

基于 Fisher 判别和 GKF-RELM 算法的多特征步态模式识别

黎毅达^{1,2}, 高发荣¹, 姚 婷¹, 蔡利杰¹

(1. 杭州电子科技大学自动化学院, 浙江杭州 310018; 2. 北京京东乾石科技有限公司, 北京 100176)

摘 要: 为提高下肢表面肌电信号步态识别的识别精度和计算效率, 采用一种基于高斯核函数优化正则化超限学习机(GKF-RELM)算法, 对肌电信号提取时域、频域和非线性动力学三类特征并分别计算步态识别率, 运用 Fisher 判别函数分析所提特征的可分性, 得到多类特征的融合特征作为输入数据对分类器进行训练, 再用训练好的分类器进行步态识别, 从识别率和计算时间两方面, 分别与支撑向量机(SVM)和深度神经网络(DNN)方法进行了对比分析. 结果表明, 基于 Fisher 判别可分性指标确定的多类特征组合, 能得到最优识别效果, 并在提高分类精度的同时, 优化了计算效率. 此外, GKF-RELM 方法的识别率也优于传统的 ELM 方法.

关键词: 步态识别; 多特征融合; GKF-RELM 算法; 深度神经网络; Fisher 判别分析

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112(2021)10-1993-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200033

Multi-Feature Gait Pattern Recognition Based on Fisher Discriminant and GKF-RELM Algorithm

LI Yi-da^{1,2}, GAO Fa-rong¹, YAO Ting¹, CAI Li-jie¹

(1. School of Automation, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

2. Beijing Jingdong Dry Stone Technology Co. Ltd., Beijing 100176, China)

Abstract: To improve the recognition accuracy and computational efficiency of gait recognition for lower extremity surface electromyography (sEMG), the Gaussian kernel function-regularized extreme learning machine (GKF-RELM) algorithm is presented. The features of time domain, frequency domain and non-linear dynamics via sEMG signals are extracted and the corresponding gait recognition rates are calculated, respectively. Fisher discriminant function is utilized to analyze the separability of the proposed features, and the fusion features of multi-class features are obtained as the input data to train the classifiers, and the trained classifier is used for gait recognition. The recognition rate and calculation time are compared with support vector machine (SVM) and deep neural network (DNN). The results show that the combination of multi-class features based on Fisher discriminant separability index can obtain the optimal recognition effects, and improve the classification accuracy, as well as optimize the calculation efficiency. In addition, the recognition rate of GKF-RELM method is preferable to that of traditional ELM method.

Key words: gait recognition; multi-feature fusion; GKF-RELM algorithm; deep neural network (DNN); Fisher discriminant analysis

1 引言

人体步态是指人行走时下肢的连续运动及其状态, 正常步态具有互异性、协调性和周期性等特点. 在可穿戴信号源中, 表面肌电信号(surface Electromyography, sEMG)蕴涵着丰富的肌肉运动信息, 可用于区分

肢体动作的不同阶段, 从而实现步态识别^[1-3]. 这在安防监控、运动预测、人机交互等领域具有良好的应用前景^[4].

采用肌电信号进行步态识别, 主要分为特征提取和分类识别两个步骤. 特征提取主要包括时域法、频域

法,以及非线性动力学方法^[5].常用时域特征有积分肌电值、方差、过零点数、波长和威尔逊振幅等^[6,7];频域特征有平均功率频率和中值频率^[8];非线性动力学方法主要有熵值分析,用来描述时间序列的复杂程度^[9,10].虽然肌电信号的特征提取方法很多,但其方法各有优缺点,如时域特征操作简单,当肌肉收缩力大小稍有变化时,时域特征变化较大且不稳定,而频域特征则相对稳定^[11].肌电信号是一种混沌信号,其复杂性介于随机信号和周期信号之间,具有非周期、非平稳、非线性的特性^[12].针对肌电信号非线性特性,通过熵值分析方法,可以描述信号时间序列的复杂程度.但此类方法用于多类动作模式识别时,由于动作电位之间的耦合特性而难以实现准确识别^[13].因此,在步态识别中,如何有效地进行特征提取,从而提高步态运动模式的识别精度,仍然是一个值得探讨的问题.

特征提取的维数过高,会导致训练模型结构复杂,因而在将特征输入分类器进行识别之前,需要寻求一种有效的方法来对特征进行筛选.在生物信息处理领域,Fisher判别分析以最大化类间散布程度与类内散布程度的比值为优化目标,使得各类样本的可分性达到最大^[14].采用Fisher判别分析,分别在日常行走及跌倒行为识别^[15]、手部握力运动模式识别^[16],以及融合人脸与虹膜的身份识别^[17]等方面,均获得了良好的效果.

肌电信号是一种微弱的生物电信号,有效的肌电信号识别算法有助于提高步态识别的准确率.神经网络(Neural Networks, NN)、隐马尔可夫模型(Hidden Markov Model, HMM)、贝叶斯(Bayes)方法,以及支持向量机(Support Vector Machine, SVM)等,广泛应用于人体动作识别领域^[18-20].随着深度学习的发展^[21], Gharehbaghi等人^[22]提出深度时间增长神经网络(Deep Time-Growing Neural Network, DTGNN),可用于对具有循环时间序列特性的生物信号进行分类. Duan等人^[23]引入卷积神经网络(Convolutional Neural Network, CNN),利用肌电信号的频域特征对手势动作进行分类. Suri等人^[24]和 Mukhopadhyay等人^[25]则分别采用不同的肌电信号时域特征,通过深度神经网络(Deep Neural Network, DNN)完成了手势信号的分类识别.然而深度学习网络需要大量训练样本进行迭代训练,在计算时间开销上会比浅层网络大很多.

在计算速度上,超限学习机(Extreme Learning Machine, ELM)与传统神经网络方法相比,在求解过程中具有运算速度快、泛化性能好等优点^[26]. Kuang等人^[27]采集表面肌电信号并提取时域特征构建特征向量,利用ELM算法对人体日常行为的7种动作进行分类识别,结果表明ELM在识别率上高于BP神经网络.曹祥

红等人^[28]利用ELM算法对5种步态动作进行识别,识别率高于SVM算法.同时,ELM算法自身也在不断优化改进, Yang等人^[29]提出双向超限学习机(Bidirectional Extreme Learning Machine, B-ELM)算法,其收敛速度更快,泛化性能更好.将径向基核函数与超限学习机^[30](Radial Basis Function-Extreme Learning Machine, RBF-ELM)融合,可以解决在高维特征空间难以确定非线性映射函数形式和参数及特征空间维数等问题.针对ELM算法容易产生过拟合现象,可在ELM中引入正则化系数,即正则化超限学习机^[31](Regularized Extreme Learning Machine, RELM),该算法具有更好的稳定性和泛化能力.

本文以肌电信号的步态识别为研究对象,针对多类特征的选择问题以及识别精度和算法效率问题开展研究.总体思路是,选择GKF-RELM作为分类器,先分别利用时域、频域和非线性特征以及经Fisher判别得到的组合特征,分别计算步态识别率,再对识别结果进行对比分析讨论,以期达到提高识别准确性和识别效率的结果.

2 肌电信号的特征提取

在肌电信号特征提取前,需要先对原始信号进行消噪处理,避免噪声导致信号失真^[6].然后对消噪处理后的肌电信号分别提取时域、频域和非线性动力学特征.

2.1 时域特征

设 x_i 为每个通道中肌电信号的第 i 个样本点, N 表示每次特征提取时间窗的长度.分别提取积分肌电值(IAV)、方差(VAR)、过零点数(ZC)、波形长度(WL)和威尔逊振幅(WAMP)5种特征,即

$$IAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (1)$$

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2 \quad (2)$$

$$ZC = \sum_{i=1}^{N-1} \text{sgn}(-x_i x_{i+1}) \quad (3)$$

其中, $\text{sgn}(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$ 表示单位阶跃函数.

$$WL = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (4)$$

$$WAMP = \sum_{i=1}^N u(|x_{i+1} - x_i| - T) \quad (5)$$

其中,在肌电信号分析中,阈值 T 一般取值为0.05V.

2.2 频域特征

选取平均功率频率(MPF)和中值频率(MF):

$$\text{MPF} = \frac{\int_0^{+\infty} fP(f) df}{\int_0^{+\infty} P(f) df} \quad (6)$$

$$\begin{aligned} \int_0^{f_{\text{MF}}} P(f) df &= \int_{f_{\text{MF}}}^{+\infty} P(f) df \\ &= \frac{1}{2} \int_0^{+\infty} P(f) df \end{aligned} \quad (7)$$

其中, f 为频率; $p(f)$ 表示肌电信号的功率谱密度函数; f_{MF} 为待求取的中值频率.

2.3 非线性动力学特征

分别提取样本熵(SE)、模糊熵(FE)和排列组合熵(PE)特征, 具体为

$$\text{SE}(m, r, N) = -\ln \left[\frac{\alpha^{m+1}(r)}{\alpha^m(r)} \right] \quad (8)$$

$$\text{FE}(m, r, N) = \ln C_i^m(n, r) - \ln C_i^{m+1}(n, r) \quad (9)$$

$$\text{PE} = -\sum_{j=1}^z K_j \ln K_j \quad (10)$$

其中, m 为嵌入维数; r 是阈值(相似系数); $\alpha^m(r)$ 和 $C_i^m(n, r)$ 分别表示样本熵和模糊熵平均相似度.

记每种排序序列出现的概率分别为 K_1, K_2, \dots, K_z, z 为总的排列组合数.

2.4 Fisher 线性判别方法

Fisher 判别分析是一种应用广泛的有监督降维方法, 通过训练数据的标签信息对目标函数加以约束, 得到类内散度最小化及类间散度最大化以求得最佳子空间投影矩阵^[14]. 类间散度矩阵 S_B 和类内散度矩阵 S_ω 表示如下

$$S_B = \sum_{q=1}^Q N_q (\bar{\eta} - \bar{\eta}_q)(\bar{\eta} - \bar{\eta}_q)^T \quad (11)$$

$$S_\omega = \sum_{q=1}^Q \sum_{i=1}^{Q_q} (\eta_i - \bar{\eta}_q)(\eta_i - \bar{\eta}_q)^T \quad (12)$$

其中, Q 为训练样本类别总数; Q_q 是属于第 q 类的训练样本数量; $\bar{\eta}$ 表示所有训练样本的均值向量; η_i 表示第 i 个训练样本; $\bar{\eta}_q$ 代表第 q 类训练样本的均值向量. 因而可以得到可分性指标 J , 即

$$J = \frac{\text{tr}(S_B)}{\text{tr}(S_\omega)} \quad (13)$$

其中, $\text{tr}(S_B)$ 、 $\text{tr}(S_\omega)$ 分别表示类间和类内离散度矩阵的迹, 指标 J 越大, 说明数据在投影子空间越能获得较好的分类效果^[15].

3 高斯核函数正则化超限学习机

超限学习机(Extreme Learning Machine, ELM)是 Huang 提出的一种机器学习算法^[26], 与传统的神经网络

比较, ELM 算法在求解过程中具有运算速度快、泛化性能好等优点.

对于给定的训练样本集, $\{(\mathbf{x}_i, \mathbf{t}_i) | i = 1, 2, \dots, S\}$, $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})^T \in \mathbf{R}^n$ 为 n 维输入, $\mathbf{t}_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in \mathbf{R}^m$ 为 m 维输出. 具有 L 个隐含层节点并采用激活函数 $\delta(x)$ 的单隐层前馈神经网络模型为

$$\begin{aligned} f_L(x) &= \sum_{i=1}^L \beta_i \delta_i(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{t}_j \\ j &= 1, 2, \dots, S \end{aligned} \quad (14)$$

其中, $\mathbf{w}_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{im})^T$ 为第 i 个隐含层节点与输入节点间的权值向量; $\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$ 为第 i 个隐含层节点与输出节点间的权值向量; b_i 为第 i 个隐含层节点的阈值. 将式(14)写成矩阵形式, 则为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (15)$$

$$\text{其中, } \mathbf{H} = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_S) \end{bmatrix} = \begin{bmatrix} \delta(\omega_1 \cdot x_1 + b_1) & \cdots & \delta(\omega_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ \delta(\omega_1 \cdot x_S + b_1) & \cdots & \delta(\omega_L \cdot x_S + b_L) \end{bmatrix}_{S \times L}$$

为隐含层输出矩阵. ELM 通过寻找网络的最优参数来使目标函数取值最小, 即

$$\min E = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (16)$$

ELM 的网络训练过程可等效为一个非线性优化问题, 当激活函数无限可微时, 网络的输入权值和隐含层节点阈值可随机赋值^[26]. 绝大多数情况下, 隐含层节点数 L 远小于训练样本数 S , 则 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$ 的最小范数二乘解为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (17)$$

其中, \mathbf{H}^+ 为 \mathbf{H} 的 Moore-penrose 广义逆矩阵.

为了解决过拟合问题, Huang 等人^[31]在 ELM 中引入了正则化参数, 以增强 ELM 的稳定性和泛化能力, 构建了正则化超限学习机 RELM. RELM 的目标函数为

$$\min E = \min_{\boldsymbol{\beta}} \left\{ \frac{\lambda}{2} \|\boldsymbol{\varepsilon}\|^2 + \frac{1}{2} \|\boldsymbol{\beta}\|^2 \right\} \quad (18)$$

其中, λ 即为正则化系数; $\boldsymbol{\varepsilon}_j = \sum_{i=1}^L \beta_j \delta(\mathbf{w}_j \cdot \mathbf{x}_j + b_j) - \mathbf{t}_j$ 为训练误差和, $j = 1, 2, \dots, S$; $\|\boldsymbol{\varepsilon}\|^2$ 和 $\|\boldsymbol{\beta}\|^2$ 分别代表经验和结构风险. 由此构造拉格朗日方程得

$$L(\boldsymbol{\alpha}, \boldsymbol{\varepsilon}, \boldsymbol{\beta}) = \frac{\lambda}{2} \|\boldsymbol{\varepsilon}\|^2 + \frac{1}{2} \|\boldsymbol{\beta}\|^2 - \boldsymbol{\alpha}(\mathbf{H}\boldsymbol{\beta} - \mathbf{T} - \boldsymbol{\varepsilon}) \quad (19)$$

$\boldsymbol{\alpha}_i \in \mathbf{R}$ ($i = 1, 2, \dots, S$) 为拉格朗日算子. 由此得

$$\begin{cases} \frac{\partial L}{\partial \beta} = 0 \rightarrow \beta^T - \alpha H = 0 \\ \frac{\partial L}{\partial \varepsilon} = 0 \rightarrow \lambda \varepsilon^T + \alpha = 0 \\ \frac{\partial L}{\partial \alpha} = 0 \rightarrow H\beta - T - \varepsilon = 0 \end{cases} \quad (20)$$

$$\begin{cases} \tilde{\beta} = \begin{bmatrix} \phi(x, x_1) \\ \vdots \\ \phi(x, x_s) \end{bmatrix} \left(\frac{1}{\lambda} + \psi_{\text{GKF}} \right)^{-1} T \\ y = \sum_{i=1}^L \tilde{\beta}_i \delta(w_i \cdot x + b_i) \end{cases} \quad (24)$$

通过式(20)可解得输出权值矩阵,从而得到RELM的拟合回归模型,即

$$\begin{cases} \hat{\beta} = \left(H^T H + \frac{I}{\lambda} \right)^{-1} H^T T \\ y = \sum_{i=1}^L \hat{\beta}_i \delta(w_i \cdot x + b_i) \end{cases} \quad (21)$$

由于提取的特征在低维空间不可线性分离,需要利用核函数将输入样本非线性映射到高维特征空间实现线性可分^[30].核函数 $\phi(x,y)$ 的意义为 x 和 y 在高维空间投影后的内积,常用核函数包括线性核函数(Linear Kernel Function, LKF)、多项式核函数(Polynomial Kernel Function, PKF)以及径向基核函数^[32](Radial Basis Function, RBF)等.其中高斯核函数(Gaussian Kernel Function, GKF)是最常用的径向基核函数,其表达式为

$$\phi(x,y) = \phi(\|x-y\|) = \exp\left\{-\frac{\|x-y\|^2}{2\zeta^2}\right\} \quad (22)$$

其中, ζ 表示核的宽度.本文通过将高斯核函数(GKF)与正则化超限学习机(RELM)组合,得到GKF-RELM算法,此时输出权值矩阵可表示为

$$\tilde{\beta} = \left(\frac{1}{\lambda} + H^T H \right)^{-1} H^T T = \begin{bmatrix} \phi(x, x_1) \\ \vdots \\ \phi(x, x_s) \end{bmatrix} \left(\frac{1}{\lambda} + \psi_{\text{GKF}} \right)^{-1} T \quad (23)$$

从而得到GKF-RELM的拟合回归模型为

其中, ψ_{GKF} 表示高斯核函数.

4 结果分析与讨论

4.1 数据获取与预处理

正常人的步态周期可分为支撑相和摆动相,进而又可再细分成支撑前期、支撑中期和支撑后期、摆动前期和摆动后期共5个阶段^[5].本文选择下肢运动中具有代表性的大小腿上的8块肌肉,分别是:大腿股直肌、股内侧肌、长收肌、阔筋膜张肌和半腱肌以及小腿胫骨前肌、腓肠肌和比目鱼肌.

图1为实验数据采集和算法分析总流程.通过便携式肌电仪(DataLINK SX-230-1000, UK Biometrics Ltd Company)采集表面肌电信号,人体三维位置信息则通过运动捕获系统(Vicon, UK Oxford Metrics Limited Company)得到.6位年龄在23~25岁的健康男性受试者参与实验,为避免随机干扰,每次实验中匀速行走70步,步速为1.3m/s.8块肌肉通过8路肌电信号同时采集,采集频率为1000Hz.

采集到的表面肌电信号,通过小波模极大值方法进行消噪^[6].消噪后的肌电信号通过滑动时间窗方法进行特征提取,设置窗口长度为100ms,增量为30ms.ELM和GKF-RELM分类器的参数设置如下:ELM的隐含层个数为400,转换函数为正弦函数;GKF-RELM的隐含层个数为400,正则化系数 $\lambda=10$,核函数采用高斯核函数.

4.2 单类特征分析与识别

为了全面比较ELM和GKF-RELM算法的分类性

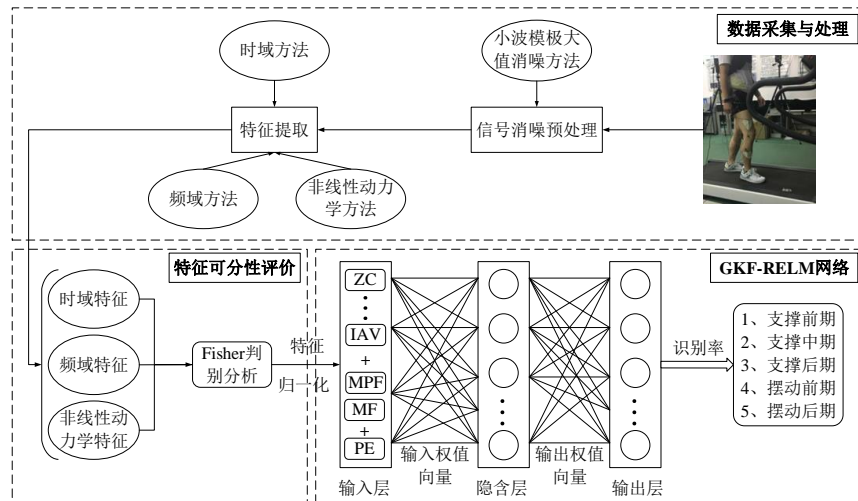


图1 数据采集和算法分析总流程

能,分别采用时域特征、频域特征和非线性动力学特征,进行单类特征及其同类特征组合的步态识别分析。

4.2.1 时域特征分析识别

从时域方法入手,分别提取 6 位受试者 8 个通道肌电信号的 IAV、VAR、ZC、WL 和 WAMP 5 种时域特征,则特征向量共有 $C_5^1 + C_5^2 + C_5^3 + C_5^4 + C_5^5 = 31$ 种组合方式. 将特征向量分别输入 ELM 和 GKF-RELM 分类器中进行识别,表 1 为其中几组代表性结果的识别率。

表 1 时域特征识别率/%

组别		支撑前期	支撑中期	支撑后期	摆动前期	摆动后期	平均识别率
Z ₁	ELM	97.22	91.67	85.60	86.11	79.63	88.05
	GKF-RELM	94.44	93.06	88.02	85.19	87.96	89.73
Z ₂	ELM	97.25	90.97	82.40	88.89	77.78	87.46
	GKF-RELM	97.22	94.44	90.40	96.30	87.04	93.08
Z ₃	ELM	97.22	87.50	90.40	87.96	80.56	88.73
	GKF-RELM	97.22	92.36	89.60	91.67	93.52	92.87
Z ₄	ELM	93.06	95.31	86.40	98.15	84.03	91.39
	GKF-RELM	94.44	92.36	95.20	97.22	93.52	94.55
Z ₅	ELM	94.97	95.51	95.50	96.24	96.59	95.76
	GKF-RELM	97.22	99.31	96.80	99.07	96.30	97.74

表 1 中,特征向量 $Z_1=(IAV)$, $Z_2=(IAV, VAR)$, $Z_3=(IAV, VAR, ZC)$, $Z_4=(IAV, VAR, ZC, WL)$, $Z_5=(IAV, VAR, ZC, WL, WAMP)$ 。

从表 1 中可以发现,在不同的时域特征组合下,步态支撑前期、支撑中期、支撑后期、摆动前期和摆动后期 5 个阶段的整体识别率,GKF-RELM 均要高于 ELM,且当不断增加时域特征并组合成高维特征向量输入分类器识别时,步态周期 5 个阶段的识别结果均有所提升. 这表明,增加时域特征个数,可更加准确地反映步态模式的变化,但同时也会增加计算的复杂度。

为了更全面地分析时域特征的步态识别结果,分别计算不同时域特征组合下两种分类器在步态周期 5 个阶段的平均识别率,比较结果如图 2 所示. 从图 2 中可以看出,对于步态周期 5 个阶段的平均识别率最高为 GKF-RELM 分类器的 97.74%,且随着时域特征的增加,多特征组合向量维数也随之增大,两种分类器对于步态周期的平均识别率有所提高,但也存在增加某些时域特征而识别率降低的情况,说明这些时域特征之间存在一定的相似性,难以具有明显区分度,需要在组合特征向量输入分类器进行步态识别之前对特征进行判别分析并比较特征的可区分度,从而找到最佳的特征组合,这将有利于提高后续的步态识别率。

4.2.2 频域特征分析识别

在频域分析中,本文分别提取 6 位受试者 8 个通道




图 2 时域特征组合平均识别率

肌电信号的 MPF 和 MF 频域特征,将特征向量分别输入 ELM 和 GKF-RELM 分类器进行识别,由此得到不同频域特征组合下的识别结果,如表 2 所示。

表 2 频域特征识别率/%

组别		支撑前期	支撑中期	支撑后期	摆动前期	摆动后期	平均识别率
MPF	ELM	95.14	96.53	94.40	95.20	94.44	95.14
	GKF-RELM	97.22	95.14	96.80	99.08	96.30	96.91
MF	ELM	97.22	83.33	84.00	77.78	65.74	81.61
	GKF-RELM	94.44	84.03	93.60	89.81	79.63	88.30
MPF+MF	ELM	94.44	96.53	97.60	96.80	96.30	96.33
	GKF-RELM	97.22	99.30	96.80	99.07	98.15	98.11

通过表 2 分别比较 MPF 和 MF 两个频域特征在 ELM 和 GKF-RELM 分类器中的识别效果发现,MPF 比 MF 特征的识别率高;当组合 MPF 和 MF 特征向量时,步态周期 5 个阶段的整体识别率有所提高. 在两种分类器中,GKF-RELM 对于步态频域特征的识别性能较好。

进一步计算各种频域特征组合下的平均识别率,结果如图 3 所示. 可以看出,MPF 特征的步态周期平均识别率最高为 GKF-RELM 分类器的 98.3%,对比发现,MPF 的识别率均要高于 MF 的识别率. 而将两个频域组合特征输入分类器进行步态识别时,识别率有所提高. 这说明在单一频域特征无法准确描述步态模式变化时,增加频域特征的个数可以提高步态模式分类识别的准确率。




图 3 频域特征组合平均识别率

4.2.3 非线性动力学特征分析识别

选取SE、FE和PE作为非线性动力学特征,将特征向量输入ELM和GKF-RELM分类器进行识别,由此得到不同熵值特征组合下的识别结果,如表3所示。

通过表3数据发现,FE相比较于SE和PE,平均识别率最高为GKF-RELM分类器识别的91.03%,而PE在ELM分类器中的平均识别率只有83.51%。

表3 非线性动力学特征识别率/%

组别		支撑前期	支撑中期	支撑后期	摆动前期	摆动后期	平均识别率
SE	ELM	86.82	83.20	79.24	85.14	83.96	83.67
	GKF-RELM	87.45	87.64	86.85	90.72	89.45	88.42
FE	ELM	91.67	75.69	90.40	98.15	77.78	86.74
	GKF-RELM	94.44	81.94	93.60	95.37	89.81	91.03
PE	ELM	85.47	80.56	80.25	88.14	83.13	83.51
	GKF-RELM	88.60	81.84	82.61	90.51	86.15	85.94
SE+FE	ELM	94.44	85.42	96.00	93.52	89.81	91.84
	GKF-RELM	95.83	89.06	95.81	95.14	93.06	93.78
SE+PE	ELM	86.23	89.22	85.42	82.64	90.47	86.80
	GKF-RELM	92.61	90.28	93.48	92.87	94.14	92.68
FE+PE	ELM	91.67	77.78	84.80	93.52	87.96	87.15
	GKF-RELM	91.67	86.46	87.43	97.22	92.36	91.03
SE+FE+PE	ELM	94.44	83.33	97.60	93.52	92.59	92.30
	GKF-RELM	97.92	83.85	97.01	95.83	93.75	93.67

进一步计算每种非线性动力学特征组合下的平均识别率。GKF-RELM分类器在非线动力学特征组合下的特征识别结果较好,且单一FE特征的识别率及组合(FE+PE)的识别率均为91.03%,而采用三种特征组合(SE+FE+PE)时,识别率为93.67%,低于组合特征向量(SE+FE)的识别率93.78%。对于ELM分类器,也存在增加特征个数而识别率仅有略微提高的情况。

通过上述分析发现,若直接将各种特征叠加组合后输入分类器进行识别,不但会增加训练模型的复杂度,还会增加模型训练时间并降低分类器的识别精度。

4.3 基于Fisher判别的多特征融合识别

为了融合时域、频域和非线性动力学特征进行综合分析,需要对特征进行融合评估,找到步态周期5个阶段下的最佳特征组合。利用Fisher判别分析方法,分别计算6位受试者30个步态周期中10个特征的可分性指标并取平均值,结果如图4所示。

从图4中可以看出,经过Fisher判别分析后,每个特征的可分性指标具有差异,其中特征ZC、MPF、WL的可分性指标相对较高。首先,取特征向量 $A_1=(ZC, MPF,$




图4 Fisher判别分析

WL),并按照可分性指标从大到小顺序,依次增加特征向量中的特征个数,即 $A_2=(ZC, MPF, WL, IAV)$,并以此类推,其他特征向量分别记作 A_3, A_4, A_5, A_6, A_7 和 A_8 ,进行多特征融合。显然 A_1 中只取了可分性最大的3个特征,而 A_8 则包含了全部10个特征。然后,分别采用这些特征向量,依次输入分类器进行识别。同时,为了与其他方法进行对比分析,在原有ELM和GKF-RELM分类器的基础上,增加了经典的支持向量机^[20](SVM)和基于深度学习的深度神经网络^[25](DNN)分类器,4种分类器的识别结果如表4所示。

表4为通过Fisher判别分析得到的组合特征向量,分别输入4种分类器后得到的步态周期中5个阶段的详细识别结果。为了更直观地进行分析,取每个步态周期的平均识别率,得到如图5所示的结果。

在比较分类精度的同时,为了比较计算效率,本文还记录了采用 A_8 特征进行识别时,4种分类器所需的计算时间(主要硬件配置: Intel i7, 8G RAM, Nvidia GTX 950M),其结果如表5所示。

结合表4、表5和图5,可以发现如下结果。

(1)在计算精度上,ELM与SVM差别不大,但在计算开销上,ELM的计算时间不到SVM和1/3,效率更高。GKF-RELM算法的最佳识别率(取 A_5 特征时),平均比SVM和ELM分别高出1.18%和0.99%,且计算时间虽然比ELM有所增加,但仍然不足SVM的 $\frac{1}{2}$ 。由此可见,本文采用的GKF-RELM算法,在提高识别率的同时,仍保持了较高的识别效率。

(2)当特征向量为 $A_5=(ZC, MPF, WL, IAV, PE, MF, VAR)$ 时,GKF-RELM分类器的步态平均识别率达到最高,为98.60%。此时SVM和ELM分类器中的识别率,也都高于其他特征组合情况,达到了峰值。继续增加特征向量个数,3种分类器的识别率都开始下降,当取 A_8 特征向量时,输入特征向量中包含了全部的时域、频域和非线性动力学等共10个特征,而此时分类器的识别效果并不是最佳。由此可见,综合考虑分类器识别的准确率和特征维数会增加训练时间,本文引入的Fisher判别方法,在利用可分性指标优化特征组合得到最优识别

表 4 多特征融合识别率/%

组别		支撑前期	支撑中期	支撑后期	摆动前期	摆动后期	平均识别率
A1	ELM	95.37	96.45	94.57	98.01	94.64	95.81
	GKF-RELM	95.83	96.35	95.81	98.80	95.14	96.39
	SVM	94.38	93.16	94.69	98.96	96.82	95.60
	DNN	98.76	89.85	93.41	98.50	94.18	94.94
A2	ELM	94.25	97.47	95.51	98.03	95.17	96.09
	GKF-RELM	95.83	97.40	97.60	98.56	96.53	97.18
	SVM	94.29	96.36	96.24	98.10	96.16	96.23
	DNN	99.00	91.35	94.16	97.68	94.72	95.38
A3	ELM	95.20	97.27	95.17	98.30	95.75	96.34
	GKF-RELM	97.92	97.92	96.41	98.20	98.61	97.81
	SVM	95.51	96.62	94.22	97.26	98.31	96.38
	DNN	99.64	91.74	94.25	97.90	94.81	95.67
A4	ELM	95.80	98.53	95.40	97.97	96.73	96.89
	GKF-RELM	97.92	98.96	96.41	97.01	98.61	97.78
	SVM	97.65	94.29	94.18	98.19	98.38	96.53
	DNN	99.67	92.28	94.33	98.10	95.27	95.93
A5	ELM	97.22	98.50	97.30	98.43	96.60	97.61
	GKF-RELM	97.92	98.44	99.40	99.31	97.92	98.60
	SVM	98.55	93.24	96.87	99.68	98.78	97.42
	DNN	99.15	94.79	94.75	99.30	94.91	96.58
A6	ELM	96.30	98.27	95.83	98.26	96.10	96.95
	GKF-RELM	97.92	98.44	96.41	99.30	97.22	97.86
	SVM	97.26	92.56	96.37	99.60	97.31	96.62
	DNN	99.00	93.85	95.17	99.34	95.68	96.61
A7	ELM	94.48	97.81	96.57	97.89	94.82	96.31
	GKF-RELM	95.83	96.88	98.20	96.41	96.53	96.77
	SVM	96.38	92.56	95.29	99.38	96.15	95.96
	DNN	99.27	94.86	95.89	99.21	95.73	96.99
A8	ELM	93.37	94.86	95.57	97.33	94.71	95.17
	GKF-RELM	93.75	94.79	97.60	97.30	94.44	95.58
	SVM	94.26	92.86	94.37	98.61	95.19	95.06
	DNN	99.48	95.74	96.28	99.46	97.16	97.62

表 5 4 种分类器的平均计算时间

分类器	SVM	ELM	GKF-RELM	DNN
时间	3.02s	0.97s	1.30s	8.60min

别率的同时,还有效避免了多余特征引起的时间开销,从而提高了识别效率.

(3)相比 SVM 和 ELM 方法, DNN 方法的识别率则呈现了不同的趋势,当特征样本数增加时,其识别率并未出现峰值,而是随着特征数量的增加而增大,但总体上仍低于 GKF-RELM 方法. 另外 DNN 方法还有两点格外突出:一是在特征较少时,其识别率低于其他 3 种方法;二是其识别计算时间明显高于其他算法. 造成这一现象的主要原因是,本文中数据量较少,不太适合深层网络进行训练^[21]. 在 DNN 方法的对比实验中,适当增加网络层数可以提高模型的性能,但是在数据量不足的情况下,网络结构越复杂越容易出现过拟合现象,故本文采用了多层神经网络结构进行计算,且层与层之间采用激活函数,设置 Dropout 层减小过拟合,并采用随机梯度下降法在训练集上进行迭代训练^[33]. DNN 的不足之处在于,如果训练次数过少则模型无法收敛,因而需要大量的迭代训练,所以总的计算时间远远大于其他 3 种浅层网络方法^[34]. 同时也发现,随着训练数据量的增加, DNN 方法所获得的准确率也随之提升,这在处理大数据方面具有明显优势,也是今后值得研究的方向.

综合上述单类特征识别和基于 Fisher 判别分析的多类特征融合识别结果,相较于单一时域、频域以及非线性动力学方法,通过多特征融合方法并与 GKF-RELM 分类器结合,有效提高了步态识别的准确率,同时 Fisher 判别方法降低了全组合特征的维度,减少了计算的复杂度,提高了计算效率.

5 结论

本文研究了融合表面肌电信号多特征的步态识别问题. 一方面,融合算法相比于时域、频域和非线性特征等单类特征的识别,其识别率更高. 另一方面,在融合算法中采用三类组合特征,并基于 Fisher 判别进行多特征优化组合,不仅提高了识别精度,还减少了冗余特征参与运算的时间开销. 同时,相较于经典 ELM 算法,改进后的 GKF-RELM 算法具有更好的识别效果. 其结果对于人体运动评估、行人步态检测和智能安防监控等,具有一定的参考价值.

参考文献

[1] Mei C, Gao F R, Li Y. A determination method for gait event based on acceleration sensors[J]. Sensors, 2019, 19 (24): 5499.

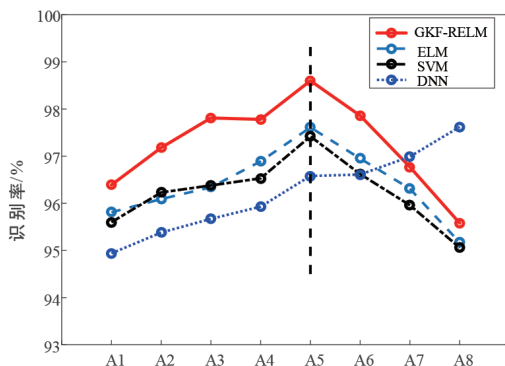



图 5 分类器步态周期平均识别率比较

- [2] 石鹏, 张启忠, 张华平, 等. 基于多元经验模态分解的多元多尺度熵静态平衡能力评估[J]. 电子学报, 2020, 48(4): 670 – 674.
Shi P, Zhang Q Z, Zhang H P, et al. Static balance capability assessment of multivariate multiscale entropy based on multivariate empirical mode decomposition[J]. *Acta Electronica Sinica*, 2020, 48(4): 670 – 674. (in Chinese)
- [3] Ryu J, Lee B H, Kim D H. sEMG signal-based lower limb human motion detection using a top and slope feature extraction algorithm[J]. *IEEE Signal Processing Letters*, 2017, 24(7): 929 – 932.
- [4] Connor P, Ross A. Biometric recognition by gait: A survey of modalities and features[J]. *Computer Vision and Image Understanding*, 2018, 167: 1 – 27.
- [5] Zhang X F, Sun S Q, Li C, et al. Impact of load variation on the accuracy of gait recognition from surface EMG signals[J]. *Applied Sciences*, 2018, 8(9): 1462 – 1476.
- [6] Phinyomark A, Phukpattaranont P, Limsakul C. Feature reduction and selection for EMG signal classification[J]. *Expert Systems With Applications*, 2012, 39(8): 7420 – 7431.
- [7] 牟永阁, 彭承琳, 郑小林, 等. 肌肉动态收缩期间表面肌电信号的时频分析[J]. 生物物理学报, 2004, 20(4): 323 – 328.
Mu Y G, Peng C L, Zheng X L, et al. Time-frequency analysis of surface myoelectric signals during dynamic contractions[J]. *Acta Biophysica Sinica*, 2004, 20(4): 323 – 328. (in Chinese)
- [8] Too J, Abdullah A R, Zawawi T N, et al. Classification of EMG signal based on time domain and frequency domain features[J]. *International Journal of Human and Technology Interaction*, 2017, 1(1): 25 – 29.
- [9] 谢平, 魏秀丽, 杜义浩, 等. 基于自排序熵的表面肌电信号特征提取方法[J]. 模式识别与人工智能, 2014, 27(6): 496 – 501.
Xie P, Wei X L, Du Y H, et al. Feature extraction method of sEMG based on auto permutation entropy[J]. *Pattern Recognition and Artificial Intelligence*, 2014, 27(6): 496 – 501. (in Chinese)
- [10] 成娟, 陈勋, 彭虎. 基于样本熵的肌电信号起始点检测研究[J]. 电子学报, 2016, 44(2): 479 – 484.
Cheng J, Chen X, Peng H. An onset detection method for action surface electromyography based on sample entropy [J]. *Acta Electronica Sinica*, 2016, 44(2): 479 – 484. (in Chinese)
- [11] 罗志增, 王人成. 基于表面肌电信号的前臂手部多运动模式识别[J]. 仪器仪表学报, 2006, 27(9): 996 – 999.
Luo Z Z, Wang R C. Hand movement pattern recognition based on surface electromyography[J]. *Chinese Journal of Scientific Instrument*, 2006, 27(9): 996 – 999. (in Chinese)
- [12] Boyd J E, Little J J. Biometric gait recognition[A]. *Advanced Studies in Biometrics*[M]. Berlin, Heidelberg, GER: Springer Berlin Heidelberg, 2005. 19 – 42.
- [13] 丁帅, 王亮. 基于块稀疏贝叶斯学习的肌电信号特征提取[J]. 仪器仪表学报, 2014, 35(12): 2731 – 2738.
Ding S, Wang L. Feature extraction of surface electromyography based on block sparse Bayesian learning[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(12): 2731 – 2738. (in Chinese)
- [14] 蔡竞, 王万良, 郑建炜, 等. 基于 Fisher 判别分析的增量式非负矩阵分解算法[J]. 模式识别与人工智能, 2018, 31(6): 505 – 515.
Cai J, Wang W L, Zheng J W, et al. Incremental non-negative matrix factorization based on fisher discriminant analysis[J]. *Pattern Recognition and Artificial Intelligence*, 2018, 31(6): 505 – 515. (in Chinese)
- [15] Xi X G, Tang M Y, Miran S M, et al. Evaluation of feature extraction and recognition for activity monitoring and fall detection based on wearable sEMG sensors[J]. *Sensors*, 2017, 17(6): 1229 – 1249.
- [16] 伏云发, 徐保磊, 李永程, 等. 基于运动相关皮层电位握力运动模式识别研究[J]. 自动化学报, 2014, 40(6): 1045 – 1057.
Fu Y F, Xu B L, Li Y C, et al. Recognition of actual grip force movement modes based on movement-related cortical potentials[J]. *Acta Automatica Sinica*, 2014, 40(6): 1045 – 1057. (in Chinese)
- [17] 何国辉, 甘俊英, 李春芝, 等. 人脸与虹膜特征层融合模型的研究[J]. 电子学报, 2007, 35(7): 1365 – 1371.
He G H, Gan J Y, Li C Z, et al. A model study for face and iris feature fusion and recognition[J]. *Acta Electronica Sinica*, 2007, 35(7): 1365 – 1371. (in Chinese)
- [18] 贲晔焯, 徐森, 王科俊. 行人步态的特征表达及识别综述[J]. 模式识别与人工智能, 2012, 25(1): 71 – 81.
Ben X Y, Xu S, Wang K J. Review on pedestrian gait feature expression and recognition[J]. *Pattern Recognition and Artificial Intelligence*, 2012, 25(1): 71 – 81. (in Chinese)
- [19] 席旭刚, 汤敏彦, 张自豪, 等. 融合表面肌电和加速度信号的下肢运动模式识别研究[J]. 电子学报, 2017, 45(11): 2735 – 2741.
Xi X G, Tang M Y, Zhang Z H, et al. Lower limb motion recognition based on the fusion of sEMG and acceleration signal[J]. *Acta Electronica Sinica*, 2017, 45(11): 2735 –

2741. (in Chinese)
- [20] 王佳佳, 高发荣, 孙曜, 等. 基于 sEMG 的行走步态非均匀特性及其对识别的影响[J]. 传感技术学报, 2016, 29(3): 384 – 389.
- Wang J J, Gao F R, Sun Y, et al. Non-uniform characteristics and its recognition effects for walking gait based on sEMG[J]. Chinese Journal of Sensors and Actuators, 2016, 29(3): 384 – 389. (in Chinese)
- [21] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436 – 444.
- [22] Gharehbaghi A, Lindén M. A deep machine learning method for classifying cyclic time series of biological signals using time-growing neural network[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(9): 4102 – 4115.
- [23] Duan N, Liu L Z, Yu X J, et al. Classification of multi-channel surface-electromyography signals based on convolutional neural networks[J]. Journal of Industrial Information Integration, 2019, 15: 201 – 206.
- [24] Suri K, Gupta R. Transfer learning for sEMG-based hand gesture classification using deep learning in a master-slave architecture[A]. The 3rd International Conference on Contemporary Computing and Informatics (IC3I)[C]. Delhi, India: IEEE, 2018. 178 – 183.
- [25] Mukhopadhyay A K, Samui S. An experimental study on upper limb position invariant EMG signal classification based on deep neural network[J]. Biomedical Signal Processing and Control, 2020, 55: 101669.
- [26] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489 – 501.
- [27] Kuang Y X, Wu Q, Shao J K, et al. Extreme learning machine classification method for lower limb movement recognition[J]. Cluster Computing, 2017, 20(4): 3051 – 3059.
- [28] 曹祥红, 刘磊, 杨鹏, 等. 利用多源信息和极限学习机的人体运动意图识别[J]. 传感技术学报, 2017, 30(8): 1171 – 1177.
- Cao X H, Liu L, Yang P, et al. The research of locomotion-mode recognition based on multi-source information and extreme learning machine[J]. Chinese Journal of Sensors and Actuators, 2017, 30(8): 1171 – 1177. (in Chinese)
- [29] Yang Y M, Wang Y N, Yuan X F. Bidirectional extreme learning machine for regression problem and its learning effectiveness[J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(9): 1498 – 1505.
- [30] Huang G B, Siew C K. Extreme learning machine: RBF network case[A]. ICARCV 2004 8th Control, Automation, Robotics and Vision Conference[C]. Kunming, China: IEEE, 2004. 1029 – 1036.
- [31] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B, 2012, 42(2): 513 – 529.
- [32] Dutta S, Singh M, Kumar A. Automated classification of non-motor mental task in electroencephalogram based brain-computer interface using multivariate autoregressive model in the intrinsic mode function domain[J]. Biomedical Signal Processing and Control, 2018, 43: 174 – 182.
- [33] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84 – 90.
- [34] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[A]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)[C]. Boston, MA, USA: IEEE, 2015. 1 – 9.

作者简介



黎毅达 男, 1995年5月出生, 湖南冷水江人. 2020年毕业于杭州电子科技大学控制工程专业, 获工学硕士学位. 现就职于京东物流X研究部. 主要研究方向为智能信息处理和自动驾驶视觉定位技术.

E-mail: lyda2019@163.com



高发荣(通信作者) 男, 副教授, 硕士生导师. 2007年毕业于华中科技大学, 获工学博士学位. 现为杭州电子科技大学自动化学院教师. 主要研究方向为机器人技术、智能信息处理和模式识别.

E-mail: frgao@hdu.edu.cn