

基于虚拟现实技术的康复训练 系统设计与效果评估研究

章 蕾¹, 张 执²

(1. 中国医科大学附属盛京医院, 沈阳 110022;

2. 沈阳工学院 机械工程与自动化学院, 沈阳 113122)

摘要: 虚拟现实技术被越来越多地应用到康复训练中, 但其实际的康复训练效果仍然不够理想; 为此, 研究结合脑电信号和虚拟现实技术设计了康复训练系统; 首先, 利用非侵入式电机采集运动想象脑电信号, 并进行预处理; 其次, 利用粒子群优化算法改进支持向量机, 进而对采集到的运动想象脑电信号进行分析; 然后, 以识别分类后的运动想象脑电信号为输入, 设计一种基于虚拟现实技术的康复训练系统; 最后, 提出一种基于改进长短期记忆网络的康复训练效果评估模型, 以验证系统的应用效果; 实验结果表明, 在对两名受试者的运动想象训练实验中, 所提改进支持向量机分类器对于受试者的分类准确率最高, 为 95.54%; 所提康复训练效果评估模型对于 15 名患者的评估准确率均在 93% 以上, 最高可达到 96.02%, 对上肢功能障碍的评估精确率为 95.87%; 实验结果证实了所提系统和效果评估模型的性能, 有利于提高康复训练过程的智能化水平, 改善患者的康复训练效果。

关键词: 虚拟现实; 康复训练; 脑电信号; 效果评估; 循环神经网络

Research on the Design and Effect Evaluation of Rehabilitation Training System Based on Virtual Reality Technology

ZHANG Lei¹, ZHANG Zhi²

(1. Shengjing Hospital of China Medical University, Shenyang 110022, China;

2. School of Mechanical Engineering and Automation, Shenyang Institute of Technology, Shenyang 113122, China)

Abstract: Virtual reality technology is increasingly being applied in rehabilitation training, but its actual rehabilitation training effect is still not ideal. To this end, a rehabilitation training system was designed by combining EEG signals and virtual reality technology. Firstly, non-invasive motors are used to collect motor imagery EEG signals and preprocess them. Secondly, using particle swarm optimization algorithm to improve support vector machine, and then analyzing the collected motor imagery EEG signals. Then, using the identified and classified motor imagery EEG signals as input, a rehabilitation training system based on virtual reality technology is designed. Finally, a rehabilitation training effectiveness evaluation model based on an improved long short-term memory network is proposed to verify the application effectiveness of the system. The experimental results showed that in the exercise imagination training experiment on two subjects, the proposed improved support vector machine classifier achieved the highest classification accuracy of 95.54% for the subjects. The proposed rehabilitation training effect evaluation model has an accuracy rate of over 93% for 15 patients, with the highest reaching 96.02%. The accuracy rate for evaluating upper limb dysfunction is 95.87%. The experimental results confirmed the performance of the proposed system and effect evaluation model, which is beneficial for improving the intelligence level of rehabilitation training process and enhancing the rehabilitation training effect of patients.

Keywords: virtual reality; rehabilitation training; EEG signals; effect evaluation; recurrent neural network

收稿日期: 2024-07-03; 修回日期: 2024-11-06。

基金项目: 辽宁省科技计划联合计划(应用基础研究项目)(2023JH2/101700068)。

作者简介: 章 蕾(1988-), 女, 大学本科, 护师。

张 执(1981-), 男, 硕士, 副教授。

引用格式: 章 蕾, 张 执. 基于虚拟现实技术的康复训练系统设计与效果评估研究[J]. 计算机测量与控制, 2025, 33(2): 317-324.

0 引言

随着经济的发展和人工智能技术在医疗领域的应用,患者的康复训练也逐渐向着智能化的方向转变。近年来,因脑卒中、脊髓损伤或神经性肌肉萎缩等疾病导致出现肢体运动功能障碍的患者数量在不断地增长,不仅对患者的日常生活和工作带来严重的影响,还增加了患者的心理负担。因此,如何帮助其制定科学可行的康复训练方案具有重要意义。康复训练是指当患者的运动功能受到损伤后,在专业人员的指导下进行的有利于恢复或改善功能的身体活动。康复训练的可行性来源于神经系统的可塑性,即神经系统能够根据外界环境的改变自适应调整神经回路和突触结构,适当的康复治疗对神经和运动功能的恢复是有效的^[1]。许多学者对康复训练进行了大量的研究。尹相国等人^[2]针对上肢康复训练中单一传感器难以准确跟踪的问题,提出了一种误差修正算法来解决累积误差。结果表明,所提算法能够有效跟踪骨骼运动轨迹。胡玉舸等人^[3]针对康复训练中的运动意图识别条件复杂的问题,提出了一种基于 Kinect 的上肢主动康复训练运动意图识别方法。结果表明,所提方法能够有效预测人体上肢运动意图,有助于制定个性化的运动康复训练方案。郑奇等人^[4]针对老年人的平衡、活动能力和肌肉力量等功能受损的问题,提出一种基于计算机视觉和支持向量机的康复训练评估算法,有助于解决体型差异和动作滞后的问题,实验结果证明了所提算法的评估性能。吴达等人^[5]针对下肢的被动康复训练过程监测问题,提出利用机器学习来分析表面肌电和运动姿态信号,能够实现康复训练过程的自动识别以及训练效果量化分析判断。

尽管目前有关康复训练的研究十分广泛,但仍存在一定的缺陷,例如康复设施老旧导致康复训练的效果受到影响,康复训练的个性化程度还不够高等,亟待提高康复训练的智能化水平和针对性,以提升患者的康复效果和生活质量^[6]。为此,研究设计了一种基于虚拟现实(VR, virtual reality)技术的康复训练系统,并提出了基于长短期记忆网络(LSTM, long short-term memory)的康复训练效果评估模型。研究旨在设计出有效的康复训练系统和康复效果评估模型,进而提高患者的康复训练效果。研究的创新点在于结合惯性测量单元和自注意力机制改进的 LSTM,搭建了基于 LSTM 的康复训练效果评估模型。

1 基于 VR 技术的康复训练系统及效果评估

1.1 基于脑电信号和 VR 的康复训练系统设计

1.1.1 脑电信号采集与预处理

运动想象(MI, motor imagery)疗法是一种为了

提高运动功能而进行的反复运动想象,使大脑神经元活动产生脑电信号,进而调动患者各机体感官模仿实际运动功能锻炼的方法^[7-8]。脑-计算机接口(BCI, brain-computer interface)是基于脑电信号形成的一种能够使大脑与外部设备进行信息交流的接口,其中基于 MI 的 BCI 仅仅通过运动想象便可产生相应的脑电信号^[9-10]。研究采用非侵入式电极 Neuracle-64 来采集脑电信号,由于采集到的脑电信号会受到眼电、心电和肌电等因素的干扰,因此需对信号进行滤波、去伪迹、分段和基线校正处理。为提取脑电信号特征,研究选择均方误差(MSE, mean square error)作为运动想象脑电信号的时域特征, $MSE_{\sigma j}$ 的计算如公式(1)所示:

$$\sigma j = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{ij}(t) - \bar{x}_j)^2} \quad (1)$$

式中, j 为通道数, N 为数据个数, $\bar{x}_j$ 为数据序列的平均值。共空间模式(CSP, common spatial pattern)是一种用于 BCI 中的空域滤波特征提取算法,旨在找到最优空间投影以最大化两类信号的功率差异,用于处理脑电信号或其他生物电信号的分类问题^[11]。CSP 算法通过 Karhunen-Loeve (K-L) 变换实现分类,通过矩阵对角化找到一组最优空间滤波器,使得脑电信号在经过这些滤波器处理后能够提取出具有较高区分度的特征向量。首先计算通过第 b 个滤波器的两类 MI 脑电信号中每个 trial 的协方差矩阵,如公式(2)所示:

$$C_b = \frac{E_b E_b^T}{\text{trace}(E_b E_b^T)} \quad (2)$$

式中, E_b 为第 b 个滤波器得到的 MI 脑电信号, T 为转置运算符, $\text{trace}(\cdot)$ 为矩阵的迹。通过平均协方差得到所有 trial 的混合空间协方差矩阵 $\mathbf{R}$ 并进行特征值分解,得到公式(3):

$$\mathbf{R} = \mathbf{U}_{\text{lc}} \mathbf{D}_{\text{lc}} \mathbf{U}_{\text{lc}}^T \quad (3)$$

式中, $\mathbf{U}_{\text{lc}}$ 为特征向量矩阵, $\mathbf{D}_{\text{lc}}$ 为特征值对角矩阵。构造白化协方差矩阵 $\mathbf{P}$ 和空间系数矩阵 $\mathbf{S}$, 如公式(4)所示:

$$\begin{cases} \mathbf{P} = \mathbf{D}_{\text{lc}}^{-1/2} \mathbf{U}_{\text{lc}}^T \\ \mathbf{S}_l = \mathbf{P} \mathbf{C}_l \mathbf{P}^T \\ \mathbf{S}_r = \mathbf{P} \mathbf{C}_r \mathbf{P}^T \end{cases} \quad (4)$$

式中, $\mathbf{C}_l$ 为左运动想象的平均协方差, $\mathbf{C}_r$ 为右运动想象的平均协方差, 利用 $\mathbf{S}$ 具有的相同特征向量构成矩阵 $\mathbf{B}$ 对其进行分解, 如公式(5)所示:

$$\begin{cases} \mathbf{S}_l = \mathbf{B} \mathbf{D}_l \mathbf{B}^T \\ \mathbf{S}_r = \mathbf{B} \mathbf{D}_r \mathbf{B}^T \end{cases} \quad (5)$$

随后计算投影矩阵 $\mathbf{W}$, 进而得到经空间滤波后的脑电信号 $\mathbf{Z}$, 如公式(6)所示:

$$\begin{cases} \mathbf{W} = (\mathbf{B}^T \mathbf{P})^T \\ Z = \mathbf{W}^T \mathbf{E}_b \end{cases} \quad (6)$$

提取 Z 前后各 m 行来计算特征向量 f_p , 如公式 (7) 所示:

$$f_p = \log \left[\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right], p = 1:2m \quad (7)$$

式中, $\text{var}(\cdot)$ 为矩阵的方差。

1.1.2 基于改进支持向量机的运动想象分类

在提取到脑电信号特征后, 研究采用支持向量机 (SVM, support vector machine) 来进行分类, 即将脑电信号特征分为运动想象或休息两类。SVM 是一种用于分类任务的监督学习模型, 基本原理是寻找一个最优超平面来分割不同类别的样本, 使得不同标签的样本点离超平面的间隔最大^[12-13]。SVM 通过使用核技巧, 可以处理非线性分类问题, 通过将数据映射到高维空间, 使得数据在该空间中变得线性可分。假设进行分类的数据集为 $(x_i, y_i), i = 1, 2, \dots, N$, 线性判别函数为 $g(c) = wx + b$, 则最优超平面距离两类样本的间距如公式 (8) 所示:

$$d = \frac{(x_1 - x_2)w}{\|w\|} = \frac{2}{\|w\|} \quad (8)$$

式中, $\|w\|$ 越小则两类超平面的间隔越大。拉格朗日乘子的主要思想是引入一个新的参数来联立约束条件函数与原函数, 从而求出得到原函数极值的各个变量的解^[14-15]。拉格朗日乘子的引入可以将有约束的优化问题转化为无约束问题, 主要用于求解在约束条件下的多元函数极值问题。使用拉格朗日乘子计算最优分类函数, 如公式 (9) 所示:

$$f(x) = \text{sgn} \left(\sum_{i=1}^k a_i y_i (x_i x) + \delta \right) \quad (9)$$

式中, a_i 为拉格朗日乘子, δ 为分类阈值。当样本数据为线性不可分时, 引入松弛因子 δ , 如公式 (10) 所示:

$$y_i(x_i w + b) + \zeta - 1 \geq 1, i = 1, 2, \dots, N \quad (10)$$

目标函数如公式 (11) 所示:

$$\min_{\varphi}(\omega, b, \zeta) = \frac{\|w\|^2}{2} + \partial \sum_{i=1}^k \zeta \quad (11)$$

式中, ∂ 为惩罚因子。判别函数如公式 (12) 所示:

$$f'(x) = \text{sgn} \left(\sum_{i=1}^k a_i^* y_i (x_i x) + \delta^* \right) \quad (12)$$

由于样本是非线性样本, 因此将公式 (12) 转化为求二次规划最优解, 则 SVM 的分类函数如公式 (13) 所示:

$$f''(x) = \text{sgn} \left(\sum_{i=1}^k a_i^* y_i K(x_i, x_j) + \delta^* \right) \quad (13)$$

式中, $K(x_i, x_j)$ 为核函数, 研究采用的是径向基核函数。针对 SVM 分类过程中的参数优化问题, 研究采用

粒子群优化算法 (PSO, particle swarm optimization) 来进行搜索最优参数, 以提升 SVM 的分类准确性。PSO 算法是一种智能优化算法, 通过模拟动物寻找食物的行为初始化一群粒子, 再对其进行迭代, 具有收敛速度快且易实现的优点^[16]。PSO 算法的基本思想是通过群体中个体之间的协作和信息共享来寻找最优解, 优势在于简单容易实现并且没有许多参数的调节。在迭代过程中通过跟踪个体最优值和全体最优值, 速度迭代公式和位置迭代如公式 (14) 所示:

$$\begin{cases} v_i(t+1) = \omega v_i(t) + c_1 \text{rand}(P_{\text{best}_i} - x_i(t)) + \\ \quad c_2 \text{rand}(G_{\text{best}} - x_i(t)) \\ x_i(t+1) = x_i(t) + v_i(t+1) \end{cases} \quad (14)$$

式中, v_i 为粒子速度, rand 为随机因子, P_{best_i} 为第 i 个粒子过去经历的最佳值, x_i 为粒子当前位置, G_{best} 为群体经历过的最佳值, c_1 和 c_2 为加速因子。但 PSO 算法也存在着易陷入局部最优的问题, 为此, 研究采用动态惯性权重来平衡粒子群算法中的全局搜索能力和局部搜索能力, 如公式 (15) 所示:

$$\omega_{n+1} = \omega_n + r \frac{f_n - f_{n-1}}{|f_n - f_{n-1}|} \quad (15)$$

式中, ω_n 和 ω_{n+1} 分别为当前的惯性因子和下次迭代时的惯性因子, r 为增益系数, f_n 和 f_{n-1} 分别为当前和上次迭代时的最优适应度值。研究在对 MI 脑电信号进行预处理和特征提取之后, 基于 PSO-SVM 算法实现了对患者运动想象意图的识别和分类, 能够为基于 VR 技术的康复训练系统提供了输入数据。

1.1.3 基于 VR 技术的康复训练系统设计

VR 技术是一种计算机仿真系统, 可利用计算机生成一种模拟环境, 在这个虚拟世界中, 用户可以通过特殊的设备和技术, 获得关于视觉、听觉甚至触觉等多种感官的体验, 从而产生身临其境的感觉^[17-18]。基于 MI 的 BCI 在康复领域得到了广泛的应用, 而 VR 系统可以帮助患者体验沉浸式的康复训练, 从而达到大脑运动功能区的神经重塑。因此, 将 VR 技术引入到基于 MI 的 BCI 康复训练系统能够调动患者的积极性和主动性。虚拟现实—运动想象—脑—计算机接口 (VR-MI-BCI, virtual reality-motor imagery-brain-computer interface) 技术的康复原理是使用无线脑电帽采集患者进行 MI 时产生的脑电信号, 并利用 BCI 处理采集到的信息, 识别患者的运动意图并控制外部设备做出响应。基于 VR-MI-BCI 技术的康复训练系统的基本结构如图 1 所示。

图 1 中, 脑电信号采集和预处理模块根据研究在 1.1.1 节中提出的方法进行。SVM 意图识别模块用于对运动想象意图进行分类, 由研究在 1.1.2 节中提出的




图 1 基于 VR-MI-BCI 技术的康复训练系统结构

PSO-SVM 算法进行。VR 游戏模块通过特定接口与 MI-BCI 连接,接受由脑电信号转化的控制命令,为患者提供了可以进行重复训练的沉浸式趣味虚拟场景,并向患者提供反馈刺激,以在重塑神经功能的同时,提高患者的训练积极性。研究利用 VR 技术模拟生活场景来设计 VR 游戏,帮助患者进行康复训练。为实现 VR 游戏的人机交互控制功能,搭建一个完整的虚拟场景至关重要。研究采用 3D Studio Max 软件来制作康复训练界面中各种物体和人物的三维模型,并导入到 Unity 3D 中进行参数调整,进一步提高三维模型的真实性和美观性,改善患者的使用体验。3D Max 是用于创建三维模型、动画和数字图像的电脑图形软件,通常用于角色建模和动画,以及渲染建筑和其他的一些真实的图像,具有优越的建模速度且操作简单。Unity3D 是由 Unity Technologies 开发的一个让玩家轻松创建诸如三维视频游戏、建筑可视化、实时三维动画等类型互动内容的多平台的综合型游戏开发工具,是一个全面整合的专业游戏引擎。最后,给场景中的物体添加控制脚本,当患者进行 MI 训练时,搭建好的物体和人物的三维模型会根据 BCI 接收到的控制指令做出相应变化。

研究使用 HTC VIVE 作为 VR 硬件设备,使用采样率为 1 000 Hz 的 Neuracle-64EEG 信号采集设备来采集脑电信号,并选择戴尔塔式服务器作为系统的计算机设备。TCP/IP 协议的核心是传输控制协议(TCP, transmission control protocol)和因特网协议(IP, internet protocol),TCP 负责确保数据的可靠传输,而 IP 则处理数据包的寻址和路由^[19]。TCP/IP 协议定义了电子设备如何连入因特网,以及数据如何在它们之间传输的标准,使得不同计算机系统之间的通信成为可能,是互联网通信的基础。为确保数据处理模块和 VR 游戏模块之间进行数据交互的稳定性和安全性,研究选取 TCP/IP 协议构建数据通信,并在每次传输命令后断开连接。使用 Python 语言构建数据处理模块,使用 C# 语言构建 VR 游戏,主要包括主菜单、用户登录、任务

与强度设置、虚拟训练界面、信息查询、康复状态评估以及数据管理模块。训练任务界面包含训练场景和训练任务,还包含暂停和结束训练等功能。康复状态评估界面主要通过记录患者训练前后的康复评估报表结果来进行简单的评估。研究基于 MySQL 数据库来设计数据管理模块,能够储存患者的康复训练数据,展示康复训练效果。

1.2 基于 LSTM 的康复训练效果评估模型搭建

在设计了基于 VR-BCI 技术的康复训练系统后,为进一步改善康复训练效果,需密切关注患者在训练过程中的身体变化情况,以及时调整训练方案。康复训练效果评估是指在康复训练过程中,对患者的身体功能、日常活动能力及生活质量进行评估,了解患者在康复训练前后的变化情况,有助于及时调整治疗方案,最大程度地提升康复训练效果。传统的康复训练效果评估通常采用评估量表来对患者的康复效果进行打分,存在着主观性较强的问题。为此,研究结合传感器技术和深度学习来实现对患者康复训练效果的客观化评估。惯性测量单元是一种结合加速度计和陀螺仪有时还有磁力计,来测量和报告物体的特定力、角速度和物体周围磁场的电子设备^[20]。研究采用惯性测量单元来对患者进行运动数据采集,并对数据进行预处理。为避免测量偏差带来的影响,研究采用过滤了重力加速度的三轴自由加速度 $f_a = (f_{ax}, f_{ay}, f_{az})$ 和角速度 $V_a = (V_{ax}, V_{ay}, V_{az})$ 作为特征,并采用样条插值法来对数据的长度进行统一化处理。假设预处理后得到时间序列数据 $X_T = (x_1, x_2, \dots, x_i), t \in [1, T]$, 则时间点 t 的输入 x_i 如公式(16)所示:

$$\begin{cases} x_i = (data_1, data_2, \dots, data_n)_i, t \in [1, T], n \in [1, N] \\ data_n = (f_{axn}, f_{ayn}, f_{azn}, V_{axn}, V_{ayn}, V_{azn})_n, n \in [1, N] \end{cases} \quad (16)$$

式中, N 为惯性测量单元的数量, T 为时间点的数量, n 为惯性测量单元的编号。循环神经网络(RNN, recurrent neural network)是一类以序列数据为输入,在序列的演进方向进行递归且所有节点按链式连接的递归神经网络^[21]。RNN 凭借其记忆性、参数共享并且图灵完备等特点,在对序列的非线性特征进行学习时展示出了优越的性能。LSTM 是 RNN 的一种变体,能够通过门控机制解决 RNN 在处理长序列时面临的梯度消失问题,为此研究采用 LSTM 来进行康复训练效果评估^[22]。所提基于 LSTM 的康复训练效果评估模型的框架如图 2 所示。

图 2 中,基于 LSTM 的康复训练效果评估模型的输入为采集的患者运动时间序列数据,输出为患者的康复效果评估结果,各步骤的具体方法将在后文进行详细描述。考虑到输入数据具有较强的时间性,为向细胞状




图2 基于LSTM的康复训练效果评估模型的框架图

态提供更多的信息, 研究设计了一个提取数据变化层, 如公式 (17) 所示:

$$x'_t = \frac{x_t - x_{t-1}}{\Delta t} \quad (17)$$

式中, x'_t 为通过时间点 t 和 $t-1$ 的直线斜率, x_t 为时间点 t 上采集的数据, Δt 为数据采集的时间间隔。LSTM 包含 3 个门控机制, 分别是输入门、遗忘门和输出门^[23]。其中, 遗忘门负责对信息进行记忆或丢弃, 遗忘门的状态如公式 (18) 所示:

$$f_t = \sigma(\mathbf{W}_f h_{t-1} - 1 + \mathbf{V}_f x_t + b_f) \quad (18)$$

式中, σ 为 sigmoid 激活函数, $\mathbf{W}$ 为神经网络层的权重矩阵, h_{t-1} 为上一时刻的输入, $\mathbf{V}$ 为 h_{t-1} 的权重矩阵, x_t 为当前时刻的输入值, b 为偏置项。更新门用于控制输入信息是否更新到 cell 单元中, 如公式 (19) 所示:

$$\begin{cases} i_t = \sigma(\mathbf{W}_i h_{t-1} - 1 + \mathbf{V}_i x_t + b_i) \\ \tilde{c}_t = \tanh(\mathbf{W}_c h_{t-1} - 1 + \mathbf{V}_c x_t + b_c) \\ c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \end{cases} \quad (19)$$

式中, i_t 为输入门的状态, $\tanh$ 为激活函数, $\tilde{c}_t$ 为候选 cell 单元, c_t 为记忆单元 cell 节点的最新状态。输出门用于实现记忆单元状态值的控制输出, 如公式 (20) 所示:

$$\begin{cases} o_t = \sigma(\mathbf{W}_o h_{t-1} - 1 + \mathbf{V}_o x_t + b_o) \\ h_t = o_t * \tanh(c_t) \end{cases} \quad (20)$$

式中, o_t 为输出门的状态, h_t 为当前时刻的输出。虽然 LSTM 的出现在一定程度上解决了 RNN 有关梯度的问题, 但是在面对较长序列的数据时, 还是会存在一定的局限性。为解决这一问题, 研究利用自注意力机制来进行数据处理。自注意力机制是一种将单个序列的不同位置关联起来以计算同一序列的表示的注意机制, 允许模型在处理序列数据时更好地理解上下文信息, 能够有效地捕捉序列中远距离的依赖关系, 并且可以应用于不同类型的序列数据, 容易扩展到更长的序列^[24]。自注意力机制的主要优点包括并行计算、捕捉长距离依赖以及灵活性, 不像 RNN 那样需要顺序处理序列中的元素, 而是允许并行处理序列中的所有元素, 提高了计算效

率。假设有输入序列, 自注意力首先会根据每个节点的输入生成 $Q = \mathbf{W}_q X$, $K = \mathbf{W}_k X$ 和 $V = \mathbf{W}_v X$ 这 3 个向量。其中, Q 为 query, K 为 key, V 为 value, $\mathbf{W}$ 为权重矩阵。第 l 个节点的自注意力得分如公式 (21) 所示:

$$x'_l = \text{soft max} \left(\frac{Q_l \cdot K_l}{\sqrt{d}} \right) \quad (21)$$

式中, d 为向量 $\mathbf{K}$ 的维度。节点的自注意力得分越高则该节点的输入数据与其他节点的输入数据的关联程度越强。自注意力层的输出 A 如公式 (22) 所示:

$$A = \sum \text{soft max} \left(\frac{Q \times K^T}{\sqrt{d}} \right) V \quad (22)$$

式中, $\mathbf{K}^T$ 为 $\mathbf{K}$ 的转置。为便于分类, 研究将自注意力输出的抽象特征输入到全连接层中进行整合。全连接层中的每一个结点都与上一层的所有结点相连, 且每个连接都有各自的权重, 主要作用是学习输入特征之间的各种可能的内在关系。全连接层的输出如公式 (23) 所示:

$$F = \mathbf{W}_F \times A + b_F \quad (23)$$

式中, $\mathbf{W}_F$ 为全连接层的权值, b_F 为全连接层的偏置。Softmax 是机器学习和深度学习中一种常用的函数, 尤其在处理多分类问题时, 可以将一个实数向量标准化为一个概率分布, 通常用作分类问题的输出层, 以将神经网络的输出转换为概率分布, 从而表示模型预测各个类别的概率。为获取时间序列数据对应不同类别的概率值, 研究将全连接层的输出输入到 Softmax 层中, 预测结果如公式 (24) 所示:

$$y^* = \text{softmax}(\mathbf{W}_y \times F + b_y) \quad (24)$$

式中, $\mathbf{W}_y$ 为 Softmax 层的权值, b_y 为 Softmax 层的偏置。损失函数通常作为学习准则与优化问题相联系, 即通过最小化损失函数求解和评估模型。常见的损失函数有均方误差损失函数、交叉熵损失函数、对数损失函数以及多分类交叉熵损失函数等^[25]。其中交叉熵损失函数主要用于衡量模型输出与真实标签之间的差异, 能够主要用于衡量模型输出与真实标签之间的差异, 从而提升模型的性能, 在机器学习中的应用非常广泛。研究采用计算简单、善于处理多类别问题的交叉熵损失函数来衡量预测值与真实值 y 间的误差, 如公式 (25) 所示:

$$J = - \sum y \log y^* \quad (25)$$

在 LSTM 模型的训练阶段, 首先, 将患者的运动时间序列数据分批输入模型中对模型进行训练, 进行前向传播输出评估结果。然后, 将结果与真实情况进行对比, 计算误差。最后, 通过反向传播对模型的权重进行更新。具体而言, 基于 LSTM 的康复训练效果评估模型在开始训练时通过前向传播获取预测值, 然后通过反

向传播获取每个神经元的误差项,利用优化算法更新变量,研究采用 Adam 算法来计算权重梯度。Adam 算法是一种可以替代传统随机梯度下降过程的一阶优化算法,能够基于训练数据迭代地更新神经网络权重,具体计算如公式 (26) 所示:

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{cases} \quad (26)$$

式中, m_t 为当前梯度的一阶动量, β_1 为一阶矩阵指数衰减率, g_t 为当前的梯度值, v_t 为当前梯度的二阶动量, β_2 为二阶矩阵指数衰减率。由于 m_t 和 v_t 在初始时均为零向量,因此需要进行偏差校正,如公式 (27) 所示:

$$\begin{cases} \hat{m}_t = \frac{m_t}{1 - \beta_1} \\ \hat{v}_t = \frac{v_t}{1 - \beta_2} \end{cases} \quad (27)$$

式中, $\hat{m}_t$ 为梯度带权平均, $\hat{v}_t$ 为梯度带权有偏方差。优化后的参数 θ_t 如公式 (28) 所示:

$$\theta_t = \theta_0 - \frac{\alpha}{10^{-8} + \sqrt{\hat{v}_t}} \hat{m}_t \quad (28)$$

式中, θ_0 为初始参数, α 为学习率。在获得权重梯度后对权重进行更新,以获取最优效果的参数矩阵完成对 LSTM 模型的训练及应用。

2 康复训练系统及效果评估模型的性能分析

2.1 康复训练系统的测试结果分析

为验证所提 PSO-SVM 分类器的分类性能,研究将 CSP 算法中的 m 设置为 11,将种群规模设置为 50,将粒子群维数设置为 30,将惯性权重设置为 $[0.4, 0.9]$,将迭代次数设置为 200,将 $Epoch$ 设置为 30,将学习因子设置为 1.5,将惩罚参数设置为 1.0。邀请两名身体健康,没有神经系统病史和认知障碍的受试者进行 MI 训练实验。并与线性判别分类器 (LDA, linear discriminant analysis)、Tree、SVM 和 KNN 四种分类器的分类准确率进行对比,结果如图 3 所示。从图 3 (a) 中可以看出,相较于另外 4 种分类器,所提 PSO-SVM 分类器对于受试者 1 的分类准确率最高,为 95.54%,其次是 SVM 分类器,准确率为 91.46%,Tree 分类器的分类效果最差。从图 3 (b) 中可以看出,在对受试者 2 的 MI 训练实验中,所提 PSO-SVM 分类器的分类准确率仍然最高,为 96.88%,比 Tree 分类器高 22.71%。结果表明,研究所提 PSO-SVM 分类器具有较好的分类性能,能够对传统的 SVM 分类器进行有效的改进,分类准确率较高,具有一定的可行性和有效性。

为验证基于 VR-MI-BCI 技术的康复训练系统的性能,研究邀请 5 位受试者对系统进行测试。所提康复训




图 3 5 种分类器的分类准确率对比

练系统的各项功能测试结果如图 4 所示。从图 4 中可以看出,经过测试,用户能够通过用户名和密码顺利登录系统并进行信息查询、康复训练任务选择、任务强度设置、康复训练以及康复状态评估结果获取等操作。训练任务界面的功能正常,用户能够进行康复训练并随时停止和退出康复训练任务。结果表明,所提康复训练系统的各项功能均完好,能够顺利通过测试。

2.2 康复训练效果评估模型的有效性分析

为验证所提基于 LSTM 的康复训练效果评估模型的性能,研究采用准确率为评价指标,将注意力层输出和隐藏层的维度设置为 128,将学习率设置为 0.001。并邀请在医院康复医学中心进行康复训练的 15 名运动功能障碍患者进行实验。要求患者佩戴 Xsens DOT 惯性测量单元进行肘关节伸展,获取患者的运动数据,利用康复训练效果评估模型对患者的康复效果进行评估。并传统 LSTM 和结合自注意力机制的 LSTM 进行对比,3 种模型的评估准确率对比结果如图 5 所示。从图 5 中可以看出,所提基于 LSTM 的康复训练效果评估模型具有较好的评估效果,对于 15 名患者的评估准确率均在 93% 以上,最高可达到 96.02%。其次是结合自注意力机制的 LSTM,传统 LSTM 的评估性能最差。结果表明,基于 LSTM 的康复训练效果评估模型具有较好的性能,评估的准确率较高,且所提策略能够有效对 LSTM 进行改进,具有一定的可行性。

为进一步验证所提康复训练效果评估模型的应用效




图 4 康复训练系统的功能测试结果






图 5 3 模型的评估性能对比

果, 研究分别对上述 15 名患者的上肢功能障碍和下肢功能障碍进行评估, 使患者佩戴 Xsens DOT 惯性测量单元进行肘关节伸展和膝关节伸展, 为避免误差, 让患者在测试前放松静坐 30 s。并与基于关联规则的数据挖掘模型、LSTM 和自适应神经模糊模型进行对比, 4 种模型的平均评估精确度结果如图 6 所示。从图 6 (a) 中可以看出, 所提基于 LSTM 的康复训练效果评估模型对上肢功能障碍的评估精确率为 95.87%, 高于另外 3 种模型。其次是自适应神经模糊模型, 为 83.47%, LSTM 的评估精确率最低, 为 72.55。从图 6 (b) 中可以看出, 研究所提康复训练效果评估模型在下肢功能障碍评估中的表现仍然较好, 评估精确率为 96.74%, 比自适应神经模糊模型高 10.35%, 比基于关联规则的数据挖掘模型高 16.26%, 比 LSTM 高 23.46%。结果表明, 所提康复训练效果评估模型具有较好的应用效果, 在对患者的上肢功能障碍和下肢功能障碍评估中均表现

出了较高的精确率, 具有一定的可行性和优越性。



(a) 上肢评估结果



(b) 下肢评估结果

图 6 4 种模型的平均评估精确度

3 结束语

随着经济和科技的快速发展, 医学领域也面临着智能化发展的需要。针对康复训练过程枯燥且康复方案制定较为复杂的问题, 研究设计了一种基于 VR 技术的康复训练系统, 并提出了 LSTM 的康复训练效果评估模型。结果表明, 所提 PSO-SVM 分类器对于受试者的分类准确率最高, 为 95.54%, 其次是 SVM 分类器, 准确率为 91.46%。所提康复训练系统的各项功能均完好, 能够顺利通过测试。用户能够通过用户名和密码顺利登录系统并进行信息查询、康复训练任务选择、任务强度设置、康复训练以及康复状态评估结果获取等操作。所提基于 LSTM 的康复训练效果评估模型对于 15 名患者的评估准确率均在 93% 以上, 对上肢功能障碍的评估精确率为 95.87%, 高于另外 3 种模型。研究所提康复训练效果评估模型在下肢功能障碍评估中的表现仍然较好, 评估精确率为 96.74%, 比自适应神经模糊模型高 10.35%, 比基于关联规则的数据挖掘模型高 16.26%, 比 LSTM 高 23.46%。综上所述, 研究设计的系统和模型具有较好的应用效果。但研究仅对上肢肘关节和下肢膝关节进行了测试, 实际中的康复训练还需要对更多动作进行测试。因此, 在未来的研究中, 应进

一步分析所提模型对更多动作的评估效果,以搭建出更加高效准确的康复效果评估模型,进而提高康复训练过程的智能化水平,改善患者的康复训练效果。

参考文献:

- [1] OLBORT C, PFANNE F, SCHWAHN C, et al. Training of the lateral pterygoid muscle in the treatment of temporomandibular joint disc displacement with reduction: a randomised clinical trial [J]. *Journal of Oral Rehabilitation*, 2023, 50 (10): 921–930.
- [2] 尹相国, 张岱岩, 林明星, 等. 基于多模感知的上肢康复训练轨迹跟踪研究 [J]. *仪器仪表学报*, 2023, 44 (2): 154–163.
- [3] 胡玉舸, 陶庆, 孟庆丰, 等. 基于 Kinect 的上肢主动康复训练运动意图识别 [J]. *机械设计与制造*, 2023, 385 (3): 35–42.
- [4] 郑奇, 郭立泉, 陈静, 等. 基于计算机视觉的居家康复训练评估算法 [J]. *小型微型计算机系统*, 2022, 43 (11): 2336–2341.
- [5] 吴达, 马超, 高经纬, 等. 基于机器学习的下肢被动康复训练过程监测评价研究 [J]. *现代电子技术*, 2022, 45 (16): 175–180.
- [6] BENFIELD J K, HEDSTROM A, EVERTON L F, et al. Randomized controlled feasibility trial of swallow strength and skill training with surface electromyographic biofeedback in acute stroke patients with dysphagia [J]. *Journal of Oral Rehabilitation*, 2023, 50 (6): 440–451.
- [7] BIAAS K, KEDZIORA M, CHAUPNIK R, et al. Multifactor authentication system using simplified EEG brain-computer interface [J]. *IEEE Transactions on Human-Machine Systems*, 2022, 52 (5): 867–876.
- [8] KUMARI R, GIBSON H, JARHEES M, et al. The predictive value of cortical activity during motor imagery for subacute spinal cord injury-induced neuropathic pain [J]. *Clinical Neurophysiology*, 2023, 148 (1): 32–43.
- [9] TAKENAKA Y, MATSUMOTO H, SUZUKI T, et al. Corticospinal excitability changes during muscle relaxation and contraction in motor imagery [J]. *The European Journal of Neuroscience*, 2023, 58 (8): 3810–3826.
- [10] SHAH A M. New development in brain-computer interface platforms: 1-year results from the SWITCH trial [J]. *Artificial Organs*, 2023, 47 (4): 615–616.
- [11] BISWAS S, SINHA R. Wavelet filterbank-based EEG rhythm-specific spatial features for covert speech classification [J]. *IET Signal Processing*, 2022, 16 (1): 92–105.
- [12] ALEX R, VINOD V, SHEREEF R M. SVM-based anti-islanding protection for DER near a modern industrial premise [J]. *Electrical Engineering*, 2023, 105 (1): 369–382.
- [13] JIAO J, CHENG J, LIU Y, et al. Inversion of TEM measurement data via a quantum particle swarm optimization algorithm with the elite opposition-based learning strategy [J]. *Computers & Geosciences*, 2023, 174 (5): 1–13.
- [14] HELTAI L, ZUNINO P. Reduced lagrange multiplier approach for non-matching coupling of mixed-dimensional domains [J]. *Mathematical Models and Methods in Applied Sciences*, 2023, 33 (12): 2425–2462.
- [15] ZHENG Z, NI X, HE J. Lagrange multiplier structure-preserving algorithm for time-fractional Allen-Cahn equation [J]. *Computers and Mathematics with Applications*, 2024, 164 (3): 67–78.
- [16] 侯赓舜, 徐永利, 徐志刚, 等. 基于 Kriging 算法与 PSO 算法的桁架机器人横梁模块智能优化设计方法 [J]. *科学技术与工程*, 2023, 23 (18): 7758–7763.
- [17] MUNOZ-GONZALEZ A, KOBAYASHI S, HORIE R. A multiplayer VR live concert with information exchange through feedback modulated by EEG signals [J]. *IEEE Transactions on Human-Machine Systems*, 2022, 52 (2): 248–255.
- [18] SIVAKUMAR K, SAGAR P, THEJASWI P. Virtual reality software aids precise transcatheter closure of sinus venosus defect using covered stent without 3D printing [J]. *Pediatric Cardiology*, 2024, 45 (4): 939–941.
- [19] 冯一飞, 丁楠, 叶钧超, 等. 领域专用低延迟高带宽 TCP/IP 卸载引擎设计与实现 [J]. *计算机工程*, 2022, 48 (9): 162–170.
- [20] 马江华, 林炜轩, 万美琳, 等. MEMS 惯性测量单元航姿更新中的测量误差估算方法 [J]. *电子与信息学报*, 2022, 44 (2): 775–780.
- [21] YANG S B, MOREIRA J, LI Z. Bioinspired encoder-decoder recurrent neural network with attention for hydroprocessing unit modeling [J]. *Industrial & Engineering Chemistry Research*, 2023, 62 (44): 18526–18540.
- [22] 谷妙春. 基于噪声统计的 EMD-LSTM 网络流量预测方法 [J]. *计算机测量与控制*, 2023, 31 (2): 21–27.
- [23] HU C, CHENG F, MA L, et al. State of charge estimation for lithium-ion batteries based on TCN-LSTM neural networks [J]. *Journal of the Electrochemical Society*, 2022, 169 (3): 1–12.
- [24] 郭乾宇, 武一, 刘华宾, 等. 基于损失自注意力机制的立体匹配算法研究 [J]. *计算机应用研究*, 2022, 39 (7): 2236–2240.
- [25] 张强, 杨吉斌, 张雄伟, 等. CS-Softmax: 一种基于余弦相似性的 Softmax 损失函数 [J]. *计算机研究与发展*, 2022, 59 (4): 936–949.