

面向外骨骼性能评估的多源生理能耗预测

李坦, 王宏, 金博丕, 吴志伟

(东北大学 机械工程与自动化学院, 辽宁 沈阳 110819)

摘要: 在外骨骼设计过程中, 助力性能评估直接影响整体结构的安全性和效率. 针对目前性能评估多采用单一指标问题, 提出了一种基于多源生理信号(表面肌电、脉搏和呼吸)的长短期记忆(long short-term memory, LSTM)网络运动能耗预测方法. 该方法首先对生理信号进行处理和特征提取, 然后使用6层LSTM模型进行预测, 并使用K折交叉验证方法进行验证. 同时, 与决策树(decision tree, DT)和支持向量机(support vector machine, SVM)进行了对比实验. 最后, 建立了在线能耗监测系统, 作为评估外骨骼助力性能的依据. 结果表明, 三源信号均方根差(root mean square error, RMSE)为0.073 kJ, 证明了采用多源生理信号融合预测的可行性; LSTM的RMSE相较于DT, SVM下降了39.53%, 15.68%, 测试集的总能耗值误差值为23.98 kJ, 说明LSTM模型对于总能耗预测效果最好, 可用于外骨骼的助力性能评估.

关键词: 能耗预测; 长短期记忆; 外骨骼性能评估; 信号融合; 在线监测

中图分类号: TP 183

文献标志码: A

文章编号: 1005-3026(2024)06-0850-08

Multi-source Physiological Energy Consumption Prediction for Exoskeleton Performance Evaluation

LI Tan, WANG Hong, JIN Bo-pi, WU Zhi-wei

(School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China. Corresponding author: WANG Hong, E-mail: hongwang@mail.neu.edu.cn)

Abstract: In the process of exoskeleton design, the evaluation of assistance performance directly impacts the overall structural safety and efficiency. Addressing the current issue of predominantly utilizing single metrics for performance evaluation, a method based on multi-source physiological signals (surface electromyography, photopretismography, and respiration) for LSTM prediction of motion energy consumption was proposed. This method involves preprocessing and feature extraction of physiological signals, followed by prediction using a 6-layer LSTM model and validation through K-fold cross-validation. Comparative experiments with DT and SVM were conducted. Finally, an online energy consumption monitoring system was established, serving as a basis for evaluating exoskeleton assistance performance. Results indicate the feasibility of utilizing multi-source physiological signals for fusion prediction, with an RMSE of 0.073 kJ for the three-source signal. The LSTM model achieves a 39.53% and 15.68% reduction in RMSE compared to DT and SVM, respectively. The total energy consumption error on the test set is 23.98 kJ, demonstrating the superior performance of the LSTM model for total energy consumption prediction and its suitability for exoskeleton assistance performance evaluation.

Key words: energy consumption prediction; LSTM; exoskeleton performance evaluation; signal fusion; online monitoring

外骨骼已被开发用于帮助下肢肌肉恢复耗散的动能, 以提高步行效率^[1-2], 用于增强人体负

重能力, 减少人力使用. 合理、客观的助力性能评估作为一种重要反馈依据, 有助于指导和优化外

收稿日期: 2023-02-09

基金项目: 国家重点研发计划项目(2021YFF0306405).

作者简介: 李坦(1998-), 女, 山东菏泽人, 东北大学博士研究生; 王宏(1960-), 女, 辽宁沈阳人, 东北大学教授, 博士生导师.

骨骼控制设计.外骨骼主要目标是对用户的运动功能产生影响,即降低用户活动能量消耗(简称能耗).因此,能耗可作为外骨骼助力性能的重要评价指标.如果穿戴外骨骼可以有效降低用户的能耗,可以反映出穿戴外骨骼具有助力效果.目前国内外缺少标准化的面向外骨骼助力能耗评估方法. Baltrusch等^[3]使用了Cosmed srl呼吸气体分析系统评估被动外骨骼对重复举重的能量代谢的影响; Zhou等^[4]使用Oxycon Mobile间接量热系统来测量使用无动力髌关节外骨骼步行过程中能耗代谢并进行性能评估.这种能耗获取方式主要是根据呼吸氧气消耗和二氧化碳产生量,需要依赖高精度的测量面罩.实际上,外骨骼性能评估需要在非自然的实验室条件下进行长时间的测试^[5],长时间佩戴面罩存在不适感. Beato等^[6]对运动中的受试者进行心率测量,之后根据心率和摄氧量的关系进行运动消耗计算. Bisi等^[7]使用表面肌电(surface electromyography, sEMG)信号评估在单侧腿部推举运动过程中的能耗情况,通过比较与气体交换数据测量的能耗证明了该方法的有效性.这些方法大多是通过采集单一信号进行能耗预估,提供了一定的参考意义.

然而,用户穿戴外骨骼时运动过程存在大量复杂和交互效应的附加因子^[8],能耗有着较强的非线性和不确定性,若仅靠单一的信号来源,过于简化人体运动与代谢能量消耗之间的关系,难以全面反映运动状态以及外骨骼的助力效能.相关学者已经证明能耗与生理信号有关,如sEMG^[7]和心率^[9]等.本研究使用sEMG信号、光电容积脉搏波(photopretismography, PPG)信号以及呼吸(respiration, RESP)信号进行能耗预测.此外,这些信号均为时间序列信号,即基于时间顺序的一系列数据.长短期记忆(long short-term memory, LSTM)网络是基于循环神经网络(recurrent neural network, RNN)的一种变体,对于时间序列相关的连续运动信号具有很好的预测效果^[10-11].

针对上述问题,本研究提出了一种基于多源信号的面向外骨骼助力能耗评估方法,具体通过采集被试者的sEMG, PPG, RESP数据,利用LSTM建立能耗预测模型,采用K折交叉验证方法对多源特征组合信号(单一源信号、双源信号以及三源信号)进行对比试验,并对比决策树(decision tree, DT)和支持向量机(support vector machine, SVM)模型的预测效果.同时开发了基

于LabVIEW的在线可视化的预测系统,用于在线采集生理信号和能耗监测,监测结果可作为外骨骼助力性能的依据.

1 数据获取

1.1 实验设备

能耗测量精度受多方面因素影响,如温度和工频干扰等.因此,实验在全封闭的安静实验室内进行,确保室内温度维持在 (25 ± 0.5) °C、相对湿度维持在 (45 ± 1) %.参考相关研究^[12]的方法,将跑步机作为运动能耗标定监测工具.使用汇康A1680跑步机作为运动环境,该设备可调节速度范围0.3~16 km/h,并可实现 0° ~ 16° 坡度调节.

在实验过程中,被试者的sEMG, PPG, RESP信号利用Biofeedback 2000 X-pert型生物反馈仪(SCHUHFRIED公司,奥地利)采集.本研究具体使用EMG Module检测模块进行sEMG信号采集,将导电凝胶差动湿电极片贴在小腿腓肠肌外侧,该传感器参数范围为0~10 mV,精度为 $0.01 \mu\text{V}$;使用Multi Module检测模块进行PPG信号采集,将带有红外脉冲传感器的电极绑带缚于被试左手的中指上,该传感器参数范围为30~200次/min,测量分辨率为1次/min;使用RESP Module测量模块进行RESP信号采集,将呼吸带围绕穿戴者胸腔一周用于测量腹式呼吸,在运动实验中注意防止导管急剧弯曲或扭结,该传感器参数范围为 ± 11 cm,分辨率为0.2 mm.三种信号采集单元以50 Hz的相同采样频率和24位的相同量化分辨率同时记录生物信号以满足实验测试需求.传感器穿戴示意如图1所示,穿戴位置与外骨骼结构未发生干涉.根据信号采集仪(Biofeedback 2000 X-pert)使用方法,将采集仪生理指标信号通过Bluetooth Wireless PAN 3.0连接至电脑并与电脑中的BFB2000软件同步.

1.2 实验设计

参与实验的被试者为6名男性,平均年龄24.8岁,近期没有心血管、肌肉骨骼或神经系统疾病,且精神状态良好.所有被试者均自愿参与实验并知晓实验流程,同意配合测量运动过程中的sEMG, PPG和RESP信号,且都签署了实验知情同意书.

实验开始前,被试者穿戴好Biofeedback 2000 X-pert设备后在跑步机上步行2 min,熟悉实验环境以及进行热身活动,实验员观察此时数据信号并进行调整.待数据采集及保存功能未见

异常后,开始正式实验.每名被试者以 4 km/h 的速度在跑步机上步行 60 min.此时跑步机传送带倾斜角度为 0° ,即相当于平地步行.三种生理信号由 Biofeedback 2000 X-pert 设备同时采集并传输至计算机中.在实验进行过程中,被试者手握跑步机测量手柄,实验员实时记录每次能耗值刷新的时间和能耗数值,观察数据是否发生异常.若发生异常则终止实验,检查传感器是否掉落,被试者需要重新再次进行实验,直到实验完成.




图 1 信号采集传感器穿戴示意图

Fig. 1 Schematic diagram of the signal acquisition sensor worn

2 数据处理

2.1 信号预处理

sEMG, PPG 和 RESP 三种信号都是非平稳且微弱的电信号,易受硬件及实验环境影响,采集到的原始数据包含噪声数据^[13],例如肌肉生理特性、基线漂移、检测设备,以及空间环境中 50 Hz 工频干扰等.因此,需对原始数据进行降噪预处理.

对 sEMG 原始信号进行 25~450 Hz 带通滤波和 48~52 Hz 陷波滤波,以去除高频噪声和工频干扰.对 PPG 原始信号进行 0.1~20 Hz 带通滤波消除高频噪声和低频噪声(如静脉血容量的变化、温度变化等),并滤除 0.1 Hz 的基线漂移.采用截止频率为 2 Hz 的低通滤波器去除 RESP 原始信号的高频噪声,再通过窗口大小为 100 ms 的滑动平均滤波处理.三种生理信号处理前后对比如图 2 所示.

2.2 信号特征提取

特征提取采用设置时间窗方式,保证实验数据在时间上的连续性.考虑到运动环境(跑步机)能耗值刷新频率以及在线预测的实时性要求,时

间窗口大小选用 5 s.这一选择基于对能耗数据的详细分析,发现 5 s 的时间窗口能够捕捉到运动过程中的关键变化.较小的时间窗口提供更高的时间分辨率,能够更准确地捕捉到运动能耗的瞬时波动,从而更好地满足实时性的要求.对于 sEMG 信号提取 4 种时域特征:均方根值(RMS)、标准差(SD)、绝对值均值(MAV)、波形长度(WL).计算过程如下公式所示.

$$\text{RMS} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N x_i^2}, \quad (1)$$

$$\text{SD} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}, \quad (2)$$

$$\text{MAV} = \frac{1}{N} \sum_{i=1}^N |x_i|, \quad (3)$$

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

其中: N 为样本数; $x_i (i=1, 2, \dots, N)$ 为肌电信号的时间序列; \bar{x} 为时间序列的平均值.




图 2 三种信号时域图

Fig. 2 Time-domain diagrams of the three signals (a)—sEMG 信号; (b)—PPG 信号; (c)—RESP 信号.

PPG 信号在每个脉搏周期内的分割采用小波模极大值法^[14],确定 6 个脉搏波特征点,选取 3 个特征:周期脉搏压均值(P_m)、脉动间隔(T)、脉搏收缩面积比(S_\wedge):

$$P_m = \frac{1}{T} \int_0^T P(t)dt, \quad (5)$$

$$T = T_{i+1} - T_i, \quad (6)$$

$$S_\wedge = \frac{S_a}{S}. \quad (7)$$

其中: $P(t)$ 为人体脉搏波随时间变化的函数; T_{i+1} , T_i 分别为上一脉动和当前脉动时刻; S, S_a 分别为脉搏收缩面积和总面积。

RESP 信号根据两个相邻波峰与波谷的关系,选取 2 个特征:平均呼吸幅值(\bar{A}_r)和呼吸频率(f).计算过程为

$$\bar{A}_r = \frac{1}{N} \sum_{i=1}^N |a_i|, \quad (8)$$

$$f = \frac{m'}{m}. \quad (9)$$

其中: a_i 为呼吸信号的时间序列; m' 为 m 内的呼吸次数。

为了消除个体差异对实验结果的影响,需要特征量来表示人体运动生理体征,因此,增加身体指标特征量,即体重指数 BMI. 计算过程为

$$BMI = \frac{H}{W}. \quad (10)$$

其中: H 为身高值; W 为体重值。

由于各特征量化范围不同,梯度更新时量化指标会发生震荡波动,因此,采用 min-max 标准化对特征进行归一化处理,将每个特征量缩放到 $[0, 1]$ 范围,并能较好保持原有数据分布结构。

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}. \quad (11)$$

其中: \tilde{x} 为归一化后的特征值; x 为特征原始值; x_{\min}, x_{\max} 分别为样本中特征的最小值和最大值。

2.3 数据集划分

运动能耗数据具有时间序列的特征,本研究使用前 1 min 数据对能耗进行预测,特征提取窗口大小为 5 s,因此 LSTM 模型的时间步长为 12,输入数据大小为 $(n, 12, 10)$,其中 n 为样本长度。每次用前 12 个数据特征组成的矩阵作为输入 X ,第 12 个样本时间所对应的运动能耗值作为输出 Y 。每名受试者运动实验时间为 60 min,处理后得到 720 个样本。时间窗移动方式以及数据集的构成如图 3 所示,通过时间窗之后每名受试者得到 709 个数据样本,总数据按照 6:1:1 比例划分训练集、验证集和测试集。




图 3 时间窗口移动及每名受试者数据集构成示意图

Fig. 3 Diagram of time window movement and data set composition for each subject

3 能耗预测模型搭建

3.1 LSTM 网络简介

为解决序列较长时出现梯度爆炸或梯度消失的问题, Hochreiter 等^[14]在 1997 年提出了 LSTM. LSTM 的关键是细胞状态,通过“门”结构

对细胞状态进行删除或者添加信息。“门”由 Sigmoid 层和点乘法运算组成,包括遗忘门 f_t , 输入门 i_t 和输出门 o_t . 该模型整体结构如图 4 所示. LSTM 的计算步骤如下。

首先,计算出 f_t, i_t 和 o_t , 以及输入单元状态 c_t' :

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f), \quad (12)$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i), \quad (13)$$

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o), \quad (14)$$

$$c'_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c). \quad (15)$$

其中: h_{t-1} 为上一时刻的外部状态; x_t 为当前时刻的输入; b_f, b_i, b_o, b_c 分别为 f_t, i_t, o_t 以及 c'_t 的偏差项; σ 为 Sigmoid 激活函数; \tanh 为双曲正切激活函数; W_f, W_i, W_o, W_c 分别为 f_t, i_t, o_t 和 c'_t 的权重.




图 4 LSTM 网络整体结构

Fig. 4 Overall structure of the LSTM network

然后,结合 f_t 和 i_t 来更新记忆单元 c_t :

$$c_t = f_t c_{t-1} + i_t c'_t. \quad (16)$$

其中, c_{t-1} 为 $t-1$ 时刻的单元状态.

最后,结合 o_t , 将内部状态的信息传递给外部状态 h_t :

$$h_t = o_t \tanh(c_t). \quad (17)$$

3.2 LSTM 结构框架

本研究所提出的 LSTM 预测模型由 6 层组成,如图 5 所示.该结构包含 2 层 LSTM 网络,每层都设置了 Dropout(0.2)以防止过拟合.随后,引入了一个全连接层,将 LSTM 的输出转换为一个具有实际值的输出.在全连接层之后,采用线性激活函数.模型结构的构建依据对序列预测任务的深入理解和以往研究的经验.

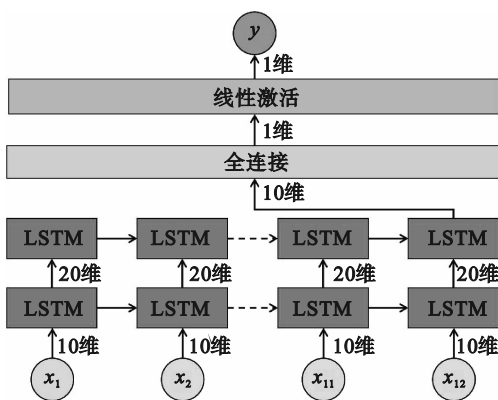


图 5 LSTM 模型结构图

Fig. 5 LSTM model structure diagram

具体而言,设计了 2 层 LSTM 网络以捕捉时间序列中的长期和短期依赖关系. Dropout 被引

入以增强模型的泛化性能,避免在训练过程中对某些特定模式的过度拟合.全连接层用于将 LSTM 的输出映射到最终的预测结果,线性激活函数则用于保留输出的连续性,确保预测值在合理的范围内.该 LSTM 模型结构充分考虑了序列数据的特点,并借鉴了先前在时间序列预测领域取得的成果.这一设计旨在提高模型的准确性和泛化能力,以适应运动能耗的复杂动态变化.

3.3 预测模型流程

本研究使用 64 位 Windows 10 版本系统计算机,利用 PyCharm Professional Version 2020.3.1 和 Anaconda3 开发环境,使用 Tensorflow 框架搭建模型.整体预测流程如图 6 所示,主要包括多源生理信号获取、数据预处理、数据特征提取、预测模型训练、测试和应用.

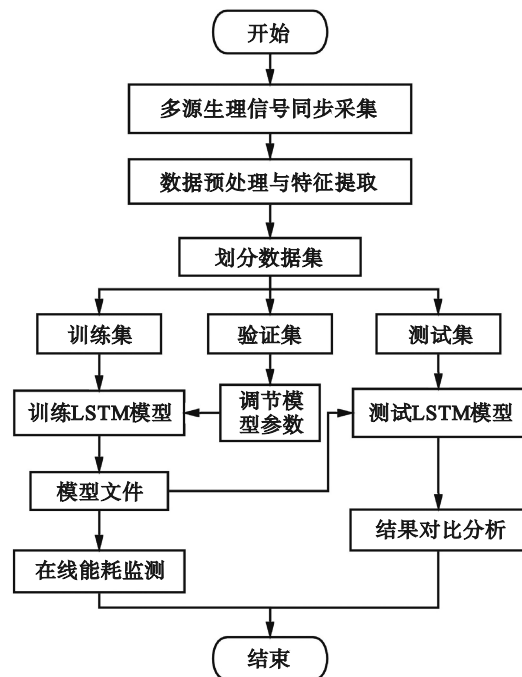


图 6 运动能耗预测流程图

Fig. 6 Flow chart for predicting energy consumption in motion

1) 通过实验同时采集 sEMG, PPG 和 RESP 三种生理信号,并对采集到的数据进行预处理和特征提取,之后归一化处理.对所有数据按照 6:1:1 比例划分训练集、验证集和测试集.

2) 利用训练集数据进行 LSTM 模型训练,输入数据大小为 $(n, 12, 10)$,其中 n 为样本长度,12 为时间步长,10 为特征数量.采用 K 折交叉验证方法调节训练模型参数.其中优化器选择 Adam Optimizer, batch_size 设置为 8,迭代次数为 130,

学习率为 0.006.

3) 采用测试集测试预测模型性能,同时将模型文件导入利用 LabVIEW 搭建的在线能耗预测可视化平台.

3.4 模型评价指标

在 LSTM 给出预测值之后,需要对模型的预测精度以及有效性进行评价,分析预测值和实际观测值之间的差异程度.本研究评判指标为均方根误差 (root mean square error, RMSE), 计算公式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (18)$$

其中: y_i 为 i 时刻运动能耗的实际测量值; \hat{y}_i 为 i 时刻运动能耗的预测值; N 为样本集数量.

4 模型实验结果及分析

4.1 交叉验证分析

为验证多源信号组合预测模型的可行性与准确性,采用 K 折交叉验证方法对不同信号特征组合进行内部交叉验证,此时 K 为 7. 信号组合分为三类:单一源信号、双源信号和三源信号.其中,单一源信号包括 sEMG (s), PPG (P) 和 RESP (R), 双源信号是将任意两个单一源信号进行组合,包括 sEMG-PPG (s-P), sEMG-RESP (s-R) 和 PPG-RESP (P-R), 三源信号是将三个单一源信号进行组合,即 sEMG-PPG-RESP (s-P-R). 每组特征选取对应的生理信号特征外加 BMI, 特征数量及测试结果如表 1 所示. 由表 1 可以看出,单一源信号的 RMSE 均大于 0.108 kJ, 双源信号的 RMSE 在 0.080~0.089 kJ 之间, 三源信号的 RMSE 为 0.073 kJ. 结果表明,信号特征融合的数量对预测性能有一定影响,其中三源信号融合效果最好.

表 1 不同特征组合交叉验证
Table 1 Cross-validation of different feature combinations

组合类型	信号名称	特征个数	RMSE/kJ
单一源信号	s	5	0.133
	P	4	0.116
	R	3	0.120
双源信号	s-P	8	0.089
	s-R	7	0.087
	P-R	6	0.080
三源信号	s-P-R	10	0.073

sEMG 主要反映人体肌肉载荷,与能耗没有特别明显的直接关系;PPG 反映心脏搏动情况,与运动剧烈程度呈正相关关系,能够在一定程度上反映能耗情况,但易受情绪及环境影响发生波动,PPG 单独预测仍存在不确定性;RESP 能够反映人体代谢情况,但存在随体内激素调控的波动.因此,单一源信号虽然可一定程度反映能耗代谢信息,但都存在一定干扰情况.双源信号和三源信号预测效果较单一源信号预测效果更好, RMSE 明显减小,预测结果的稳定性得到较大改善.三源信号能够补充彼此,多方面显示出运动者的精细状态,从而提升运动能耗的预测准确度.结果证明,采用三源信号融合模型进行能耗预测具有可行性.

4.2 预测模型对比实验

为了验证 LSTM 模型在能耗预测方面的优越性,选择 DT, SVM 模型作为对照,评价指标结果如表 2 所示.其中,DT 使用 CART 算法,限制树的最大深度为 10,每个叶子节点的最小样本数为 5. SVM 模型选择径向基函数核,设置惩罚参数 C 为 1.0,核函数宽度 γ 为 0.1. 从表 2 中可以看出, LSTM 模型效果明显优于其他预测模型, RMSE 值相较于 DT, SVM 分别下降了 39.53%, 15.68%. LSTM 与 SVM 模型的 RMSE 之间具有显著的统计学差异 ($P=0.003$), DT 与其余两种模型之间具有十分显著的统计学差异 ($P<0.001$). 三种模型运动能耗的预测结果如图 7 所示. 从图 7 可以看出, DT, SVM 模型尽管可以描述大致的能耗值,但局部量的描述能力较差,说明了 LSTM 模型在数据的拟合度上表现性能明显高于 DT, SVM 模型.

表 2 预测模型评价指标对比
Table 2 Comparison of predictive model evaluation indicators

方法	RMSE 均值	RMSE 方差
DT	0.108	0.009 0
SVM	0.077	0.008 0
LSTM	0.065	0.004 5

在实际穿戴外骨骼实验应用中,大家更关注一段时间内的总能耗值.通过与未穿戴外骨骼相同时间内的能耗值比较,进行外骨骼助力性能评估.本研究将测试集内预测能耗值相加作为总能耗,图 8 为三种模型总能耗值对比.可以看出,预测误差值最小的为 LSTM 模型,误差值 23.98 kJ,其次为 SVM 模型,误差值 89.03 kJ,误差最大的为 DT 模型,误差值 149.14 kJ. DT 模型的基本原理

是以层级结构逐渐往下拆分,最终形成较少的决策结果,但运动能耗预测问题涉及到多种因素,即便是拆分了很多次也不能准确识别出运动的各种情况,同时DT和SVM模型在预测时没有考虑到延迟和滞后效应.而LSTM模型能够记忆较长时间序列,且能够更好地获取运动中连续时间段的信息.总能耗值是每一个样本点绝对误差的累计,因此,LSTM模型的总误差值最小.以上结果说明,LSTM模型对一段时间内的运动总能耗预测效果更好,可以应用于外骨骼的助力性能评估.

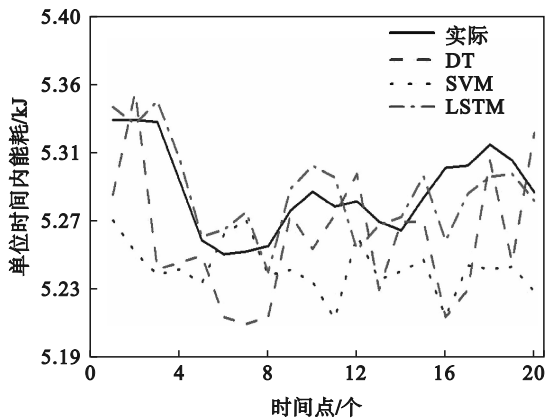


图7 DT,SVM和LSTM模型预测效果图

Fig. 7 Prediction results of DT,SVM and LSTM models




图8 测试集数据预测的总能耗值对比

Fig. 8 Comparison of total energy consumption values predicted from test set data

5 外骨骼助力评估方法应用

本研究团队研发的外骨骼为柔性外骨骼,主要由负重背架、可调腰带、鲍登线及集成硬件系统几部分组成.由于刚性结构的自身质量会为穿戴者带来额外的负担,故除电机输出轴与髋关节

外展内收支架采用铝合金材料外,其余部分材料均采用碳纤维或3D打印材料,整个系统质量只有6.5 kg(包含左右电机),外骨骼穿戴效果如图9所示.




图9 柔性外骨骼穿戴效果图

Fig. 9 Wearing effect of the flexible exoskeleton

同时为了更直观展示外骨骼能耗助力效果,本研究以计算机为主控单元,以LabVIEW软件为开发平台设计了能耗监测系统,充分发挥了虚拟仪器技术的优势.该系统界面如图10所示,主要包括波形图显示、硬件连接状态、测试者信息和能耗分析结果显示4个部分.该系统不仅可以实现对下位机数据(sEMG,PPG和RESP信号)进行采集和显示,而且内置了LSTM模型用于实现实时运动能耗预测以及输出展示.该系统每间隔1 min自行保存当前监测时间和能耗值.

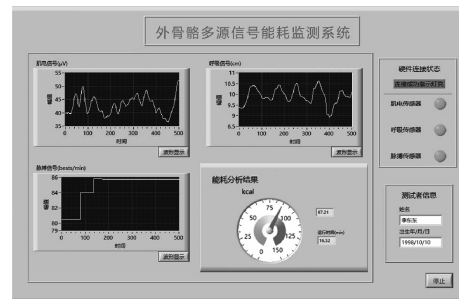


图10 基于LabVIEW的能耗在线监测系统界面

Fig. 10 Interface of online energy consumption monitoring system based on LabVIEW

外骨骼能耗评估流程图如图11所示.在受试者穿戴与未穿戴外骨骼的状态下分别进行相同时间的走路运动,运动的环境与速度设置均一样.通过能耗在线监测系统记录未穿戴外骨骼时的能耗 E_1 以及穿戴外骨骼时的能耗 E_2 .若 $E_1 > E_2$,说明外骨骼起到了助力效果,同时通过计算 $(E_1 - E_2) / E_1$ 定量描述外骨骼助力性能;若 $E_1 < E_2$,

说明外骨骼未起到助力效果,需进一步对外骨骼进行优化.

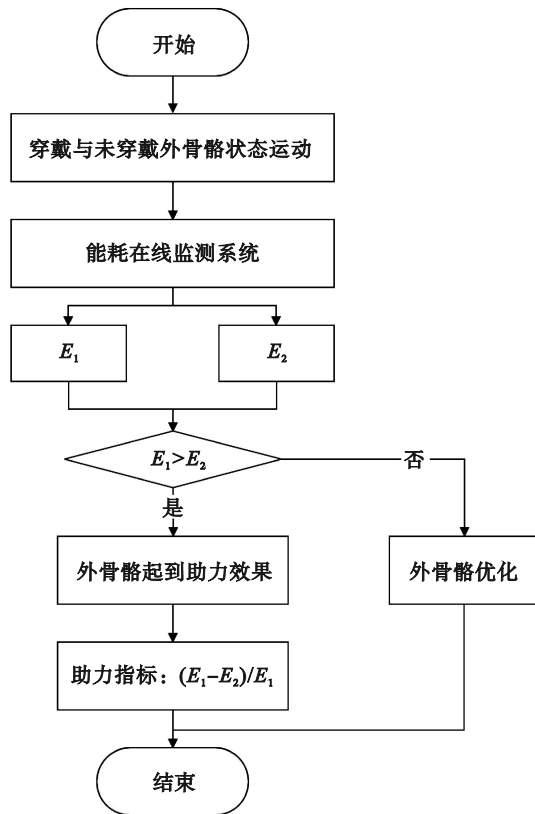


图 11 外骨骼能耗评估流程图

Fig. 11 Flow chart for exoskeleton energy consumption evaluation

6 结 论

1) sEMG, PPG 和 RESP 三类信号特征融合的数量对预测性能有影响,其中三源信号融合 RMSE 为 0.073 kJ,说明本研究所提出的多源信号融合能够一定程度上提高运动能耗预测精度.

2) LSTM 模型的 RMSE 值相较于 DT, SVM 模型分别下降了 39.53%, 15.68%, 说明了该模型在数据的拟合度上表现性能明显高于 DT, SVM 模型.

3) 对于一段时间内的总能耗值,DT, SVM 和 LSTM 模型误差分别为 149.14, 89.03 和 23.98 kJ,说明 LSTM 模型对于总体能耗预测效果最好,可以应用于外骨骼的助力性能评估.

4) 基于 LabVIEW 搭建的在线能耗监测系统,可为外骨骼助力性能评估提供可视化服务,同时输出结果可定量描述外骨骼助力性能.

参考文献:

- [1] Shepertycky M, Burton S, Dickson A, et al. Removing energy with an exoskeleton reduces the metabolic cost of walking[J]. *Science*, 2021, 372(6545):957-960.
- [2] 戚文谦,孙守迁,陈超,等.面向竞技训练的下肢外骨骼多模态交互系统研究[J]. *机械工程学报*, 2023, 59(5):29-40.
(Qi Wen-qian, Sun Shou-qian, Chen Chao, et al. Research on multimodal interaction system of lower limb exoskeleton for athletic training [J]. *Journal of Mechanical Engineering*, 2023, 59(5):29-40.)
- [3] Baltrusch S J, van Dieën J H, Koopman A S, et al. SPEXOR passive spinal exoskeleton decreases metabolic cost during symmetric repetitive lifting[J]. *European Journal of Applied Physiology*, 2020, 120(2):401-412.
- [4] Zhou T C, Xiong C H, Zhang J J, et al. Reducing the metabolic energy of walking and running using an unpowered hip exoskeleton [J]. *Journal of Neuro Engineering and Rehabilitation*, 2021, 18(1):1-15.
- [5] Slade P, Kochenderfer M J, Delp S L, et al. Personalizing exoskeleton assistance while walking in the real world [J]. *Nature*, 2022, 610(7931):277-282.
- [6] Beato M, Impellizzeri F M, Coratella G, et al. Quantification of energy expenditure of recreational football [J]. *Journal of Sports Sciences*, 2016, 34(24):2185-2188.
- [7] Bisi M C, Stagni R, Han H, et al. An EMG-driven model applied for predicting metabolic energy consumption during movement [J]. *Journal of Electromyography & Kinesiology*, 2011, 21(6):1074-1080.
- [8] Tsianos G A, Macfadden L N. Validated predictions of metabolic energy consumption for submaximal effort movement [J]. *Plos Computational Biology*, 2016, 12(6):e1004911.
- [9] Choi J W, Kim H J. Accuracy verification of heart rate and energy consumption tracking devices to develop forest-based customized health care service programs [J]. *Journal of People Plants and Environment*, 2019, 22(2):219-229.
- [10] Wang B C, Li Y, Luo Y, et al. Early event detection in a deep-learning driven quality prediction model for ultrasonic welding [J]. *Journal of Manufacturing Systems*, 2021, 60:325-336.
- [11] 王斐,魏晓童,秦昊.基于 sEMG 和 LSTM 的下肢连续运动估计 [J]. *东北大学学报(自然科学版)*, 2020, 41(3):305-310.
(Wang Fei, Wei Xiao-tong, Qin Hao. Continuous motion estimation of lower limbs based on sEMG and LSTM [J]. *Journal of Northeastern University(Natural Science)*, 2020, 41(3):305-310.)
- [12] 仇逊超,曹军.无源无线传感器平台在人体跑步检测中的应用 [J]. *计算机工程与设计*, 2014, 35(12):4395-4401.
(Qiu Xun-chao, Cao Jun. Application of passive wireless sensor platform in human running detection [J]. *Computer Engineering and Design*, 2014, 35(12):4395-4401.)
- [13] Zong X, Wang F, She J, et al. Denoising method for surface electromyography signals combining CEEMDAN and interval total variation [J]. *Circuits, Systems, and Signal Processing*, 2022, 41(11):6493-6512.
- [14] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8):1735-1780.