

文章编号: 2095-2163(2023)12-0158-07

中图分类号: TP391.41

文献标志码: A

# 基于 DWPSO-SVM 的 sEMG 手势动作识别

王宇春, 王敏, 袁东华, 赵化启

(佳木斯大学 信息电子技术学院, 黑龙江 佳木斯 154007)

**摘要:** 为了提高表面肌电信号(surface Electromyographic signal, sEMG)手势动作识别的准确率, 本文提出基于双权重粒子群算法(Particle Swarm Optimization, PSO)优化支持向量机(Support Vector Machine, SVM)的分类模型(DWPSO-SVM)。针对传统 PSO 在参数寻优时易陷入“早熟”问题, 进一步提高粒子寻优能力, 本文在标准 PSO 的基础上引入约束因子结合同向更新策略用于速度约束, 有效的提高了粒子的寻优能力并缓解了“早熟”现象; 其次, 分析了多种权重更新策略对惯性权重和约束因子的影响; 最终, 采用非线性更新策略结合 DWPSO 优化 SVM 模型构建特征分类模型。实验表明, 本文提出的 DWPSO-SVM 模型能够有效完成 sEMG 手势动作识别任务。

**关键词:** sEMG; 粒子群算法; 支持向量机; 手势动作识别

## sEMG gesture recognition based on DWPSO-SVM

WANG Yuchun, WANG Min, YUAN Donghua, ZHAO Huaqi

(College of Information and Electronic Technology, Jiamusi University, Jiamusi Heilongjiang 154007, China)

**Abstract:** In order to improve the accuracy of surface electromyographic signal (sEMG) gesture recognition, this paper proposes a classification model (DWPSO-SVM) based on Particle Swarm Optimization (PSO) to optimize Support Vector Machine (SVM). In response to the problem of premature convergence in parameter optimization of traditional PSO, and further improving the particle optimization ability, this paper introduces a constraint factor and a directed following strategy based on the standard PSO for speed constraints, effectively improving the particle optimization ability and alleviating the phenomenon of premature convergence; Secondly, the impact of various weight update strategies on inertia weights and constraint factors was analyzed; Finally, a non-linear update strategy combined with DWPSO optimization SVM was used to construct a feature classification model. The experiment shows that the DWPSO-SVM model proposed in this article can effectively complete the sEMG gesture action recognition task.

**Key words:** sEMG; Particle Swarm Optimization; Support Vector Machine; gesture action recognition

## 0 引言

表面肌电信号是反应人体肌肉活动信息的一个重要信号, 由多个运动单元的动作电位序列在人体皮肤表面综合叠加而产生<sup>[1]</sup>。sEMG 获取方便, 在人机交互、医疗康复、假肢控制等领域有着广泛的应用。基于 sEMG 的手势动作识别是当下的研究热点, 提高 sEMG 手势识别的精度是一项具有挑战的任务。

近年来, 基于 sEMG 的手势识别, 支持向量机(SVM)的应用逐渐增加。侯秀离<sup>[2]</sup>通过提取 sEMG

小波变换系数绝对值的最大值, 并与其他时频域特征值一起构成特征向量, 设计了 SVM 分类器, 实现了手部动作的分类; 阮婷等<sup>[3]</sup>提出了一种新的 sEMG 时域特征, 使用 SVM 模型, 完成了对截肢者的手势动作识别。但在使用传统 SVM 进行分类时, 其惩罚系数  $C$  和核函数中的参数  $\sigma$  需要人为设定, 参数取值的不同会严重影响分类的效果, 因此对 SVM 进行改进研究, 粒子群算法(PSO)因其收敛速度快、参数少等优点被用于 SVM 模型的参数寻优。隋修武等<sup>[4]</sup>采用 PSO 算法改进 SVM, 构建动作分类

**基金项目:** 黑龙江省省属本科高校基本科研业务费科研项目(2018-KYYWF-0943); 黑龙江省卫生健康委立项科研课题(2019-287); 佳木斯大学优秀学科团队项目(JDXKTD-2019008); 佳木斯大学教育教学改革研究项目(2021JY1-49)。

**作者简介:** 王宇春(1979-), 男, 博士, 讲师, 主要研究方向: 生物医学仪器及信号分析; 王敏(1999-), 女, 硕士研究生, 主要研究方向: 生物医学仪器及肌电信号识别; 袁东华(1999-), 男, 硕士研究生, 主要研究方向: 模式识别及图像处理。

**通讯作者:** 赵化启(1973-), 男, 博士, 教授, 主要研究方向: 人工智能、计算机控制。Email: zhaohuaqi@126.com

收稿日期: 2022-12-05

器,实现肌电假手动作的模式识别与在线控制;顾明亮等<sup>[5]</sup>提出一种改进的 PSO 优化 SVM 模型(IPSO-SVM),简化 PSO 的位置和速度公式,提高了基于 sEMG 的机械手运动模式识别率。虽然利用 PSO 优化 SVM 能够提升手势动作的识别效果,但在寻优时易陷入局部极值、进化后期粒子寻优能力差等缺点。

在 PSO 算法中,  $w$  为惯性权重,表示前一次迭代速度对当前迭代速度的影响,其大小会直接影响整个收敛过程中每个粒子的寻优能力以及收敛能力。本文采用一种双权重 PSO 优化 SVM 构建分类模型(DWPSO-SVM),实现基于 sEMG 的手势动作识别。受多策略融合启发,本文提出一种同向更新策略结合 DWPSO-SVM 分类模型,与标准 PSO-SVM 分类模型对比,本文所提出的 DWPSO-SVM 模

型对基于 sEMG 的手势动作识别效果更优。

## 1 基于 DWPSO-SVM 的手势动作识别

本文 sEMG 手势识别整体框架如图 1 所示,包括 sEMG 的预处理、特征分类器的构建以及手势动作的识别 3 部分。sEMG 预处理包括了 sEMG 去噪和特征提取,首先,使用小波阈值对原始 sEMG 去噪;其次,对各类手势动作的 sEMG 提取相应的时域特征,将预处理后得到的各类手势动作的 sEMG 时域特征用于 DWPSO-SVM 的模型训练,使用 DWPSO 对 SVM 中参数  $C$  和  $\sigma$  寻优,以建立最终的特征分类器;最后,利用构建的分类模型对手势动作进行识别。

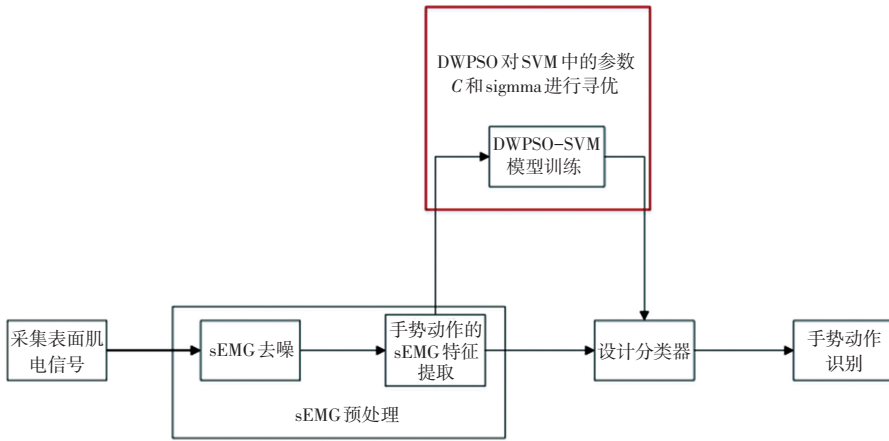


图 1 sEMG 手势识别整体框架

Fig. 1 Overall framework of sEMG gesture recognition

### 1.1 sEMG 预处理

#### 1.1.1 sEMG 去噪

本文采用小波阈值去噪的方法对原始 sEMG 进行去噪处理,其流程如图 2 所示。小波阈值去噪的基本思想是在小波变换(Mallat 算法)的基础上,将信号经小波分解,噪声部分的小波系数要小于有用部分的小波系数,通过选取一个合适的阈值,将小于阈值部分的信号视为是噪声,予以置零;将大于阈值部分的信号视为有用的信号,予以保留,从而达到对 sEMG 去噪的效果<sup>[6]</sup>。

小波阈值去噪的主要步骤:对含噪的 sEMG 进行小波变换,设置分解层数(3 层)和小波基函数(db5);选取合适的阈值函数(软阈值函数)对各个分解尺度下的高频小波系数进行阈值处理;对阈值处理后的信号进行小波重构。

#### 1.1.2 特征提取

sEMG 三大特征即时域特征、频域特征、时频域

特征。本文选用获取方便、计算简单的时域特征作为手势识别的 sEMG 特征。选取均方根(RMS)、积分绝对值(IAV)、平均绝对值(MAV)、波长(WL)作为各类手势动作的 sEMG 时域特征,表达式为式(1)~式(4):

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (1)$$

$$MAV = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (2)$$

$$WL = \sum_{i=1}^{n-1} |x_{i+1} - x_i| \quad (3)$$

$$IAV = \sum_{i=1}^n |x_i| \quad (4)$$

其中,  $n$  表示采样窗口的长度,  $x_i$  表示第  $i$  个采样点的幅值。

并分别对 4 种时域特征进行归一化处理,取其绝对值,以 RMS 为例,式(5):

$$nRMS = |f(RMS)| \quad (5)$$

其中,  $f$  为归一化函数。

处理后得到的特征值分别表示为  $nRMS$ 、 $nIAV$ 、 $nMAV$ 、 $nWL$ , 最终构成的时域特征向量表示:

[ $RMS$ ,  $nRMS$ ,  $IAV$ ,  $nIAV$ ,  $MAV$ ,  $nMAV$ ,  $WL$ ,  $nWL$ ]

## 1.2 基于 DWPSO-SVM 的参数寻优

### 1.2.1 支持向量机原理

支持向量机 (Support Vector Machines, SVM) 是由著名学者 Vapnik 等在 1995 年首次提出的一种新的机器学习方法<sup>[7]</sup>。其核心思想: 在特征空间中构造出一个最优超平面, 满足分类间距最大, 能准确地把两类样本分类。SVM 最优超平面如图 2 所示。




图 2 SVM 最优超平面

Fig. 2 SVM optimal hyperplane

以二分类为例, 在平面上分别用圆圈和三角形表示, 设训练样本集为  $\{(x_i, y_i) \mid i = 1, 2, \dots, n\}$ ,  $x_i \in R^n$ ,  $y_i \in \{-1, +1\}$ , 其中  $x_i$  为输入样本,  $y_i$  为样本标签。

图 3 中的超平面, 式(6):

$$wx + b = 0 \quad (6)$$

可计算出分类间隔  $d$  为  $2/\|w\|$ 。

针对线性不可分问题, 引入松弛变量  $\xi_i \geq 0$  和惩罚因子  $C (C > 0)$ , 其中  $C$  的取值会影响模型的泛化能力。则最大化分类间隔 ( $d$ ) 问题可转化为式(7):

$$\max_{a_i \geq 0} L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m a_i (y_i (w^T x_i + b) - 1) = \sum_{i=1}^m a_i - \frac{1}{2} \sum_{i=1}^m a_i a_j y_i y_j (x_i, x_j) \quad (7)$$

其中,  $a_i$  为二次优化问题所求解的拉格朗日因子,

约束条件为:  $0 \leq a_i \leq C, i = 1, 2, \dots, m, \sum_{i=1}^m a_i y_i = 0$ 。

在 SVM 中通常采用序列最小优化 (Sequential Minimal Optimization, SMO) 算法解决式(7)中的优化问题。最优分类超平面的求解, 式(8):

$$f(x) = \text{sgn} \left[ \sum_{i=1}^n a_i y_i (x_i \cdot x) + b \right] \quad (8)$$

其中,  $\text{sgn}$  表示取表达式的符号,  $x_i \in R^n$ 。

当输入数据为非线性时, 在 SVM 中引入核函数  $K(x_i \cdot x)$ , 得到的非线性最优分类函数, 式(9):

$$f(x) = \text{sgn} \left[ \sum_{i=1}^n a_i y_i K(x_i \cdot x) + b \right] \quad (9)$$

在目前多数的研究中, 针对 sEMG 的多运动模式识别中一般采用的是径向基 (RBF) 核函数, 式(10):

$$K(x, x') = \exp \left( - \frac{\|x - x'\|^2}{2\sigma^2} \right) \quad (10)$$

其中,  $\sigma$  是核函数参数, 取值大小会直接影响支持向量的数量, 从而影响 SVM 模型的训练、预测的速度和结果。

SVM 中多分类采用的策略: 一对一法 (One-Verse-One, OVO): 在任意两个样本之间设计一个支持向量, 对于  $K$  类样本的分类, 则需建立  $K(K-1)/2$  个支持向量; 在对一个未知样本进行分类时, 将通过投票形式, 票数最多的类别即为未知样本的分类结果。

### 1.2.2 粒子群算法的基本原理

粒子群优化算法 (Particle Swarm Optimization, PSO) 是由 Eberhart 和 Kennedy 于 1995 年提出的一种基于种群 (全局) 的随机优化算法, 其核心思想源于对鸟类捕食行为的模拟<sup>[8]</sup>。PSO 算法采用“速度-位置”的搜索方式, 即每个粒子是带有速度  $V_i$  和位置  $X_i$  两个向量的点, 速度向量  $V_i$  控制着粒子的运动方向和速率, 位置向量  $X_i$  表示粒子在解空间里的位置。每个粒子都是搜索空间的一个潜在解, 且都有可能是种群 (全局) 的最优解。

设在一个  $D$  维的搜索空间内, 有  $N$  个粒子, 则第  $i$  个粒子的速度向量  $V_i$  表示为式(11):

$$V_i = (v_{i1}, v_{i2}, \dots, v_{iD}) \quad (11)$$

第  $i$  个粒子的位置向量  $X_i$  表示为式(12):

$$X_i = (x_{i1}, x_{i2}, \dots, x_{iD}) \quad (12)$$

其中,  $i$  表示粒子的编号。

第  $i$  个粒子到目前为止搜索到的个体极值表示为式(13):

$$P_{best} = (p_{i1}, p_{i2}, \dots, p_{iD}) \quad (13)$$

整个粒子群到目前为止搜索到全局极值表示为式(14):

$$G_{best} = (g_1, g_2, \dots, g_D) \quad (14)$$

第  $i$  粒子在第  $k$  次迭代的速度和位置分别是  $V_i^k$

和  $X_i^k$ , 则在第  $k+1$  次的迭代中第  $j$  维的速度和位置更新公式分别表示为式 (15) 和式 (16):

$$V_{ij}^{k+1} = \tilde{\omega} V_{ij}^k + c_1 \text{rand}_1(P_{\text{best}} - x_{ij}^k) + c_2 \text{rand}_2(G_{\text{best}} - x_{ij}^k) \quad (15)$$

$$X_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (16)$$

其中,  $\tilde{\omega}$  为惯性权重, 表示第  $k$  次迭代的速度对第  $k+1$  次迭代速度的影响;  $c_1$ 、 $c_2$  为学习因子;  $\text{rand}_1$ 、 $\text{rand}_2$  为  $[0, 1]$  之间的均匀随机数。

### 1.2.3 改进的粒子群算法 (DWPSO)

在标准 PSO 中,  $\tilde{\omega}$  作为惯性权重, 表示前一次的迭代速度对当前速度的影响;  $\tilde{\omega}$  值越大, 速度  $V_{ij}^{k+1}$  变化越大, 全局收敛能力越强;  $\tilde{\omega}$  值越小, 速度  $V_{ij}^{k+1}$  变化越小, 则局部收敛能力越强, 所以惯性权重  $\tilde{\omega}$  的取值会直接影响整个收敛过程中每个粒子的寻优能力和收敛能力。因此, 本文在位置更新公式中引入一个新的约束因子  $\alpha$ , 用来约束当前速度对当前位置更新的影响权重, 构建一个新的粒子群算法即双权重粒子群算法 (Double Weight Particle Swarm Optimization, DWPSO)。引入约束因子  $\alpha$  后新的位置更新式 (17):

$$X_{ij}^{k+1} = x_{ij}^k + \alpha v_{ij}^{k+1} \quad (17)$$

约束因子  $\alpha$  的作用与惯性权重  $\tilde{\omega}$  的作用类似,  $\alpha$  的取值越大,  $X_{ij}^{k+1}$  的变化越大, 有利于粒子在全局寻优; 反之,  $\alpha$  的取值越小,  $X_{ij}^{k+1}$  的变化越小, 有利于粒子在局部寻优。

针对惯性权重  $\tilde{\omega}$  和约束因子  $\alpha$  的更新, 本文提出一种同向更新策略 (Codirection Update Strategy, CUS), 即惯性权重  $\tilde{\omega}$  与约束因子  $\alpha$  均采用递减策略 (Decreasing Strategy) 更新。这样更新惯性权重  $\tilde{\omega}$  和约束因子  $\alpha$  的目的是: 粒子的速度  $V_{ij}^{k+1}$  更新控制着粒子下一步的探索方向和距离, 粒子的位置更新控制着其个体最优解  $P_{\text{best}}$  的变化。由式 (15) 与式 (17) 可知, 粒子速度直接影响着其位置的更新和个体最优解的变化, 在 PSO 中速度、位置的更新都是为了探索出更优的更好的个体最优解。在整体寻优过程中, 希望粒子先在全局范围内搜索, 使搜索空间快速收敛在某一区域; 采用局部精细搜索来获得高精度的最优解。在探索前期,  $\tilde{\omega}$  和  $\alpha$  初始值较大, 速度  $V_{ij}^{k+1}$  变化较大, 粒子位置  $X_{ij}^{k+1}$  的更新及个体最优解  $P_{\text{best}}$  的变化受速度  $V_{ij}^{k+1}$  的影响也大, 有利于粒子在全局寻优; 在探索后期,  $\tilde{\omega}$  和  $\alpha$  递减后变得较小, 速度  $V_{ij}^{k+1}$  变化较小, 此时粒子位置  $X_{ij}^{k+1}$  的更新及个体最优解  $P_{\text{best}}$  的变化受速度  $V_{ij}^{k+1}$  的影响也较

小, 有利于粒子在局部进行精细搜索时缓解陷入局部最优解的问题。

将 DWPSO 与以下 4 种常见权重更新策略结合, 以惯性权重  $\tilde{\omega}$  的更新公式为例, 约束因子  $\alpha$  的更新公式与其相同。

(1) 线性更新策略, 惯性权重  $\tilde{\omega}$  的线性递减策略如式 (18) 所示:

$$\tilde{\omega}^j = \tilde{\omega}_{\text{start}} - (\tilde{\omega}_{\text{start}} - \tilde{\omega}_{\text{end}}) * (j/M) \quad (18)$$

其中,  $j$  为当前的迭代次数;  $M$  为迭代总次;  $\tilde{\omega}_{\text{start}}$  的值一般设置为 0.9;  $\tilde{\omega}_{\text{end}}$  的值一般设置为 0.4。

(2) 非线性更新策略, 惯性权重  $\tilde{\omega}$  的非线性递减策略如式 (19) 所示:

$$\tilde{\omega}^j = \tilde{\omega}_{\text{start}} - (\tilde{\omega}_{\text{start}} - \tilde{\omega}_{\text{end}}) * (j/M)^2 \quad (19)$$

(3) 自适应权重策略, 权重的取值与适应度函数值有关, 惯性权重  $\tilde{\omega}$  的自适应权重策略如式 (20) 所示:

$$\tilde{\omega}_i^j = \begin{cases} \tilde{\omega}_{\text{start}} - (\tilde{\omega}_{\text{start}} - \tilde{\omega}_{\text{end}}) \frac{f(x_i^j) - f_{\min}^j}{f_{\text{avg}}^j - f_{\min}^j}, & f(x_i^j) \leq f_{\text{avg}}^j \\ \tilde{\omega}_{\text{end}}, & f(x_i^j) > f_{\text{avg}}^j \end{cases} \quad (20)$$

其中,  $f_{\text{avg}}^j$  为第  $j$  迭代时所有粒子的平均适应度,  $f_{\min}^j$  为第  $j$  迭代时所有粒子的最小适应度, 如式 (21) 和式 (22):

$$f_{\text{avg}}^j = \sum_{i=1}^N f(x_i^j) / N \quad (21)$$

$$f_{\min}^j = \min \{f(x_1^j), f(x_2^j), \dots, f(x_i^j)\} \quad (22)$$

(4) 随机权重策略, 惯性权重  $\tilde{\omega}$  的随机权重更新策略如式 (23) 所示:

$$\tilde{\omega}^j = \tilde{\omega}_{\text{start}} - (\tilde{\omega}_{\text{start}} - \tilde{\omega}_{\text{end}}) * \text{rand}() + \sigma * \text{randn}() \quad (23)$$

其中,  $\text{rand}()$  为  $[0, 1]$  均匀分布的随机数;  $\text{randn}()$  为正态分布的随机数; 标准差用来度量随机变量权重与其均值之间的偏离程度, 一般取值范围在  $[0.2, 0.5]$  之间。

### 1.2.4 基于双权重粒子群算法优化的支持向量机 (DWPSO-SVM)

基于 DWPSO 优化 SVM 参数流程, 如图 3 所示。

(1) 给粒子群中每个粒子的速度  $V_i$  和位置  $X_i$  及 SVM 模型中的惩罚因子  $C$ 、核函数参数  $\sigma$  赋随机初值;

(2) 计算适应度函数值, 本文采用 SVM 分类预测的错误率 ( $ER$ ) 作为适应度的目标函数;



(3)对种群中的各个粒子计算其个体适应度和种群适应度,如果当前个体适应度函数值优于个体历史最优值,则更新其个体最优解  $P_{best}$  的值;如果当前种群适应度函数值优于全局历史最优值,则更新其全局最优解  $G_{best}$  的值;

(4)根据权重更新策略更新惯性权重  $\tilde{\omega}$  和约束因子  $\alpha$ , 利用式(15)和式(16)更新粒子的速度和位置;

(5)如果寻到了最优解的位置或者达到了种群的最大迭代次数,则算法终止;否则转入第(2)步,继续进行参数寻优;

(6)输出 DWPSO 寻到的最优惩罚因子  $best.C$ 、最优核函数参数  $best.\sigma$ , 以此建立最优的 SVM 分类模型。

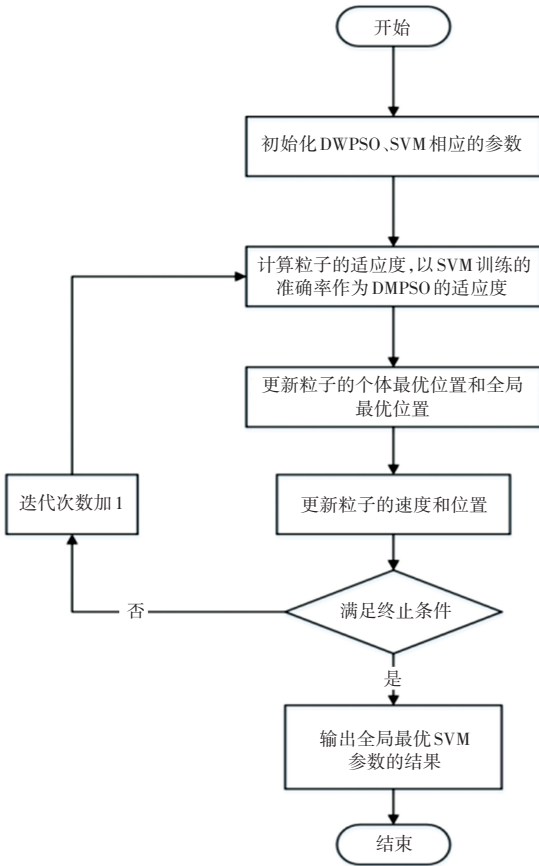


图3 DWPSO 优化 SVM 参数流程

Fig. 3 DWPSO optimization SVM parameter process

## 2 实验及结果分析

### 2.1 数据集简介与评价指标

#### 2.1.1 数据集介绍

非入侵性自适应假肢数据集 (Non Invasive Adaptive Prosthetics, Ninapro) 是 sEMG 研究领域具有代表性的一个公开数据集<sup>[9]</sup>。本文将选用其中 DB1 数据集中的 A 类动作,即 12 个基本手指动作作为本文的手势识别动作。

DB1 数据集面向 27 名健康受试者(20 名男性,7 名女性;25 名右手,2 名左手;年龄范围  $28 \pm 3.4$  岁);采集 sEMG 所用的设备是 22 传感器 CyberGlove II 数据手套和十通道(差分双电极) OttoBock MyoBock。sEMG 的采集:受试者保持特定坐姿,面向演示屏幕,将 sEMG 电极、数据手套和倾角仪穿戴在手上,受试者根据演示屏幕上的动作重复指定动作。经过预先的训练后,每一类的动作将会连续 10 次来收集数据,每次动作将持续 5 s,两个动作之间有 3 s 的休息时间。在本文进行的预处理前,使用广义似然比算法对采集的 sEMG 进行离线重标记;通过 RMS 校正,信号以 200 Hz 下采样;以 1 Hz 低通滤波。

12 类手指基本动作如图 4 所示。本文将训练集与测试集按照 7 : 3 的比例在整体数据集上进行随机分配,以保证每次实验数据的随机性和实验结果的可信度。

#### 2.1.2 评价指标

本文采用分类的准确率作为评价指标,评价手势动作的识别效果,表达式(24):

$$Accuracy = \frac{m}{M} \tag{24}$$

其中,  $m$  为测试集中分类正确的样本数,  $M$  为测试集的全部样本数。

### 2.2 预处理

除数据集中已经进行的预处理外,本文还对数据集进行了去噪处理及特征提取。

(1)采用“db5”小波基函数进行小波阈值去噪处理;



图4 12类基本手指动作

Fig. 4 12 basic finger movements

(2) 本文使用的时间窗加增量的方式对 sEMG 的时域特征提取, 其中时间窗口设为 100 ms, 增量窗口设为 25 ms。

### 2.3 模型分类对比实验

传统 SVM、标准 PSO-SVM 以及本文提出的 DWPSO-SVM 对 12 类手势动作进行识别, 以上 3 种模型对 12 类手势动作的整体识别效果如图 5 所示。

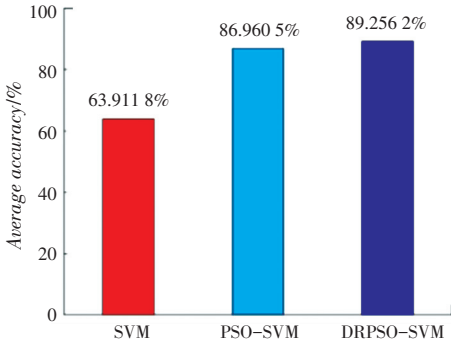


图 5 模型平均识别率对比

由图 5 可知, 本文提出的 DRPSO-SVM 对手势动作的识别较传统的 SVM 和标准 PSO-SVM 有明显的优势。

### 2.4 参数优化实验

针对 SVM 中的参数  $C$  和  $\sigma$  的寻优, 对比了传统的 PSO 与本文提出的 DWPSO 对参数  $C$  和  $\sigma$  的寻优效果, 分别选取了 PSO、DWPSO 参数寻优实验中较有代表性的两个实验结果, 如图 6、图 7 所示, 参数寻优结果见表 1。

由图 6、图 7 和表 1 可见, 图 6(a) 中的 PSO 在第四次迭代便陷入了局部最优解, 而图 7(a) 中的 DWPSO 在第八次迭代才出现“早熟”现象; 且在图 6(b)、7(b) 中, PSO 与 DWPSO 同时进入“早熟”时, DWPSO 的寻优效果也优于 PSO。由此可得, 本文提出的 DWPSO 较 PSO 对“早熟”现象有明显的缓解。


DWPSO-SVM 与上述 4 种权重更新策略结合后对手势动作的分类效果见表 2。

Fig. 5 Comparison of average recognition rate of models


表 1 PSO、DWPSO 参数寻优结果

Table 1 Optimization results of PSO and DWPSO parameters

寻优算法	迭代次数	粒子数量	惩罚因子 $C$	核函数参数 $\sigma$	最优识别率/%
PSO_1	10	5	8.581 0	0.000 581 55	87.603 3
DWPSO_1	10	5	8.897 5	0.001 640 60	89.899 0
PSO_2	10	5	6.735 3	0.000 982 40	88.888 9
DWPSO_2	10	5	9.475 1	0.000 647 76	90.358 1




(a) PSO 第一次寻优




(b) PSO 第二次寻优

图 6 PSO 参数寻优过程

Fig. 6 Optimization process of PSO parameters



(a) DWPSO 第一次寻优



(b) DWPSO 第二次寻优

图 7 DWPSO 参数寻优过程

Fig. 7 Optimization process of DWPSO parameters

表2 不同更新策略的分类效果

权重更新策略	迭代次数	粒子数量	平均准确率/%
线性更新	15	7	89.348 0
非线性更新	15	7	91.092 7
自适应权重	15	7	90.450 0
随机权重	15	7	90.633 6

由表2可知,利用非线性更新策略与DWPSO-SVM结合的手势动作识别效果较优。

### 2.5 DWPSO-SVM 手势分类实验

将参数优化实验寻到的最优参数  $best.C$ 、 $best.\sigma$  用于 SVM 模型,构建最终的特征分类器,构建的分类模型对12类基本手势动作每个动作的单独识别效果(见表3),可见构建的特征分类模型对第3类手势动作(中屈)的识别效果最优,平均准确率高达98.148 1%;对第10类手势动作(拇指内收)的识别率较低,平均准确率也可达到90.361 4%。单独动作的整体平均准确率为94.938 4%。

最终对12类手势动作的整体识别效果如图8所示。

表3 各类手势动作的单独识别效果

动作标签	平均准确率/%	动作标签	平均准确率/%
1	95.798 5	7	96.236 55
2	95.404 0	8	96.907 2
3	98.148 1	9	93.726 0
4	97.674 4	10	90.361 4
5	94.418 6	11	94.871 8
6	93.406 6	12	92.307 7




图8 整体识别效果

Fig. 8 Overall identification effect

由图8可知,在实验过程中,利用本文提出的非线性更新策略结合DWPSO-SVM构建的特征分类模型对手势动作的识别呈现出了较优的分类效果。

### 3 结束语

为了提高基于sEMG的手势动作识别准确率,缓解PSO在寻优过程过早陷入局部最优解的现象,本文提出了DWPSO-SVM并结合一种同向更新策略构建分类模型,有效地完成了手势动作识别任务。DWPSO有效避免了PSO参数寻优时过早的进入“早熟”现象,并提高了粒子的寻优能力,非线性更新策略结合DWPSO-SVM构建的模型对12类手势动作的整体识别最优准确率高达93.274%,对单独动作的平均识别准确率高达94.938%。

对sEMG的特征提取也是手势识别的研究热点,在后续基于sEMG的手势识别的研究工作上,有望于提出一种新的sEMG特征提取方法可以更方便、更准确地识别手势动作。

### 参考文献

- [1] 江茜,李沿宏,邹可,等. 肌电信号多通道相关性特征手势识别方法[J/OL]. 计算机工程与应用,2023,59(7):102-109.
- [2] 侯秀丽.SVM在表面肌电信号手部动作模式识别中的应用[J]. 九江学院学报(自然科学版),2021,36(2):68-71.
- [3] 阮婷,刘川,尹奎英. 基于表面肌电信号的截肢者人手动模式识别[J]. 太赫兹科学与电子信息学报,2021,19(1):101-106.
- [4] 隋修武,刘乃嘉,乔明敏,等. 基于PSO-SVM的仿生肌电假手反馈控制系统设计[J]. 传感技术学报,2019,32(12):1784-1789.
- [5] 顾明亮,刘俊. 改进的PSO-SVM在表面肌电信号模式识别中的研究[J]. 传感技术学报,2017,30(10):1459-1464.
- [6] GUO Daifei, ZHU Weihong, GAO Zhenming, et al. A study of wavelet thresholding denoising [C]//Proceedings of 2000 5<sup>th</sup> International Conference on Signal Processing. 2000:385-388.
- [7] NOBLE W S. What is a support vector machine? [J]. Nautre Biotechnology, 2006,24(12):1565-1567.
- [8] KENNEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of ICNN'95 - International Conference on Neural Networks IEEE. 1995,4:1942-1948.
- [9] ATZON M, GIJSBERTS A, CASTELLINI C, et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. [J]. Scientific Data, 2014,1(1):1-13.