

DOI:10.19651/j.cnki.emt.2211409

单点测量数据多模态时序图像框架 对人体跌倒姿态的鉴别*

孙 坚^{1,2} 胡鹏程¹

(1. 三峡大学电气与新能源学院 宜昌 443000; 2. 新能源微电网湖北省协同创新中心三峡大学 宜昌 443000)

摘要: 为了准确识别老人跌倒姿态,及时进行医疗干预,提出一种基于多模态时序图像的人体跌倒姿态鉴别方法。首先将合加速度进行小波包分解、重构出3个子序列,利用3种时序图像算法将之转化,得到3种三通道时序图像;然后通过 ResNet-18 提取其高维特征,运用多模态特征融合;最后将融合结果结合改进随机森林算法,完成人体跌倒姿态的鉴别。在 UMAFall 和 SisFall 两个公开数据集进行验证,得到 98.7% 和 99.3% 的精准率。结果表明,该方法在人体跌倒鉴别中具有较高准确性,可为跌倒的老人及时提供帮助。

关键词: 人体跌倒姿态鉴别;加速度;时序图像;多模态融合;随机森林

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Recognition of human fall posture using multi-mode time-series image frame based on single-point measurement data

Sun Jian^{1,2} Hu Pengcheng¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443000, China;

2. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid, China Three Gorges University, Yichang 443000, China)

Abstract: To accurately identify the elderly's fall posture and timely carry out the medical intervention, a human fall posture identification method based on multi-modal time series images was proposed. First, the resultant acceleration is decomposed into three sub-sequences by wavelet packet, and then three time series image algorithms are used to transform the resultant acceleration into three three-channel time series images. Then, its high-dimensional features are extracted through ResNet-18, and multimodal feature fusion is used. Finally, the fusion results are combined with the improved random forest algorithm to complete the identification of human fall posture. The accuracy of 98.7% and 99.3% were verified in UMAFall and SisFall. The results show that the method has high accuracy in the identification of human falls, and can provide timely help for elderly people who fall.

Keywords: human fall posture recognition; acceleration; time-series image; multimodal fusion; random forest

0 引 言

伴随老龄化人群的增长,老年人的跌倒事件大大增加,对老年人跌倒姿态的鉴别可以向监护人提供更准确、更及时的跌倒信息,以便及时进行医疗救援,故人体跌倒姿态的鉴别已成为亟须解决的问题。通过挖掘智能手机、手表等设备中惯性传感器元件的数据,为人体跌倒姿态鉴别的应用开辟了新方向。由于单节点传感器具有简便、成本低的优点,已被广泛应用,而传感器部署节点的研究尤为关键。通常传感器被部署于胸部、腕部、腰部、大腿和脚踝等位置,

Santoyo 等^[1]和 Saleh 等^[2]在这些位置采集数据分别进行了研究,其中腰部的准确率最高。因此本文以人体腰部作为加速度传感器部署位置展开研究。

现研究阶段,使用加速度传感器的人体跌倒姿态的鉴别被定义为多元时间序列分类问题。其分类方法包括通过阈值达到事件检测目的和基于机器学习生成分类模型^[3]。阈值法计算复杂度低,响应时间短且易于实施。如 Villar 等^[4]和李京慧等^[5]通过比对设定阈值,达到跌倒鉴别的目的,具有一定的准确性。但阈值法特异性差,在高度相似的运动中,如跌倒与跳起,仅靠阈值无法达到令人满意的效果。

收稿日期:2022-09-16

* 基金项目:湖北省自然科学基金青年项目(2020CFB248)资助

与阈值法相比,机器学习方法能有效提高多元时间序列分类问题的特异性^[6]。其中建立分类模型之前,一个关键的步骤便是特征提取。提取时间序列的均值、最值、方差、信号幅值区域等统计特征^[7-8],与经典的机器学习算法结合,如 K 近邻(K-nearestneighbor, KNN)、支持向量机(support vector machine, SVM)以及随机森林(random forest, RF)算法^[9-10]等,常被用于人体跌倒姿态的鉴别。但是被捕获的统计特征仅能反映数据的总体效果、不能描述其瞬时特性,以至对缺失数据泛化能力差,仍需进一步结合特征降维算法。

深度学习模型通过构建一个深层次的神经网络来自动提取特征,以减少了统计特征造成的不完备性。由于神经网络难以探寻一维数据的高维特征且图像分类方法经发展后,现如今可将一维时间序列转换为二维图像数据,故可通过格拉姆角场(Gramian angular field, GAF)、马尔科夫变迁场(Markov transition field, MTF)、递归图(recurrence plot, RP)^[12]算法转换的时序图像完成人体跌倒姿态的鉴别。不同的时序图像可提供基础辨别特征之外的互补特征,而合理的融合这些多模态信息,有助于提高人体跌倒姿态鉴别的准确率。

多模态融合可在模型的数据层、特征层以及决策层进行模态之间的融合。数据层融合缺乏对数据的处理,决策层融合需要训练多种分类器用于融合,而特征层融合使用了丰富的特征数据,且仅需一种分类器。特征层融合方法之一的典型相关分析(canonical correlation analysis, CCA)在语音识别、图像识别、自然语言处理等领域已有广泛应用^[13-14],但 CCA 仅适用于线性可分问题。Wang 等^[15]将核函数引入 CCA,提出了 KCCA 算法,以解决非线性问题。而 KCCA 算法缺乏对样本类别信息的考虑,Huang 等^[16]引入局部判别的思想,充分考虑了同类样本之间的局部相关与不同类样本之间的局部相关关系。但仍只揭示两组变量之间的相关性。Lee 等^[17]使用 SVM 算法、RF 算法以及 LSTM 算法在人体姿态识别中展开研究,其中 RF 算法具有高维特征处理能力强、结构简单且准确率高的特点,但仍存在静态性问题。

针对上述问题,本文提出一种以人体腰部加速度数据为基础结合多模态时序图像的人体跌倒姿态鉴别方法。首先,为了保留时间与数据间的相关性,并提高 ResNet-18 挖掘深层特征能力,引入多种二维时序图像变换方法,将单模态输入转换为多模态输入。其次,提出局部判别多重集典型相关分析(local discrimination multiset canonical correlation analysis, LDMCCA)方法解决非线性模型中的多模态特征融合问题。最后,针对随机森林静态性的问题,引入遗传算法(genetic algorithm, GA),通过调整随机森林和引入新的决策树,来保持随机森林的多样性,从而降低过拟合以及静态性的影响。为了验证其有效性,针对上述改进进行了一系列对比实验,证明了该方法能有效完成人体

跌倒姿态的鉴别。

1 数据预处理

如图 1 所示,人体跌倒产生的加速度信号并非一个平稳信号,可分为 3 个阶段:不平衡阶段、冲击阶段以及恢复阶段。在冲击阶段,加速度曲线存在急速跃变,将之变换到频域后,这些突变信息并不能被展现出来。而小波包分解(wavelet packet decomposition, WPD)是一种从小波分解中提取附加特征的技术,可以解构具有不同分辨率的信号,通过将信号解构为不同的频带来提取细微特征。




图 1 人体跌倒三轴加速度曲线

人体活动加速度信号的 99% 功率集中在 0~15 Hz 频带内。基于腰部加速度信号的人体日常活动和跌倒的重要频率分量集中在 0~10 Hz 内,其中日常活动在 0~2.5 Hz 频带的平均功率百分比在 87.70% 和 98.38% 之间,在跌倒时 0~5 Hz 频段的平均功率在 83.46% 和 97.97% 之间^[18]。为了提高原始信号的表达能力和更好挖掘其深层次特征,将加速度信号进行多层分解至 α : [0~2.5 Hz], β : [2.5~5 Hz] 和 γ : [5~10 Hz] 3 个子频带,通过重构处理在此区间获得 3 个新序列,这些重构序列保留了原始信号在不同频率区间的细节信息。

假定人体在一定时间 k 内的加速度序列为 $\{ax_k, ay_k, az_k\}$,选择合适的最大分解层数,将 $acc = (ax_k^2 + ay_k^2 + az_k^2)^{1/2}$ 分解至 α 、 β 、 γ 子频带并重构,最终获得重构序列 $acc\alpha$ 、 $acc\beta$ 、 $acc\gamma$ 。则人体姿态可表示为 $p = \{acc\alpha, acc\beta, acc\gamma\}$ 。加速度序列是连续的时变序列,单帧数据无法分析出人体运动姿态。因此将加速度序列以时间窗口为单位进行分割,获取具有时间窗口的加速度片段用于分类,同时带有一定滑动步长。时间窗口大小为 m ,步长为 s ,则人体姿态加速度子集 $P^l = \{\{p_1, p_2, \dots, p_m\}, \{p_{s+1}, p_{s+2}, \dots, p_{s+m}\}, \dots, \{p_{k-s}, p_{k-s+1}, \dots, p_k\}\}$ 。

2 人体跌倒鉴别框架

本文提出一种人体跌倒姿态的鉴别方法,如图 2 所示。首先将人体加速度通过 WPD 和重构生成新序列,使用 GAF、MTF、以及 RP 时序图像转换算法获得 3 组图像,每组图像包含 3 个通道,即由 α 、 β 和 γ 频带重构的序列所生成。引入 LDMCCA 算法融合每个模态利用 ResNet-18 提取的高维特征。最后将融合特征输入至改进随机森林算法

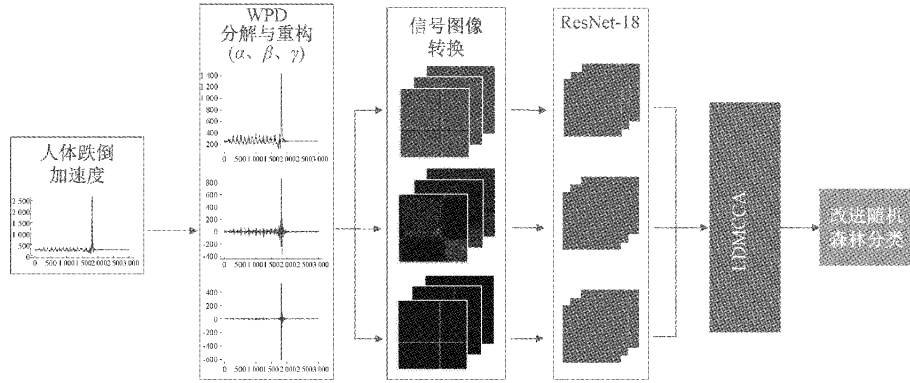


图 2 人体跌倒鉴别框架

中实现人体跌倒姿态的鉴别。

2.1 图像变换

人体跌倒是一个持续性的动作,鉴别过程中需关联前后信息。而时序图像能够降低原始信号中的冗余信息,且保留了时间与数据间的相关性,适用于人体加速度信号。由于编码形式不同,时序图像所蕴含的特征会存在差异,因此引入 GAF、MTF 以及 RP 时序图像变换的方法,所转换的时序图像如图 3 所示。




图 3 3 种时序图像

1) 基于 GAF 的时序图像变换

已知人体加速度序列片段 $P_x = \{x_1, x_2, \dots, x_m\}$, x_i 为第 i 个采样点。通过最大最小值将尺度变换至 $[-1, 1]$, 如式(1)所示。

$$\tilde{x}_i = \frac{(x_i - \max P_x) + (x_i - \min P_x)}{\max P_x - \min P_x} \quad (1)$$

$$\begin{cases} \theta_i = \arccos(\tilde{x}_i) \\ r_i = \frac{i}{m} \end{cases} \quad (2)$$

为了消除直接变换为 GAF 矩阵带来的噪声干扰,要先通过式(2)转换至极坐标系。原始数据转换至极坐标系后,数据仍然保持严格的时间关系。将任意两个角度做内积,在 GAF 中定义如式(3):

$$x_1 \oplus x_2 = \cos(\theta_1 + \theta_2) = x_1 \cdot x_2 - \sqrt{1-x_1^2} \cdot \sqrt{1-x_2^2} \quad (3)$$

如式(4)所示,任意两点之间存在角度,得到格拉姆角场 G :

$$G = \begin{bmatrix} \cos(\theta_1 + \theta_1) & \dots & \cos(\theta_1 + \theta_n) \\ \cos(\theta_2 + \theta_1) & \dots & \cos(\theta_2 + \theta_1) \\ \dots & \dots & \dots \\ \cos(\theta_n + \theta_1) & \dots & \cos(\theta_n + \theta_n) \end{bmatrix} \quad (4)$$

2) 基于 MTF 的时序图像变换

已知人体加速度序列片段 $P_x = \{x_1, x_2, \dots, x_m\}$, x_i 为第 i 个采样点。按其范围划分离散为 Q 个分位数单元,序列中每个离散值对应一个分位数 $q_i (i \in (1, Q))$, 以此来构造马尔科夫转移矩阵 W , 如式(5)所示。

$$W = \begin{bmatrix} w_{11|P(x_i \in q_1 | x_{i-1} \in q_1)} & \dots & w_{1Q|P(x_i \in q_1 | x_{i-1} \in q_Q)} \\ w_{21|P(x_i \in q_2 | x_{i-1} \in q_1)} & \dots & w_{2Q|P(x_i \in q_2 | x_{i-1} \in q_Q)} \\ \vdots & \dots & \vdots \\ w_{Q1|P(x_i \in q_Q | x_{i-1} \in q_1)} & \dots & w_{QQ|P(x_i \in q_Q | x_{i-1} \in q_Q)} \end{bmatrix} \quad (5)$$

其中, x_t 为 t 时刻信号的幅值, w_{ij} 由 q_i 中的数据被 q_j 中的数据紧邻的频率决定。

为了保持人体加速度序列与时间的相关性,将马尔科夫转移矩阵每个元素按照时间顺序排列,以此将马尔科夫转移矩阵 w 扩展为马尔科夫转移场 m , 得马尔科夫变迁场 M , 如式(6)所示。

$$M = \begin{bmatrix} m_{ij|x_1 \in q_i | x_1 \in q_j} & \dots & m_{ij|x_1 \in q_i | x_m \in q_j} \\ m_{ij|x_2 \in q_i | x_1 \in q_j} & \dots & m_{ij|x_2 \in q_i | x_m \in q_j} \\ \vdots & \dots & \vdots \\ m_{ij|x_m \in q_i | x_1 \in q_j} & \dots & m_{ij|x_m \in q_i | x_m \in q_j} \end{bmatrix} \quad (6)$$

式中: m_{ij} 为分数为 q_i 转移到 q_j 的转移概率。

3) 基于 RP 的时序图像变换

RP 通过相空间重构揭示了人体加速度序列信号的周期性、平稳性和内在相似性。已知人体加速度序列片段 $P_x = \{x_1, x_2, \dots, x_m\}$, x_i 为第 i 个采样点。通过相空间重构后,得到式(7):

$$X_i = \{x_i, x_{i-\tau}, \dots, x_{i+(m-1)\tau}\} \quad (7)$$

其中, τ 为延迟时间, m 为嵌入维度, X_i 为重构后相空间的向量。

计算两向量在相空间的欧氏距离得 \mathbf{R} 矩阵, 如式(8)所示:

$$\mathbf{R} = \theta(\epsilon - \|\mathbf{X}_i - \mathbf{X}_j\|), i, j \in (1, m) \quad (8)$$

其中, θ 为 Heaviside 函数, ϵ 是阈值。

2.2 ResNet-18 提取特征

卷积神经网络(convolutional neural networks, CNN)通过卷积核提取图像特征, 具有强大的表征学习能力^[19]。

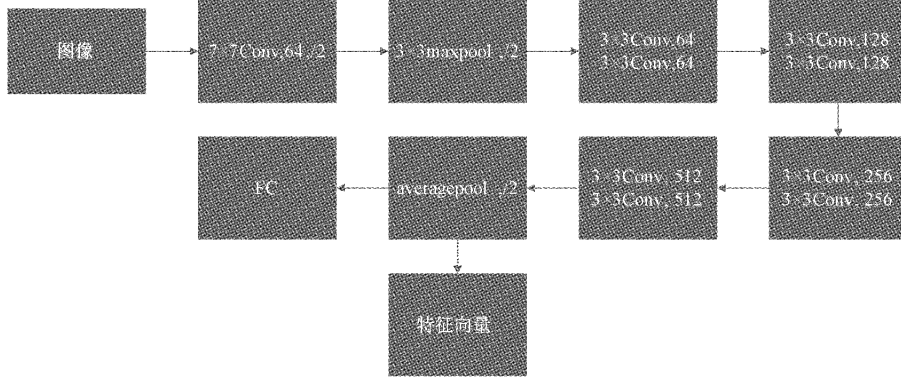


图 4 ResNet-18 网络结构

2.3 局部判别多重集典型相关分析

CCA 是一种计算两组变量之间相关程度的方法。假设存在两组变量 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ 和 $\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$, 其核心思想是寻找典型相关系数 α 和 β 使得 $\mathbf{U} = \alpha\mathbf{X}$ 和 $\mathbf{V} = \beta\mathbf{Y}$ 最大相关, CCA 目标函数如式(9)所示:

$$\max \frac{\alpha^T \mathbf{C}_{xy} \beta}{\sqrt{(\alpha^T \mathbf{C}_{xx} \alpha)(\beta^T \mathbf{C}_{yy} \beta)}} \quad (9)$$

其中, \mathbf{C}_{xy} 是 \mathbf{X} 和 \mathbf{Y} 的互协方差矩阵, \mathbf{C}_{xx} 和 \mathbf{C}_{yy} 是 \mathbf{X} 和 \mathbf{Y} 的自协方差矩阵。由于 α 和 β 大小不变, 只方向变化, 对于同一变量的相关系数压缩成归一化单位方差, 便可将式(9)等效为求解条件极值问题:

$$\begin{aligned} \max & \alpha^T \mathbf{C}_{xy} \beta \\ \text{s. t.} & \alpha^T \mathbf{C}_{xx} \alpha = 1, \beta^T \mathbf{C}_{yy} \beta = 1 \end{aligned} \quad (10)$$

通过拉格朗日乘法, 即可求得 $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_n\}$ 和 $\beta = \{\beta_1, \beta_2, \dots, \beta_n\}$ 。

CCA 利用互补原理, 最大化不同模态数据之间的相关性, 达到多模态数据融合的目的。为了解决非线性问题, 结合局部化思想, 通过考虑邻近样本之间的联系, 使同类局部 KNN 最大相关, 不同类局部 KNN 最小相关。CCA 是用来描述两组变量之间的相关性, 而往往存在两组以上的变量。为了探寻多种变量之间的关系, 在此基础上, 结合非线性局部化和多重集的思想, 提出一种局部判别多重集典型相关分析用于融合多模态时序图像的特征。假设存在 n 组向量 \mathbf{X}_n , 维度是 m , $E(\mathbf{X}_n) = 0$, 由式(9)~(10)推广可得 LDMCCA 目标函数:

但随着 CNN 层数的增加, 逐渐出现梯度消失以及网络退化问题。为了解决这些问题, 何凯明等提出了 ResNet, 该网络具有良好的收敛特性和令人信服的精度。通过引入 shortcut 结构, 使网络在训练过程中, 完成了对冗余层的恒等映射。ResNet-18 结构如图 4 所示, 其平均池化层在保持旋转、平移、伸缩等情况下减少特征和参数^[20], 因此将 ResNet-18 的平均池化层的输出作为特征向量。

$$\begin{aligned} \max & \sum_{i=1}^n \sum_{j=1}^n \alpha_i^T \mathbf{C}'_{ij} \alpha_j \\ \text{s. t.} & \begin{cases} \mathbf{C}'_{ij} = \mathbf{C}_{\omega ij} - \eta \mathbf{C}_{\psi ij} \\ \mathbf{C}_{\omega ij} = \sum_{z=1}^m \sum_{X_{jk} \in N^{\omega}(X_j) \cup X_{ik} \in N^{\omega}(X_i)} X_{iz}(X_{jk})^T + X_{iK}(X_{jz})^T \\ \mathbf{C}_{\psi ij} = \sum_{z=1}^m \sum_{X_{jk} \in N^{\psi}(X_j) \cup X_{ik} \in N^{\psi}(X_i)} X_{iz}(X_{jK})^T + X_{iK}(X_{jz})^T \end{cases} \end{aligned} \quad (11)$$

其中, \mathbf{C}'_{ij} 是 \mathbf{X}_i 和 \mathbf{X}_j 的互协方差矩阵; \mathbf{C}_{ω} 是局部类内协方差矩阵, \mathbf{C}_{ψ} 是局部类间协方差矩阵, η 是平衡参数。 $N^{\omega}(X_i)$ 是 \mathbf{X}_i 类内 KNN 邻域, 即 \mathbf{X}_i 类内相似样本集合, $N^{\psi}(X_i)$ 是 \mathbf{X}_i 类间 KNN 邻域, 即 \mathbf{X}_i 类间相似样本集合。

融合方法包括串行融合和并行融合, 但串行融合优于并行融合, 因此本文采用串行融合去融合多模态特征, 新特征向量 \mathbf{Z} 如式(12)所示。

$$\mathbf{Z} = \begin{pmatrix} \mathbf{U}_1 \\ \mathbf{U}_2 \\ \mathbf{U}_3 \end{pmatrix} = \begin{pmatrix} \alpha_1 \mathbf{X}_1 \\ \alpha_2 \mathbf{X}_2 \\ \alpha_3 \mathbf{X}_3 \end{pmatrix} \quad (12)$$

其中, $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3$ 为三组时序图像由 ResNet-18 所提取的特征向量。

2.4 改进随机森林算法

RF 算法继承了集成学习的思想, 将多个决策树集合起来, 构成一种新的算法^[21]。但随机森林一旦训练完成, 便不能调整, 易陷于局部最优。GA 算法通过一系列概率性方法, 使之无需运行在规则空间内, 自适应调整来达到

寻优的目的^[22]。鉴于此,利用遗传算法中的选择、交叉和变异的思想,改变随机森林的结构,增强其多样性,降低静态性带来的影响,提高算法的稳定性。

在利用 GA 算法优化随机森林过程中,一个随机森林即一个个体,而组成随机森林的决策树对应个体的染色体。个体 N_i 的适应值由随机森林在测试集上的准确率所决定,如式(13)所示。

$$F(N_i) = 1 - \sum_{k=1}^m (T(k, N_i)/m) \quad (13)$$

式中:当第 k 个样本分类正确,则 $T(k, N_i) = 1$; m 为测试集 T 样本数。

GA-RF 算法流程如图 5 所示,具体步骤如下:

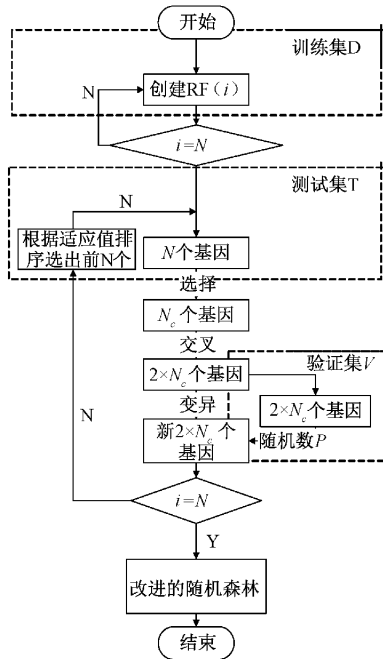


图 5 GA-RF 算法流程

步骤 1) 编码。利用训练集 D 生成 N 个随机森林,组成随机森林 N_i 的每棵决策树表示一个染色体 n_{ij} 。第 i 个随机森林编码如下: $N_i = \{n_{i1}, n_{i2}, \dots, n_{ij}\}$,并由式(13)构建适应度函数。

步骤 2) 选择。根据轮盘赌法选择 c 个优秀个体 $\{N_1, N_2, \dots, N_c\}$,使用测试集 T 计算当前个体的适应值,其适应值越小,被选择的概率越大。

步骤 3) 交叉。当交叉条件满足时,选择两个个体 $N_a = \{n_{a1}, n_{a2}, \dots, n_{aj}\}$ 和 $N_b = \{n_{b1}, n_{b2}, \dots, n_{bj}\}$ 随机选择一段染色体 $\{n_p, n_{p-1}, \dots, n_{p-q}\}$ 进行交换,从而得到两个新的个体 $N'_a = \{n_{a1}, n_{bp}, \dots, n_{bp+q}, \dots, n_{aj}\}$ 和 $N'_b = \{n_{b1}, n_{ap}, \dots, n_{ap+q}, \dots, n_{bj}\}$ 。

步骤 4) 变异。随机选择一个整数 P ,利用验证集 V 训练生成一个染色体 n_p 。当变异条件满足时,代替个体 N_i 中第 P 个染色体,生成一个新的个体 N'_i 。

步骤 5) 当迭代次数满足要求时,输出最佳的随机森林,

否则计算每个个体的适应值选出前 $N' = \{N'_1, N'_2, \dots, N'_i\}$ 个体并跳转至步骤 5) 继续迭代,直至满足条件。

步骤 6) 输出改进的随机森林。

3 算法验证与分析

3.1 数据来源

本文将在两个公开的数据集上进行验证,分别是:

1) UMAFall 数据集,由 Málaga 大学发表公开,通过所建立的人体姿态数据采集系统所采集。该系统利用 1 部手机和 4 个传感器节点构成星形拓扑传感器网络,并分布于手腕、胸口、腰部、脚踝、左腿前侧 5 个位置,其中手机作为中心节点放置于左腿前侧。由 10 男 7 女共 17 名志愿者佩戴该系统进行数据采集,在不影响志愿者人身安全情况下,以 20 Hz 采样频率,执行 13 种日常活动和 3 种跌倒事件,共采集含三轴加速度,三轴陀螺仪、三轴磁力计的 746 个样本。

2) SisFall 数据集,由 Antioquia 大学研制嵌入式设备采集并公开。邀请了 38 名志愿者包括 23 名 19~35 岁的成年人以及 15 名 60~75 岁的老年人,志愿者将采集设备佩戴至腰间,执行 19 种日常活动和 15 种跌倒事件,以 200 Hz 采样频率采集人体运动产生的三轴加速度、三轴陀螺仪数据。

将数据集 1) 和数据集 2) 以 6 : 2 : 2 划分为训练集 D 、验证集 T 以及测试集 V ,并将所有日常活动和跌倒事件都归类为二元分类。经过反复调试,预处理阶段,设置 $m = f_s \times 4.48$ s 为一个时间窗口,并以步长 $s = f_s \times 2.24$ s 滑动。将时序图像大小调整为 $224 \times 224 \times 3$,以适应 ResNet-18。ResNet-18 相关参数设置如下:学习率设置为 0.001, batchsize 设置为 32, epoch 设置为 100。

3.2 时序图像编码分析

将加速度信号变换为 GAF、MTF 以及 RP 图像,结合具有较强特征提取能力的 ResNet-18 进行分类。在分类模型中,精准率常常作为模型评价指标之一。定义以下 4 个参数:TP 被模型预测为正的正样本数;FN 被模型预测为负的正样本数;FP 被模型预测为正的负样本数;TN 被模型预测为负的负样本数。精准率计算如式(14)所示。

$$\text{精准率} = \frac{TP}{TP + FP} \times 100\% \quad (14)$$

分类精准率由表 1 可知,将加速度信号进行 WPD 和重构 3 个新序列,有助于凸显细微特征,同时证明了时序图像分类的可行性和准确性。

3.3 多模态特征融合

为了进一步验证多模态特征融合方法的有效性,将加速度数据变换为时序图像,结合 ResNet-18 的平均池化层提取特征向量,并由 LDMCCA 算法进行多模态特征融合,结合 RF 算法分类。如表 2 所示,简单的融合策略,如求和融合、相乘融合皆低于串行 CCA 融合策略。引入多重集避免了在 3 种模式融合中需多次使用 CCA 算法,同时非线性

表 1 不同信号处理对比

数据集	时序图像	信号处理方法	精准率/%
UMAFall	GAF 图像	不含 WPD	90.1
		含 WPD	93.5
	MTF 图像	不含 WPD	90.4
		含 WPD	94.7
	RP 图像	不含 WPD	90.8
		含 WPD	94.1
SisFall	GAF 图像	不含 WPD	88.2
		含 WPD	92.9
	MTF 图像	不含 WPD	92.1
		含 WPD	94.2
	RP 图像	不含 WPD	89.7
		含 WPD	93.1

表 2 多模态特征融合性能

数据集	融合方法	精准率/%
UMAFall	不融合	94.1
	求和	95.1
	相乘	87.2
	多次 CCA	96.3
	LDMCCA	97.4
SisFall	不融合	93.4
	求和	94.4
	相乘	91.2
	多次 CCA	95.7
	LDMCCA	96.9

性局部化解决了欠拟合的问题。本文提出的 LDMCCA 融合策略取得最高精准率,并证明其有效性。

3.4 模型验证分析

经过反复验证,GA 主要参数设置如下:种群数为 20,最大迭代数为 100,交叉概率为 0.3,变异概率为 0.05;RF 参数主要参数设置如下:最大深度为 18,树的规模为 100。

如图 6 所示,将 GA 算法中的选择、交叉以及变异思想引入到 RF 算法中,随着种群不断迭代进化,选择出最优随机森林,保持了随机森林的多样性,从而避免了 RF 算法陷于局部最优。为了进一步验证 GA-RF 算法的性能,采用 KNN、SVM、RF 以及 GA-RF 算法作为分类器分别进行验证。如图 7 所示 RF 由 GA 算法优化后精准率最高,证明 GA-RF 算法能够及时跳出局部最优解,具有较高的稳定性和精准性。

为了进一步探寻模型的性能,将 GA-RF 分类结果建立混淆矩阵,如表 3~4 所示。由此可知,仅极少量日常活动事件被误判为跌倒,具有理想的识别效果,可以用于老年人跌倒事件检测。同时,由于实验人员具有防备心理,实验样本不具备突发性,与真实样本之间存在一定偏差,




图 6 GA-RF 算法在不同数据集下进化曲线




图 7 多种分类算法对比

这可能是导致误判产生的原因之一。

表 3 UMAFall 数据集混淆矩阵

正确标签	预测标签	
	跌倒事件	日常活动
跌倒事件	445	3
日常活动	18	1 921

表 4 SisFall 数据集混淆矩阵

正确标签	预测标签	
	跌倒事件	日常活动
跌倒事件	1 785	13
日常活动	46	3 469

4 结 论

本文提出一种基于腰部加速度数据结合多模态时序图像的人体跌倒姿态鉴别方法。该方法将人体活动加速度序列 WPD 和重构为 3 个子序列,以此增强信号表征能力,并将其转换具有丰富特征的 GAF 图像、MTF 图像和 RP 图像。结果表明:在人体跌倒姿态的鉴别中,人体加速度序列变换为时序图像具有可行性,并分别在 UMAFall

和 SisFall 数据集上取得 94.1%、93.4% 的平均精准率;设计了多种多模态融合策略实验并证明了 LDMCCA 融合算法在跌倒鉴别中的有效性,相比于 CCA 算法提高了 1.1% 的平均精准率;引入 GA 算法对 RF 算法中的静态性缺陷进行改进,并与 KNN、SVM、RF 等分类器进行对比,进一步证明了 GA-RF 算法的稳定性和精准性。而本文不足之处在于未考虑计算复杂度问题,在接下来的研究中,应探寻一种轻量级的跌倒鉴别方法,如通过阈值法保留可疑数据,再结合本文方法进行鉴别,可降低整体算法复杂程度,以及部署设备的传输成本和功耗成本。

参考文献

- [1] SANTOYO R J A, CASILARI E, CANO G J M. Analysis of a smartphone-based architecture with multiple mobility sensors for fall detection with supervised learning[J]. *Sensors*, 2018, 18(4): 1155.
- [2] SALEH M, ABBAS M, PRUD' HOMM J, et al. A reliable fall detection system based on analyzing the physical activities of older adults living in long-term care facilities [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, DOI: 10.1109/TNSRE.2021.3133616.
- [3] LARA O D, LABRADOR M A. A survey on human activity recognition using wearable sensors[J]. *IEEE Communications Surveys & Tutorials*, 2013, 15(3): 1192-1209.
- [4] VILLAR J R, CHIRA C, DE L C E. Autonomous on-wrist acceleration-based fall detection systems: unsolved challenges [J]. *Neurocomputing*, 2021, DOI: 10.1016/j.neucom.2019.12.147.
- [5] 李京慧,迟宗涛,李钟晓.基于阈值分析法的人体跌倒检测系统[J]. *传感器与微系统*, 2019, 38(8): 80-82,86.
- [6] DE QUADROS T, LAZZARETTI A E, CHNEIDER F K. A movement decomposition and machine learning-based fall detection system using wrist wearable device [J]. *IEEE Sensors Journal*, 2018, 18(12): 5082-5089.
- [7] 范书瑞,贾雅亭,刘晶花.基于三轴加速度传感器人体姿态识别的特征选择[J]. *应用科学学报*, 2019, 37(3): 427-436.
- [8] 宋贺良,郑毅,王克强.可穿戴式人体姿态识别系统研究进展[J]. *激光与红外*, 2021, 51(9): 1123-1128.
- [9] THAKUR D, BISWAS S. A hybrid action related K-nearest neighbour approach for recommendation systems [J]. *IEEE Access*, 2020, DOI: 10.1109/ACCESS.2020.2994056.
- [10] THAKUR DBS, BANASTHALI V. Guided regularized random forest feature selection for smartphone based human activity recognition [J]. *Journal of Ambient Intelligence and Humanized Computing*, 2022, DOI: 10.1007/s12652-022-03862-5.
- [11] QIN Z, ZHANG Y B, MENG S Y, et al. Imaging and fusing time series for wearable sensor-based human activity recognition [J]. *Information Fusion*, 2020, DOI: 10.1016/j.inffus.2019.06.014.
- [12] AHMAD Z, KHAN N M. Multidomain multimodal fusion for human action recognition using inertial sensors[J]. *ArXiv Preprint*, 2020, ArXiv: 2008.09748.
- [13] 马亚彤,王松,刘英芳.融合多模态数据的人体动作识别方法研究[J]. *计算机工程*, 2022, 48(9): 180-188.
- [14] 潘惠苹,任艳,徐春.基于核典型相关分析和支持向量机的图像识别技术[J]. *南京理工大学学报*, 2022, 46(3): 284-290.
- [15] WANG L, KONG W, WANG S Q. Detecting genetic associations with brain imaging phenotypes in Alzheimer's disease via a novel structured KCCA approach[J]. *Journal of bioinformatics and computational biology*, 2021, DOI: 10.1142/S0219720021500128.
- [16] HUANG X Y, ZHANG B, QIAO H. Local discriminant canonical correlation analysis for supervised PolSAR image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 2102-2106.
- [17] LEE S K, AHN J, SHIN J H, et al. Application of machine learning methods in nursing home research[J]. *International Journal of Environmental Research and Public Health*, 2020, DOI: 10.3390/ijerph17176234.
- [18] SANTOYO R J A, CASILARI E, CANO G J M. A study of the influence of the sensor sampling frequency on the performance of wearable fall detectors [J]. *Measurement*, 2022, DOI: org/10.1016/j.measurement.2022.110945.
- [19] 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.
- [20] 朱敏玲,赵亮亮,和首杰.CNN 与 SVM 和 ResNet 相结合的牛脸识别系统模型研究与实现[J]. *重庆理工大学学报(自然科学)*, 2022, 36(7): 155-161.
- [21] 蒋丹凤,温腾腾,吴黎明,等.基于随机森林的气味感知分类研究[J]. *电子测量技术*, 2022, 45(9): 99-103.
- [22] 唐思圆,凌翔.基于遗传算法的多传感器误差配准研究[J]. *电子测量技术*, 2021, 44(4): 57-61.

作者简介

孙坚,副教授,主要从事智能控制、新能源协调控制、机器人控制等研究。

胡鹏程(通信作者),硕士研究生,主要从事模式识别研究。

E-mail: 1220889457@qq.com。