

DOI:10.19651/j.cnki.emt.2314901

# 基于多模态轻量化混合模型的情绪识别

彭军强<sup>1</sup> 张立坤<sup>1</sup> 杨亚楠<sup>2</sup>

(1.天津工业大学机械工程学院 天津 300387; 2.天津工业大学电子与信息工程学院 天津 300387)

**摘要:** 实现更加准确的情绪识别是当前面临的一项富含挑战性且十分有意义的任务。由于情绪的复杂多样性,单一模态的脑电信号难以对情绪进行全面客观的度量。因此本文提出一种多模态轻量化混合模型 PCA-MWRRelief-GAPSO-SVM,该混合模型由 PCA-MWRRelief 特征通道选择器和 GAPSO-SVM 分类器构成。选用脑电信号(EEG)、肌电信号(EMG)、体温信号(TEM)三模态信号进行情绪识别。在 DEAP 公共数据集上进行多次实验验证,在效价维度、唤醒维度和四分类中分别取得了 97.500 0%、95.833 3%、95.833 3% 的分类准确率。实验结果表明,提出的混合模型有助于提高情绪识别准确率且明显优于单模态情绪识别。与近期的类似工作相比,本文提出的混合模型具有较高准确率、计算量小且通道数少的优点,更易于实际应用。

**关键词:** 情绪识别;多模态信号融合;EEG;EMG;TEM;支持向量机

**中图分类号:** TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.50

## Emotion recognition based on multi-modal lightweight hybrid model

Peng Junqiang<sup>1</sup> Zhang Likun<sup>1</sup> Yang Yanan<sup>2</sup>

(1. School of Mechanical Engineering, Tianjin Polytechnic University, Tianjin 300387, China;

2. School of Electronic and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China)

**Abstract:** It is a challenging and meaningful task to achieve more accurate emotion recognition. Because of the complex diversity of emotions, it is difficult to measure emotions comprehensively and objectively with a single mode of EEG signal. Therefore, a multi-modal lightweight hybrid model PCA-MWRRelief-GAPSO-SVM is proposed in this paper. The hybrid model consists of a PCA-MWRRelief feature channel selector and a GAPSO-SVM classifier. Electroencephalogram (EEG), electromyographic signal (EMG) and temperature signal (TEM) were used for emotion recognition. Through many experiments on DEAP public data set, the classification accuracy of 97.500 0%, 95.833 3% and 95.833 3% in titer dimension, wake dimension and four categories were obtained, respectively. The experimental results show that the proposed mixed model can improve the emotion recognition accuracy and is significantly better than the single mode emotion recognition. Compared with the recent similar work, the hybrid model proposed in this paper has the advantages of higher accuracy, less computation and fewer channels, and is easier to be applied in practice.

**Keywords:** emotion recognition; multimode signal fusion; EEG; EMG; TEM; support vector machine

## 0 引言

情绪(emotion)是人的感觉、思想和行为的综合状态<sup>[1]</sup>,在情感识别过程中发挥着重要的作用。情绪识别是当前脑机接口领域研究的热点之一<sup>[2]</sup>,它在情感脑机接口、情绪相关疾病的诊断、智能医疗、远程教育、驾驶状态检测等领域具有广阔的应用前景<sup>[3-6]</sup>。如何更加准确的对情绪进行识别仍是当前人机交互领域有待解决的问题之一。

通过多模态特征融合实现高性能的目标识别分类仍是

当前面临的一个难题<sup>[7]</sup>。单模态的特征识别精度较低,实时性差<sup>[8]</sup>。基于此,研究者将注意力投向多模态数据集的研究中。英国 Sander Koelstra 团队提供了 DEAP 情感数据库,旨在通过机器学习方法识别人类的情绪进一步改善生活<sup>[9]</sup>。本文选择在脑电信号(electroencephalogram, EEG)和肌电信号(electromyography, EMG)的基础上加入体温信号(temperature, TEM)进行情绪识别。原因在于强烈的情感会刺激人的神经,快乐时,身体发热;抑郁时,手脚变冷,一定程度上导致温度的变化。

提取有效的特征是进行情绪分类的前提条件。宋世林等<sup>[10]</sup>以共空间模式(common spatial pattern, CSP)作为特征,所提方法获得了 91.66% 的准确率。吴文一<sup>[11]</sup>以不对称指数作为特征,五分类下获得 70.20% 的准确率。隋修武等<sup>[12]</sup>以肌分肌电值作为特征,进行 EMG 情绪识别,准确率达 91.7%。本文选择 CSP 和差异不对称性作为 EEG 的特征,选择积分肌电值、平均绝对值和均值标准差作为 EMG 的特征,选择平均振幅、平均功率和中位振幅作为 TEM 的特征,进行后续的情绪识别。

分类器也是影响情感识别的关键因素。王琳虹等<sup>[13]</sup>以 EEG 为研究对象,发现支持向量机(support vector machine, SVM)的分类效果优于 K 近邻和线性判别分析。为了更好地提高分类效果,研究者使用粒子群算法(particle swarm optimization, PSO)、遗传算法(genetic algorithm, GA)等对 SVM 进行优化。由于原始的 SVM 算法存在一定缺陷,研究者进一步转向对算法优化的研究中。王彩云等<sup>[14]</sup>引入非线性自适应时变惯性权重,引入局部算子更新粒子位置。柯钢等<sup>[15]</sup>通过更改自适应权重,引入随机扰动因子和变异操作对粒子群进行优化。本文在此基础上提出 GAPSO-SVM 分类模型,该分类模型与近期类似工作相比,可显著提高分类精度。

情绪识别的研究在不断的发展,众多研究者投身于混合模型的研究中,宗静等<sup>[16]</sup>引入混合模型 FCAN-FFM-LightGBM 对情绪进行分类识别,取得较高分类准确率。朱丽等<sup>[17]</sup>提出一种 CNN 和 Bi-LSTM 的混合模型,在效价和唤醒维度上获得了 88.55% 和 89.07% 的分类准确率。赵丹丹等<sup>[18]</sup>提出 DE-CNN-GRU 混合模型,在公开数据集上取得了 86.50% 的分类准确率。毕晓军等<sup>[19]</sup>在 LSTM 的基础上提出深度学习混合网络 C-NTM,取得了 94.50% 的准确率。陈景霞等<sup>[20]</sup>提出 CASC-CNN-LSTM 和 CASC-CNN-CNN 两种混合深度模型,在 EEG 情感分类中分别达到了 93.15% 和 92.37% 的分类准确率。虽然混合模型可以提高情绪识别准确率,但也存在计算成本过大的缺点。如果计算量过于庞大,那么该模型就缺乏实际应用意义。

针对已有混合模型存在分类准确率较低且计算成本较大的问题,本文提出一种多模态轻量化混合模型 PCA-MWReliefF-GAPSO-SVM,选用 EEG、EMG 信号的同时,选择添加体温(TEM)信号进行情绪识别,旨在进一步提高分类准确率并且减少通道数和计算成本,减少受试者因采集时间较长而出现的不适。该模型主要优点如下:

1) 选择更易于被实际应用中采集的体温信号代替其他研究者使用的眼电和心电等信号,通过多模态融合获得更全面的情绪特征。

2) 本文使用 PCA-MWReliefF 特征通道选择算法大大减少了计算量和通道数,更易于被实际应用。

3) 本文使用 GAPSO-SVM 分类器,利用非线性特征对遗传算法和粒子群算法进行优化,解决陷入局部最优问题

的同时对 SVM 的惩罚参数(cost, C)和核函数参数(gamma, G)进行优化,进一步提高分类准确率。

## 1 主成分分析和 MWReliefF 算法

### 1.1 主成分分析

主成分分析法是将  $n$  维特征映射到  $k$  维上( $k < n$ ),  $k$  维是全新的正交特征。

情绪识别实验中每种情绪得到 600 个实验样本,对于得到的一组数据,求其样本均值,如式(1)所示。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

式中:  $x_i$  表示实验样本,  $n$  表示实验样本数。计算实验样本的样本方差,如式(2)所示。

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2)$$

通过求得的样本方差  $S^2$  计算两个样本之间的协方差,如式(3)所示。

$$\text{Cov}(X, Y) = E[(X - E(X))(Y - E(Y))] \quad (3)$$

式中:  $E(X)$  表示  $X$  的期望,  $E(Y)$  表示  $Y$  的期望,  $X - E(X)$  表示  $X$  的偏离值,  $Y - E(Y)$  表示  $Y$  的偏离值。

协方差用来衡量  $X$  和  $Y$  之间的线性关系和它们的变化趋势。当协方差为 0 时,说明  $X$  和  $Y$  变量之间是线性无关的。将所有样本的列向量组成的矩阵  $X$ , 由式(4)可得两两数据之间的协方差矩阵,如式(5)所示。

$$\frac{1}{n} \mathbf{X} \mathbf{X}^T \quad (4)$$

$$\text{Cov}(X, Y, Z) = \begin{pmatrix} \text{Cov}(x, x) & \text{Cov}(x, y) & \text{Cov}(x, z) \\ \text{Cov}(y, x) & \text{Cov}(y, y) & \text{Cov}(y, z) \\ \text{Cov}(z, x) & \text{Cov}(z, y) & \text{Cov}(z, z) \end{pmatrix} \quad (5)$$

式中:  $\text{Cov}(x, x)$  表示  $x$  与  $x$  变量之间的协方差。协方差矩阵对角化即可得到对角线上最大的  $k$  个方差。对协方差矩阵求其特征向量,选出最大的  $k$  个向量单位化即可作为 PCA 所需要的  $k$  个基向量,经过基向量变换,可实现数据的降维。

### 1.2 MWReliefF 算法

Kira 在 1992 年提出 Relief 算法<sup>[21]</sup>, 该算法对每一种特征赋予权值,根据每个特征的权值得到最适合分类的特征,进而实现特征选择降维。Relief 算法仅支持二分类情况,所以在 Relief 算法的基础上 Kira 等<sup>[22]</sup>提出了适合四分类的 ReliefF 算法,通过设定权值阈值筛选出利于分类的特征。

ReliefF 算法的思想是:对通道内的特征,选择  $n$  个样本,然后从样本中选择与这个样本最相邻的  $k$  个同类别样本和  $k$  个不同类别样本,不断更新权重,重复得到每一个选择样本的权重值。如式(6)所示。

$$\mathbf{W}^{i+1}(f_l) = \mathbf{W}^i(f_l) - \frac{\sum_{j=1}^k \text{diff}(f_l, R_i, H_j)}{n \times k} + \sum_{C \neq \text{label}(R_i)} \frac{R(C)}{1 - P(\text{label}(R_i))} \cdot \sum_{j=1}^k \frac{\text{diff}(f_l, R_i, M_j(C))}{n \times k} \quad (6)$$

其中,  $k$  取 10 的效果是比较好的<sup>[23]</sup>,  $\mathbf{W}^i(f_l)$  表示第  $i$  次迭代得到第  $l$  个特征的权重值,  $R(C)$  表示类别所占比例。通过 ReliefF 算法一定程度上减少特征矩阵的维度, 减少计算量。

在此基础上, 通过每个通道特征的权重值得到对应通道的权重值, 作为通道选择的依据。计算方法如下:

1) MRReliefF: 计算通道特征权重的均值作为最终通道的权重值。如式(7)所示。

$$\mathbf{W}(l) = \frac{1}{N} \sum_{i=1}^N \mathbf{W}(f_{li}) \quad (7)$$

式中:  $N$  表示通道  $l$  包含的特征数量,  $\mathbf{W}(f_{li})$  表示通道内第  $i$  个特征。

2) RRReliefF: 计算通道内中间权重值作为最终通道的权重值。每个通道权重值排序后如式(8)所示。

$$\mathbf{W}' = \begin{pmatrix} \mathbf{w}_{11} & \cdots & \mathbf{w}_{1n} \\ \vdots & \ddots & \vdots \\ \mathbf{w}_{m1} & \cdots & \mathbf{w}_{mn} \end{pmatrix} \quad (8)$$

式中:  $m$  表示通道数,  $n$  表示每个通道权重值,  $\mathbf{w}_{ij}$  表示第  $i$  个通道的第  $j$  个权重值。中间权重值计算如式(9)所示。

$$\mathbf{W}(l) = \left( \sum \mathbf{w}[i][\lfloor (n+1)/2 \rfloor] * n_i \right) / \left( \sum n_i \right) \quad (9)$$

式中:  $i$  表示通道索引,  $n_i$  表示第  $i$  个通道的权重值数量。

3) NRReliefF: 计算通道内特征权重的求和值来作为最终通道的权重值。如式(10)所示。

$$\mathbf{W}(l) = \sum_{i=1}^N \mathbf{W}(f_{li}) \quad (10)$$

在以上研究实验的基础上引进新颖的 MWRReliefF 算法: 根据每个特征的权重和所在通道的比例, 计算每个通道的加权平均权重作为最终通道的权重值。如式(11)所示。

$$\mathbf{W}(l) = \frac{1}{n} \sum_{i=1}^n (\mathbf{w}[i][j]) \quad (11)$$

式中:  $\mathbf{W}$  是一个  $n \times m$  矩阵,  $\mathbf{w}[i][j]$  表示第  $i$  个特征在第  $j$  个通道上的权重比例。

### 1.3 PCA 降维及通道选择结果分析

在 DEAP 公共数据集上验证 PCA-MWRReliefF 模型的效果。本文选用 CSP 和差异不对称性作为脑电信号特征, 提取特征的维度为  $600 \times 36$ 。

如图 1 所示, 主成分分析 (principal component analysis, PCA) 降维之后, 特征矩阵维度为 6 时在效价维度、唤醒维度和四分类下的准确率为 91.250 0%、94.583 3% 和 82.500 0%, 略优于其他维度的准确率, 但是计算成本大大减少。因此后续进行情绪识别时选择维度为 6 的脑电特征矩阵。




图 1 分类准确率随特征矩阵维数的变化情况

根据每个通道内特征的权重值, 利用不同的通道选择算法可得通道对应权重值。如图 2 所示, MWRReliefF 算法计算不同通道下的分类准确率优于其余通道选择算法。且通道数为 16 时, 分类效果在效价维度、唤醒维度和四分类下效果较佳, 计算量显著减少。因此本文选择 EEG 通道 O2、P8、Pz、PO4、Cz、Fp1、T7、Fp2、PO3、FC2、F4、C4、P4、P7、O1、CP6 作为后续情绪识别分类的通道。

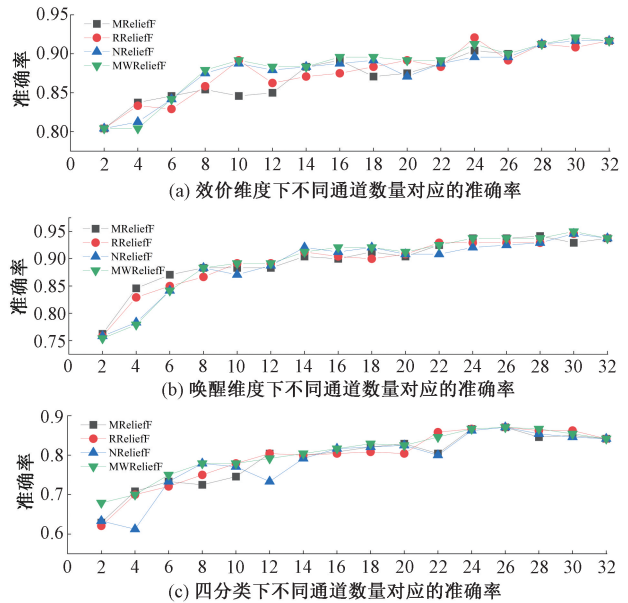


图 2 准确率在不同通道选择算法下随通道数变化情况

在实际应用中, 可根据上述通道选择效果灵活选择通道。对准确率要求较少的场合, 可适当选择更少的通道数, 以增加其实用程度。

为了进一步验证 PCA-MWRReliefF 特征通道选择算法的性能, 本文选用文献[24]使用的互信息通道选择算法与混合深度神经网络的脑电情感识别方法、文献[25]使用的标准化互信息熵通道选择算法和分解双线性池化深度情感识别方法、文献[26]使用的 ReliefF-Pearson 特征通道选择

算法和 SVM 分类器方法、文献[27]使用的基于 Otsu 的 EEG 通道选择算法和 SVM 分类器、文献[28]使用的基于 F-score 的通道选择算法和概率神经网络的情绪识别方法与本文的 PCA-MWReliefF 特征通道选择算法进行比较。如图 3 所示。




图 3 准确率在不同特征通道选择算法下的对比情况

与文献[24-28]中最新的方法相比,本文提出的 PCA-

MWReliefF 算法比孟明等<sup>[24]</sup>提出的互信息通道选择算法与混合深度神经网络的脑电情感识别方法的性能在效价维度高出 3.65%,在唤醒维度高出 6.0033%,比程程<sup>[25]</sup>提出的标准化互信息熵通道选择算法和分解双线性池化深度情感识别方法的性能在效价维度高出 0.79%,在唤醒维度高出 1.3633%,比张小内等<sup>[26]</sup>提出的 ReliefF-Pearson 特征通道选择算法和 SVM 分类器方法的性能在效价维度高出 2.74%,在唤醒维度高出 5.2733%,比钟志文等<sup>[27]</sup>提出的基于 Otsu 的 EEG 通道选择算法和 SVM 分类器方法的性能在效价维度高出 7.85%,在唤醒维度高出 12.3833%,比陈明<sup>[28]</sup>提出的基于 F-score 的通道选择算法和概率神经网络的情绪识别方法的性能在效价维度高出 3.5%,在唤醒维度高出 5.3233%,性能提升都比较显著。这表明本文提出的 PCA-MWReliefF 算法在特征通道选择方面具有明显的优越性。

### 1.4 多模态特征融合

脑电信号经 PCA-MWReliefF 算法降维后,通道数和计算成本显著减少。本文将预处理后的 EEG、EMG 和 TEM 信号分别进行特征提取,将特征提取后的矩阵基于不同的权重进行多模态特征融合,将融合结果输入后续的分类模型进行情绪识别。如图 4 所示。

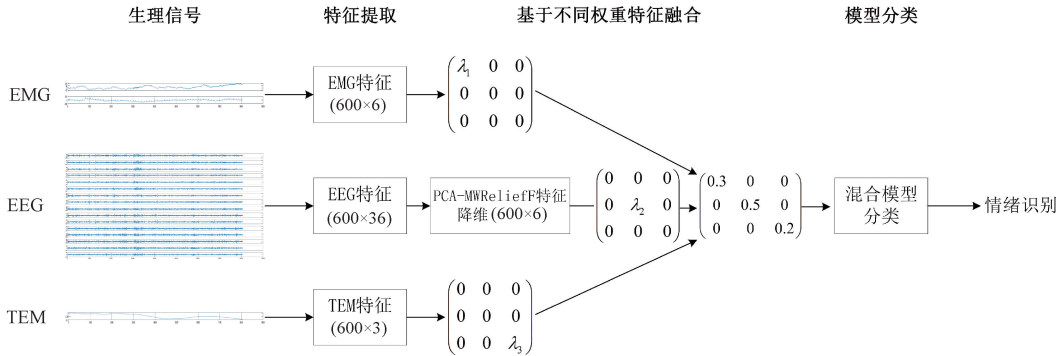


图 4 基于不同权重的多模态信号特征融合流程图

## 2 GAPSO 优化支持向量机

### 2.1 遗传算法及其改进

GA 是 1975 年由美国 Michigan 大学的 Holland 教授首先提出的<sup>[29]</sup>。GA 主要借鉴于达尔文自然选择的进化论模型。在生物进化自然发展的过程中,通过不断的复制、交叉和变异以此获得适应环境变化的能力。

GA 在交叉和变异的作用下产生新种群,通过每一次迭代保留最优个体,使其不再发生交叉和变异,最大程度保留最优解的继承性。但是在传统的遗传算法中交叉算子和变异算子是定值,这会导致最优种群仍然会发生交叉和变异进而破坏最优解。为此引入自适应交叉和突变算子,让其随着迭代次数增加而降低,放缓交叉和变异的脚步,最大程度保留种群最优解。本文在自适应交叉和突变

算子的公式基础上引入 sin 函数,利用 sin 函数在周期上由快至后期逐渐放缓的特性来动态改变交叉和变异的概率,降低迭代过程中最优种群交叉、变异的可能性。如式(12)、(13)所示。

$$pc = pc_{\max} - (pc_{\max} - pc_{\min})\sin\left(\frac{\pi t}{2T}\right) \quad (12)$$

$$pm = pm_{\max} - (pm_{\max} - pm_{\min})\sin\left(\frac{\pi t}{2T}\right) \quad (13)$$

式中:  $pc$  表示交叉概率,  $pc_{\max}$  和  $pc_{\min}$  分别表示交叉概率的最大值和最小值,取 0.9 和 0.3。  $pm$  表示变异概率,  $pm_{\max}$  和  $pm_{\min}$  分别表示变异概率的最大值和最小值,取 0.6 和 0.3。  $t$  表示当前迭代次数,  $T$  表示总的迭代次数。

### 2.2 粒子群算法及其改进

PSO 是通过模拟鸟群觅食而发展起来的一种基于群

体协作的搜索算法。美国学者 Kennedy 和 Eberhart 在 1995 年共同提出了 PSO<sup>[30]</sup>。利用粒子不断向最优值靠近的运动代替鸟类觅食行为。在每一次迭代中,粒子通过跟踪个体最优位置和全局最优位置两个极值来更新自己。在迭代过程中,不断更新粒子的速度和位置,找到自身最佳位置的同时不断向全局最优位置靠近。粒子通过式(14)更新自己的速度和位置。

$$v_{id} = w \times v_{id-1} + c_1 r_1 (p_{id} - \chi_{id}) + c_2 r_2 (p_{gd} - \chi_{id}) \quad (14)$$

式中: $i$  表示粒子, $d$  表示粒子维数, $w$  为惯性权重, $v_{id}$  表示第  $i$  个粒子在第  $d$  维的速度, $p_{id}$  表示第  $i$  个粒子在第  $d$  维的个体最优, $r_1$  和  $r_2$  表示  $random(0,1)$ , $c_1$  代表粒子自身的认知能力, $c_2$  代表粒子的社会学习能力。本文设置  $c_1=1.5, c_2=2.5$ 。

本文通过在自适应惯性权重和跳出局部最优两方面进行改进,自适应惯性权重和迭代次数与每个粒子的适应度有关。 $w$  代表当前速度受历史速度的影响大小, $w$  越大,受历史速度影响越大。速度逐渐变快,可以在更大范围内寻找最优位置。反之, $w$  越小,粒子速度变缓,运动受限,只能在较小的范围内不断寻找最佳位置,局部寻优能力变强。但是如果  $w$  是定值,速度可能会存在过大或过小问题,不利于寻优。最小值问题和最大值问题如式(15)、(16)所示。

$$w_i^d = \begin{cases} w_{\min} + (w_{\max} - w_{\min}) \frac{f(x_i^d) - f_{\min}^d}{f_{\text{average}}^d - f_{\min}^d}, & f(x_i^d) \leq f_{\text{average}}^d \\ w_{\max}, & f(x_i^d) > f_{\text{average}}^d \end{cases} \quad (15)$$

$$w_i^d = \begin{cases} w_{\min} + (w_{\max} - w_{\min}) \frac{f_{\max}^d - f(x_i^d)}{f_{\max}^d - f_{\text{average}}^d}, & f(x_i^d) \geq f_{\text{average}}^d \\ w_{\max}, & f(x_i^d) < f_{\text{average}}^d \end{cases} \quad (16)$$

式中: $w_{\max}$  和  $w_{\min}$  是预先给定的最大惯性系数和最小惯性系数, $f_{\text{average}}^d = \sum_{i=1}^n f(x_i^d)/n$ ,表示第  $d$  次迭代时所有粒子的平均适应度, $f_{\max}^d$  表示第  $d$  次迭代时所有粒子的最大适应度。

基于此,本文利用  $\sin$  函数的非线性规律将  $w$  的运动也变为动态,防止  $w$  取值线性减少时对粒子更新产生规律性变化导致在迭代早期收敛速度慢,迭代末期无法跳出局部最优<sup>[31]</sup>。通过  $\sin$  函数非线性规律改进后的  $w$  在迭代早期具有较大的值,利于全局寻优,在迭代后期具有较小的值,利于局部寻优。自适应惯性权重如式(17)。

$$w = w_{\max} - (w_{\max} - w_{\min}) \sin\left(\frac{\pi t}{2T}\right) \quad (17)$$

PSO 在迭代过程中,随着粒子不断向最优值靠拢,粒子搜索范围逐渐受限,可能会产生粒子过早收敛的现象。为了避免粒子陷入局部最优值而出现停滞向前的现象。本文在改进  $w$  的基础上引入改进的 GA,通过改进的 GA 不断更新粒子的位置和速度,帮助粒子跳出局部最优,丰富粒子多样性。为了避免局部最优解迭代刚结束就被交叉、变异操作改变,导致局部最优解很难再次被寻找到,因此当连续迭代 5 次后全局最优适应度值未发生改变时,本文就引入 GA。尽可能保证粒子寻找个体最优值和全局最优值的过程中最大化保留最优值出现的位置。

### 2.3 GAPSO 性能测试

本文选用 CEC2017 测试函数集,测试改进后算法的性能。选用文献[14]使用的 PSO 算法、文献[32]使用的 GA 算法、文献[15]使用的 AEPSON 算法,文献[33]使用的 IPSO 算法与本文的 GAPSO 算法进行比较。其中测试函数分别为:Sphere 函数、Sum of different Powers 函数、Schwefe2.22 函数与 Griewank 函数,测试函数具体信息如表 1 所示。

表 1 测试函数

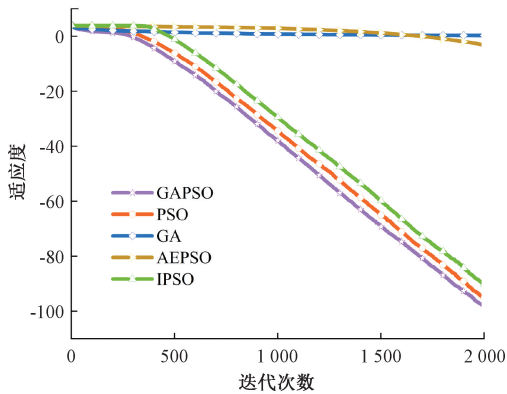
序号	函数名	表达式	维度	范围	最优值
F1	Sphere	$F_1(x) = \sum_{i=1}^n X_i^2$	10	$[-100,100]$	0
F2	Sum of different Powers	$F_2(x) = \sum_{i=1}^d  x_i ^{i+1}$	10	$[-1,1]$	0
F3	Schwefe2.22	$F_3(x) = \sum_{i=1}^n  X_i  + \prod_{i=1}^n  X_i $	10	$[-10,10]$	0
F4	Griewank	$F_4(x) = \sum_{i=1}^d \frac{x_i^2}{4000} - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	10	$[-600,600]$	0

为尽可能的缩小因实验次数少而导致偶然性引起的干扰,影响改进算法的性能测试,本文将每个测试函数单独运行 20 次,取 20 次实验结果的均值。4 种测试函数的种群规模  $m=100$ ,粒子维数  $N=10$ ,最大迭代次数  $T=2000$ 。实验结


果表明:在 Sphere 函数下,GAPSO 算法寻优得到的最佳值略低于 AEPSON 算法,但其最差值、平均值和标准差均明显优于其他 4 种算法。在 Sum of different Powers 函数、Schwefe2.22 函数和 Griewank 函数下,不论是寻优得到的最佳值、最差值、

平均值还是标准差均明显优于其余 4 种算法。因此本文改进后的 GAPSO 算法优于其他 4 种算法。


选定 4 个测试函数在 5 种算法优化下的寻优收敛曲线如图 5 所示。




(a) Sphere函数



(b) Sum of different Powers函数



(c) Schwef2.22函数



(d) Griewank函数

图 5 测试函数的收敛曲线

通过对比可以发现本文改进的 GAPSO 算法相比于其他 4 种算法具有更显著的优越性。GAPSO 算法收敛速度快且精度高,并且兼具了自适应惯性权重和跳出局部最优的优点。因此,本文后续使用 GAPSO 算法对 SVM 的参数进行优化。

### 2.4 GAPSO-SVM 分类模型

SVM 是一类按监督学习方式对数据进行二元分类的广义线性分类器。其决策边界是对学习样本求解的最大边距超平面。如式(18)所示。当线性可分时,在原空间寻找两类样本的最优分类超平面<sup>[34]</sup>。

$$g(x) = \mathbf{w}^T \mathbf{x} + \mathbf{b} \quad (18)$$

式中:  $g(x)$  是所要寻找的分类超平面,  $\mathbf{w}$  是权重向量,  $\mathbf{b}$  是截距向量。

当线性不可分时,可以利用松弛变量的特性允许一部分点到分类平面的距离不满足之前的要求,如式(19)所示:

$$y_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 - \xi_i \quad (19)$$

式中:  $i = 1, 2, \dots, n$ ,  $\xi_i$  是松弛变量。虽然希望分类间隔越大越好,但是避免  $\xi_i$  取太大的值,因此在目标函数中加入惩罚参数  $C$ ,如式(20)所示。

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{j=1}^n \xi_j \quad (20)$$

$$s. t. \quad y_j(\mathbf{w}^T \mathbf{x}_j + \mathbf{b}) \geq 1 - \xi_j, \xi_j \geq 0, 1 \leq j \leq n$$

式中:  $\xi_j$  是松弛变量,  $C$  是惩罚参数。当  $C$  过大时对分类要求较高,可以一定程度上提高分类准确率,但有时也会导致模型泛化能力下降。当  $C$  过小时,虽然允许模型出错,但容易出现欠拟合现象。因此需要合理控制  $C$  的值。

核函数用于将原始数据映射到高维空间,使得数据在高维空间容易被区分。本文采用分离非线性数据较好的高斯核函数,如式(21)所示。

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (21)$$

式中:  $\frac{1}{2\sigma^2}$  为核函数参数  $g$ 。  $g$  的取值会影响支持向量的数量,过大时容易引起过拟合,模型泛化能力低,过小又会导致无法将数据分离。因此,需选择合适的核函数以提高分类准确率。

为了提高情绪识别分类精度。本文采用改进的 GA 算法和改进的 PSO 算法组合优化 SVM 的参数  $C$  及参数  $g$ , 以此获得更优异的分类效果。

### 2.5 轻量化混合模型

本文选取脑电信号的16个通道,并对特征矩阵进行降维处理,显著降低计算成本的基础上基于不同权重进行三模态信号特征融合。利用本文提出的GAPSO算法对SVM的参数C和g进行寻优,进一步提高分类准确率。PCA-MWRRelief-GAPSO-SVM寻优流程图如图6所示。

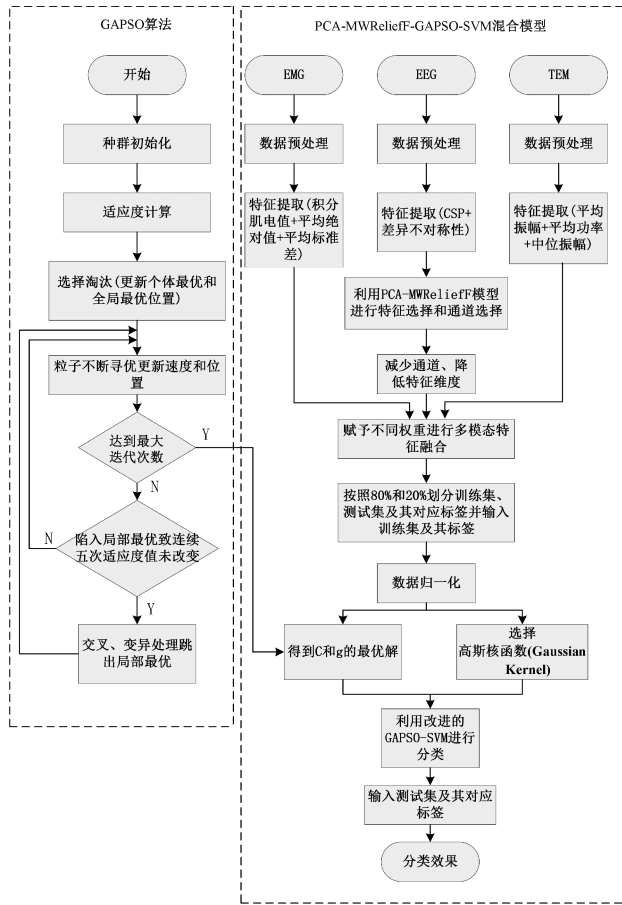


图6 PCA-MWRRelief-GAPSO-SVM流程

为了充分验证混合模型的优势和先进性,本文选用文献[35]使用的GA算法优化SVM、文献[36]使用的SVM、文献[37]使用的灰狼算法(grey wolf optimizer,GWO)优化SVM、文献[38]使用的PSO算法优化SVM、文献[39]使用的深度网络融合模型优化SVM、文献[40]使用的卷积神经网络(convolutional neural network,CNN)集成SVM与本文提出的轻量化混合模型PCA-MWRRelief-GAPSO-SVM进行比较。详细比较结果如图7所示。

与文献[35-40]中最新的方法相比,本文提出的混合模型比谭卓昆等[35]提出的GA优化SVM的性能在效价维度高出4.1667%,在唤醒维度高出1.6666%,四分类下高出1.6667%,比刘敏[36]提出的SVM的性能在效价维度高出27.5%,在唤醒维度高出32.5%,四分类下高出47.5%,比魏雪等[37]提出的GWO优化SVM的性能在效价维度高出10.23%,在唤醒维度高出8.0233%,比Al-Shargie等[38]

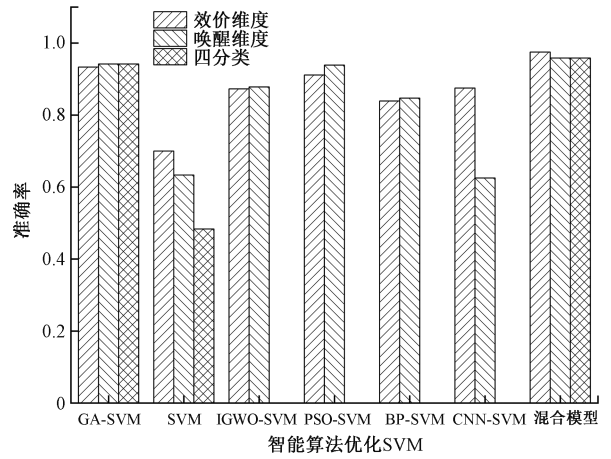


图7 准确率在不同智能算法优化SVM下的比较情况

提出的PSO优化SVM的性能在效价维度高出6.39%,在唤醒维度高出1.9533%,比林诗柔[39]提出的深度网络融合模型优化SVM的性能在效价维度高出13.6%,在唤醒维度高出11.1333%,比Mishra等[40]提出的CNN集成SVM的性能在效价维度高出10%,在唤醒维度高出33.3333%,性能提升都比较显著。这表明本文提出的混合模型具有显著的优势和先进性。

## 3 实验与结果分析

### 3.1 数据集介绍

本文采用DEAP数据集集中的EEG、EMG和TEM数据验证所提的模型。该数据集包含了32名参与者观看40段时长1min的音乐视频。参与者根据效价、唤醒、喜欢和主导4个维度对每个视频进行打分。受试者选择数字1~9作为他们本次实验的情绪。该数据集提供处理后的数据,采集到的数据使用4.0~45.0Hz的带通滤波器进行滤波,采样率下采样至128Hz,去除眼电伪迹。数据格式如表2所示。

表2 数据格式

数组名	数组维度	内容
data	40×40×8 064	实验次数×通道数×数据点数
labels	40×4	实验次数×标签

在本实验中,以5作为分界点,低于5的标签记为0,高于5的标签记为1。本文所进行的二分类实验分别是高效价(HV)、低效价(LV),高唤醒(HA)、低唤醒(LA),所进行的四分类实验分别是高效价高唤醒(HVHA)、高效价低唤醒(HVLA)、低效价高唤醒(LVHA)和低效价低唤醒(LVLA),四分类对应标签分别为0、1、2和3。本文使用预处理后的数据进行后续情绪分类识别。

### 3.2 预处理和特征提取

本文选用DEAP数据集下的EEG、EMG和TEM数

据进行多模态融合。

在 DEAP 数据集采集的 EEG 中,每个实验时长为 63 s,其中前 3 s 是基线信号,表示实验开始前的准备阶段,后 60 s 是受试者采集脑电数据的时间。本文用后 60 s 脑电信号分别减去前 3 s 基线信号的均值,将处理后的数据进行窗口划分,本文选取时间窗口长度为 4 s。将数据进行切分后可得 600 个样本,增加实验数据样本数。

在 DEAP 数据集采集的 EMG 中,对信号进行零相移滤波器进行滤波,以及 50 Hz 的工频陷波。由于 EMG 本身的微弱性和易受干扰性,将滤波后的信号利用非线性小波变换阈值法进行滤波,首先使用正交镜像滤波器对肌电信号滤波得到小波系数  $w$ ,然后根据式(22)计算阈值,根据式(23)设定阈值,计算出小波估值,最后设置信号能量阈值,大于或者等于该阈值的能量置为 0,经小波反演重构后更新信号,将预处理后的肌电数据用于后续情绪识别。

$$y(w) = \text{sign}(w)(|w| - t) \quad (22)$$

$$t = \sigma \sqrt{2lbn} / \sqrt{n} \quad (23)$$

在 DEAP 数据集采集的 TEM 中,对信号进行零相移滤波处理,有效去除滤波引起的相位延迟。最后将数据进行标准化处理,使其均值为 0,标准差为 1。将此时的温度数据用于后续情绪识别。

本文分别提取 EEG 信号、EMG 信号和 TEM 信号的时域、频域、时频域、非线性特征以及空域特征。从中筛选最优特征进行串行融合,将融合得到的特征矩阵输入情绪分类模型<sup>[41]</sup>。所选特征如表 3 所示。

表 3 特征选取

信号	特征	效价	唤醒	四分类	%
EEG	CSP	87.500 0	84.166 7	82.083 3	3
	差异不对称性	82.083 3	74.583 3	82.083 3	3
	CSP+差异不对称性	91.666 7	93.750 0	84.166 7	3
EMG	积分肌电值	81.666 7	85.833 3	70.833 3	3
	平均绝对值	79.166 7	75.833 3	62.500 0	3
	平均标准差	79.166 7	75.000 0	63.333 3	3
	积分肌电值+平均绝对值+平均标准差	90.416 7	90.833 3	82.083 3	3
TEM	平均振幅	64.583 3	72.083 3	52.083 3	3
	平均功率	66.250 0	72.083 3	48.750 0	3
	中位振幅	65.000 0	72.500 0	52.083 3	3
	平均振幅+平均功率+中位振幅	67.083 3	72.916 7	52.916 7	3

从多种常用的特征中提取最优特征进行融合作为最终的特征矩阵。经 PCA-MWRReliefF 算法特征降维和通道选择后,选择 16 个脑电通道进行后续的多模态特征融合。

### 3.3 分类结果与分析

本文将预处理后的 EEG、EMG 和 TEM 数据分别进

行特征提取,将特征提取后的矩阵基于不同的权重进行多模态特征融合,将融合后的特征矩阵输入多模态混合模型进行分类识别。

为了验证混合模型对于多模态信号情绪识别的效果,将轻量化混合模型单独对 EEG、EMG 和 TEM 进行情绪识别以及 EEG 和 EMG 特征融合、EEG 和 TEM 特征融合结果和本文选择的 3 种生理信号融合进行对比。如图 8 所示。




图 8 分类准确率在不同输入信号下的变化情况

通过图 8 可以发现,TEM 对于情绪识别同样具有良好的效果。不论是 EEG 和 EMG 还是 EEG 和 TEM 信号进行两模态融合,其分类效果均优于任何一种单模态信号。将 EEG、EMG 和 TEM 信号进行 3 模态融合,其分类效果和近期的类似工作相比,具有更高的分类准确率且兼具计算成本小和易于实际应用的优点。因此本文提出的轻量化混合模型 PCA-MWRReliefF-GAPSO-SVM 具有良好的应用前景。

## 4 结 论

本文在多模态信号融合的基础上提出一个新颖的轻量化混合模型,通过和单模态信号以及 BP-SVM、PSO-SVM、GA-SVM、SVM 等分类器进行比较,证明了所选多模态信号的优势以及混合模型对于情绪分类的效果。得出如下结论:

TEM 信号相较于心电、眼电等信号具有独特的优势,在同样可以提高情绪识别准确率的前提下,TEM 具有易于采集且方便处理的优势。更方便被实际应用。

通过 PCA-MWRReliefF 算法进行特征降维和减少通道,可以大大减少计算成本。通过改进 GA 和改进 PSO 优化 SVM,可以进一步提高情绪识别分类准确率。

### 参考文献

- [1] 聂聃,王晓曦,段若男,等.基于脑电的情绪识别研究综述[J].中国生物医学工程学报,2012,31(4):595-606.
- [2] 张学军,陈都,孙知信.基于卷积神经网络的脑电信号



- 情绪分类方法[J]. 电子测量技术, 2022, 45(1): 1-7.
- [3] SHANE M. Brain-machine interfaces from motor to mood[J]. *Nat Neurosci*, 2019, 22(10): 1554-1564.
- [4] 范方朝, 杜欣, 谢城壁, 等. 基于 CNN-LSTM 的脑电 P300 信号检测[J]. 电子测量技术, 2022, 45(23): 159-165.
- [5] 周程宁, 王青山, 王琦, 等. WiDriver: 一种基于 WiFi 的驾驶员情绪波动识别框架[J]. 小型微型计算机系统, 2022, 43(10): 2137-2142.
- [6] 赵丹丹, 赵倩, 董宜先, 等. 基于 EEG 和 DE-CNN-GRU 的情绪识别[J]. 计算机系统应用, 2023, 32(4): 206-213.
- [7] 童小钟, 魏俊宇, 苏绍璟, 等. 融合注意力和多尺度特征的典型水面小目标检测[J]. 仪器仪表学报, 2023, 44(1): 212-222.
- [8] 李鹏. 基于改进 PSO-BP 算法的机器人目标位姿识别方法[J]. 国外电子测量技术, 2023, 42(1): 7-12.
- [9] ZHENG W, LU B. Investigating critical frequency bands and channels for EEG-Based emotion recognition with deep neural networks[J]. *IEEE Transactions on Autonomous Mental Development*, 2015, 7(3): 162-175.
- [10] 宋世林, 张学军. 脑电信号多特征融合与卷积神经网络算法研究[J/OL]. 计算机工程与应用, 1-11[2024-04-02]. <http://kns.cnki.net/kcms/detail/11.2127.tp.20230425.1428.005.html>.
- [11] 吴文一. 基于 EEG-fNIRS 特征融合的多强度负性情绪识别研究[D]. 天津: 天津大学, 2023.
- [12] 隋修武, 牛佳宝, 李昊天, 等. 基于 NMF-SVM 模型的上肢 sEMG 手势识别方法[J]. 计算机工程与应用, 2020, 56(17): 161-166.
- [13] 王琳虹, 李世武, 高振海, 等. 基于粒子群优化与支持向量机的驾驶员疲劳等级判别[J]. 哈尔滨工业大学学报, 2014, 46(12): 102-107.
- [14] 王彩云, 黄盼盼, 李晓飞, 等. 基于 AEPSo-SVM 算法的雷达 HRRP 目标识别[J]. 系统工程与电子技术, 2019, 41(9): 1984-1989.
- [15] 柯钢. 改进粒子群算法优化支持向量机的入侵检测方法[J]. 合肥工业大学学报(自然科学版), 2019, 42(10): 1341-1345.
- [16] 宗静, 熊馨, 周建华, 等. 结合多模态数据和混合模型的情绪识别[J/OL]. 小型微型计算机系统, 1-11[2024-04-02]. <http://kns.cnki.net/kcms/detail/21.1106.TP.20230919.0908.006.html>.
- [17] 朱丽, 杨青, 吴涛, 等. 基于 CNN 和 Bi-LSTM 的脑电波情感分析[J]. 应用科学学报, 2022, 40(1): 1-12.
- [18] 赵丹丹, 赵倩, 董宜先, 等. 基于 EEG 和 DE-CNN-GRU 的情绪识别[J]. 计算机系统应用, 2023, 32(4): 206-213.
- [19] 毕晓君, 乔伟征. 基于改进深度学习模型 C-NTM 的脑电鲁棒特征学习[J]. 哈尔滨工程大学学报, 2019, 40(9): 1642-1649.
- [20] 陈景霞, 郝为, 张鹏伟, 等. 基于混合神经网络的脑电时空特征情感分类[J]. 软件学报, 2021, 32(12): 3869-3883.
- [21] 王永宗. 面向情绪识别的脑电特征组合及通道优化选择研究[D]. 兰州: 兰州大学, 2018.
- [22] KIRA K, RENDELL L. The feature selection problem: traditional methods and a new algorithm[J]. *National Conference on Artificial Intelligence*, 1992: 129-134.
- [23] ROBNIK M. Theoretical and empirical analysis of ReliefF and RReliefF[J]. *Machine Learning*, 2003, 53: 23-69.
- [24] 孟明, 胡家豪, 高云园, 等. 结合互信息通道选择与混合深度神经网络的脑电情感识别方法[J]. 传感技术学报, 2021, 34(8): 1089-1095.
- [25] 程程. 基于多模态深度学习的情感识别方法研究[D]. 大连: 辽宁师范大学, 2021.
- [26] 张小内, 翟文鹏, 侯惠让, 等. 基于 ReliefF-Pearson 的嗅觉脑电通道选择[J]. 电子与信息学报, 2021, 43(7): 2032-2037.
- [27] 钟志文, 陈茂洲. 基于 Otsu 的 EEG 通道选择情绪识别研究[J]. 现代电子技术, 2023, 46(17): 39-42.
- [28] 陈明. 基于脑电信号的情绪识别[D]. 杭州: 杭州电子科技大学, 2017.
- [29] 赵义武, 牛庆银, 王完成. 遗传算法与蚁群算法的融合研究[J]. 科学技术与工程, 2010, 10(16): 4017-4020.
- [30] 韩红桂, 卢薇, 乔俊飞. 一种基于种群多样性的粒子群优化算法设计及应用[J]. 信息与控制, 2017, 46(6): 677-684.
- [31] 魏秀业, 程海吉, 贺妍, 等. 基于特征融合与 ResNet 的行星齿轮箱故障诊断[J]. 电子测量与仪器学报, 2022, 36(5): 213-222.
- [32] 柳长源, 李文强, 毕晓君. 基于脑电信号的情绪特征提取与分类[J]. 传感技术学报, 2019, 32(1): 82-88.
- [33] 南杰琼, 王晓东. 改进惯性权值的粒子群优化算法[J]. 西安工程大学学报, 2017, 31(6): 835-840.

- [34] 路万里. 基于脑电与心电信息融合的精神状态识别研究[D]. 太原: 中北大学, 2020.
- [35] 谭卓昆, 罗龙飞, 王顺芳. 基于融合特征与 GA-SVM 算法的脑疾病基因预测[J]. 计算机工程与应用, 2023, 59(5): 70-77.
- [36] 刘敏. 基于 DWT 的 PCA+SVM 优化算法在人脸识别应用中的研究[J]. 绥化学院学报, 2023, 43(9): 157-160.
- [37] 魏雪, 吴清. 分段复合多尺度模糊熵和 IGWO-SVM 的脑电情感识别[J]. 计算机应用研究, 2019, 36(11): 3310-3314, 3356.
- [38] AL-SHARGIE F. Enhancing EEG-based mental stress state recognition using an improved hybrid feature selection algorithm[J]. Sensors, 2021, 21.
- [39] 林诗柔. 基于深度玻尔兹曼机的脑电信号情感分析[D]. 广州: 广东工业大学, 2021.
- [40] MISHRA A, SINGH A, RANJAN P, et al. Emotion classification using ensemble of convolutional neural

networks and support vector machine[C]. 2020 7th International Conference on Signal Processing and Integrated Networks(SPIN), 2020.

- [41] MATTHIAS S, TREDER A, ANNE K, et al. The LDA beamformer: Optimal estimation of ERP source time series using linear discriminant analysis [J]. Neuro Image, 2016, 129(10): 279-291.

### 作者简介

**彭军强**, 讲师, 研究生导师, 主要研究方向为脑机接口(BCI)控制、设备在线检测与控制、纺织机械动力学。

E-mail: pengjunqiang@tiangong.edu.cn

**张立坤**, 硕士研究生, 主要研究方向为脑电信号处理、嵌入式应用开发。

E-mail: 2231050798@tiangong.edu.cn

**杨亚楠**(通信作者), 副教授, 研究生导师, 主要研究方向为图像处理与模式识别、智能控制理论及实现、电子设备远程控制与监测。

E-mail: 1343827360@qq.com