] A. Jain 和 G. Rathna，“使用离散余弦变换和局部二值模式特征进行孤立数字的视觉语音识别”，载于*2017*年*IEEE*全球信号与信息处理大会（*GlobalSIP*）论文集，2017年，第368–372页。[49] M. D. Hafed，Ziad M. andLevine，“使用离散余弦变换进行人脸识别”，《国际计算机视觉杂志》，第43卷，第167—188页，2001年。[50] N. Ahmed、T. Natarajan 和 K. R. Rao，“离散余弦变换”，《*IEEE*计算机汇刊》，第100卷，第1期，第90–93页，1974年。[51] Z. Qian、C. Zhou、J. Cheng 和 Q. Wang，“基于多分类PSO-SVM的电力电缆导电泄漏信号识别”，载于*2017*年*IEEE*第五届电磁兼容国际研讨会（*EMC-Beijing*）论文集，2017年，第1–4页。[52] A. Tharwat，“核函数支持向量机分类器的参数研究”，《知识与信息系统》，第61卷，第3期，第1269–1302页，2019年。[53] S. Mirjalili、S. M. Mirjalili 和 A. Lewis，“灰狼优化器”，《工程软件进展》，第69卷，第46–61页，2014年。[54] J. Wagner、J. Kim 和 E. Andr´e，“从生理信号到情绪：选定特征提取和分类方法的实现与比较”，载于*2005*年*IEEE*多媒体与博览会国际会议论文集，2005年，第940–943页。[55] X. Wang 和 Z. Lin，“非随机微波鬼成像”，《IEEE地球科学与遥感汇刊》，第56卷，第8期，第4747–4764页，2018年。[56] X. Wang 和 Z. Lin，“基于鬼成像和分布式天线的微波监控”，《IEEE天线与无线传播快报》，第15卷，第1831–1834页，2016年。[57] Z. Zhang、R. Luo、X. Wang 和 Z. Lin，“基于LTE-DL信号的微波鬼成像”，载于2018年国际雷达会议（RADAR），2018，1 5 第–页。R. Luo、Z. Zhang、X. Wang 和 Z. Lin，“基于Wi-Fi的无设备微波鬼成像室内监控系统”，载于2018年第28届国际电信网络与应用会议（ITNAC），2018年，第1–6页。[59] B. Liu、M. Ding、S. Shaham、W. Rahayu、F. Farokhi 和 Z. Lin，“机器学习与隐私相遇：综述与展望”，《ACM计算调查》，《ACM计算调查》（影响因子10.282），出版日期：2021 03 05，10 1145 3436755 - - DOI：. / S. Shaham、M. Ding、B. Liu、S. Dang、Z. Lin、J. Li，“基于位置的服务中的隐私保护：一种新颖的度量指标与攻击模型”，《IEEE移动计算汇刊》，第20卷，第10期，第3006-3019页，2021年10月1日。doi：10.1109/TMC.2020.2993599。[61] S. Shaham、M. Ding、B. Liu、S. Dang、Z. Lin、J. Li，“隐私保护的位置数据发布：一种机器学习方法”，《IEEE知识与数据工程汇刊》，第33卷，第9期，第3270-3283页，2021年9月1日。doi：10.1109/TKDE.2020.2964658。[62] D. Smith、P. Wang、M. Ding、J. Chan、B. Spak、X. Guan、P.Tyler、T. Rakotoarivelo、Z. Lin、T. Abbasi，“邻域网络的隐私保护最优能源交易、统计与预测”，载于《Computer》，第53卷，第05期，第25-34页，2020年。doi：10.1109/MC.2020.2972505