

基于递归神经网络的人体下肢运动意图识别方法

张鑫¹, 李婉婷¹, 陈岩², 孙中波¹(1. 长春工业大学电气与电子工程学院 吉林 长春 130012; 2. 吉林大学第二医院神经外科
吉林 长春 130041)

摘要 采集下肢两通道的表面肌电信号和相应的关节运动信息, 对原始表面肌电信号进行预处理。建立基于径向基函数神经网络的开环估计模型, 以预处理后的表面肌电信号为输入, 关节运动量为输出。在此基础上, 归零神经网络作为一种特殊的递归神经网络被应用到开环模型中, 形成一个混合的闭环预测模型。实验结果表明, 所提出的闭环模型能够有效地消除开环模型的预测误差, 进而能够更加准确地识别出人体的主动运动意图, 为后续康复机器人的人机交互系统提供有价值的参考。

关键词 表面肌电信号; 主动运动; 运动意图; 下肢; 归零神经网络; 径向基函数神经网络

中图分类号 TP183 TP391 **文献标识码** A **文章编号** 2096-7721 (2024) 02-0121-09

A motion intention recognition method of human lower limbs based on recurrent neural network

ZHANG Xin¹, LI Wanting¹, CHEN Yan², SUN Zhongbo¹

(1. Department of Control Engineering, Changchun University of Technology, Changchun 130012, China; 2. Department of Neurosurgery, the Second Hospital of Jilin University, Changchun 130041, China)

Abstract In order to accurately identify the active motion intention of human lower limbs, the surface electromyography (sEMG) signals of the two channels and the corresponding joint motion information were collected, and the raw sEMG signals were preprocessed. Then an open-loop prediction model based on radial basis function neural network was established, using the preprocessed sEMG signal as the input and the joint motion information as the output. On this basis, as a special recurrent neural network, the zeroing neural network was exploited to the open-loop model to form a hybrid closed-loop prediction model. The experimental results indicated that the proposed closed-loop model can effectively eliminate the prediction error of the open-loop model, and it can more accurately identify the active motion intention of human lower limbs, which lays a reliable foundation for the subsequent human-computer interaction system of the rehabilitation robot.

Key words Surface Electromyography (sEMG); Active Motion; Motion Intention; Lower Limbs; Zeroing Neural Network; Radial Basis Function Neural Network

收稿日期: 2022-03-11 录用日期: 2023-04-21

Received Date: 2022-03-11 Accepted Date: 2023-04-21

基金项目: 国家自然科学基金面上项目 (61873304, 62173048); 吉林省教育厅科学研究项目 (JJKH20210745KJ)

Foundation Item: National Natural Science Foundation of China(61873304, 62173048); Scientific Research Project of Department of Education of Jilin Province(JJKH20210745KJ)

通讯作者: 孙中波, Email: zhongbosun2012@163.com

Corresponding Author: SUN Zhongbo, Email: zhongbosun2012@163.com

引用格式: 张鑫, 李婉婷, 陈岩, 等. 基于递归神经网络的人体下肢运动意图识别方法[J]. 机器人外科学杂志(中英文), 2024, 5(2): 121-129.

Citation: ZHANG X, LI W T, CHEN Y, et al. A motion intention recognition method of human lower limbs based on recurrent neural network[J]. Chinese Journal of Robotic Surgery, 2024, 5(2): 121-129.

近年来,脑卒中引起的运动性功能障碍患者不断增加^[1]。脑卒中可造成永久性中枢神经损伤,并且发病率高、复发率高、致残率高,是目前世界范围内成人致残的主要原因之一,给患者家庭和社会带来了沉重的经济和劳动负担。随着机器人技术的蓬勃发展,用于辅助患者进行康复训练的智能假肢和外骨骼机器人成为研究热点^[2-3]。相关医学研究结果提示,长期的人体主动运动激励有助于中枢神经系统的功能性康复,结合人体主动运动意图的康复训练有助于患者恢复。为使人与机器之间能够更好地结合,要求机器人能够具有自主适应能力,进而能够理解人的运动意图。因此,准确、实时、有效地识别人体运动意图,为后续的人机交互系统搭建奠定基础,是实现人机交互的关键所在^[4]。

生物电信号中蕴含丰富的行为信息,其中表面肌电信号(Surface Electromyography, sEMG)采集技术较为成熟且是无创采集,因此被众多研究者选择用来解码运动意图。基于sEMG信号的意图识别研究内容主要分为两方面:一是对肢体离散动作的分类^[5-7];二是对关节连续运动量的估计^[8-10]。相对于动作分类,关节连续运动估计更有助于患者康复,其中连续运动估计的研究包含两种途径:一种是建立关节动力学模型^[11],但模型中存在许多难以被准确测量的生理参数;另一种是直接建立回归模型用以描述sEMG信号与关节运动量之间的非线性关系,但模型的结构以及数据的分布对于模型的预测结果影响较大。

根据以上描述,本研究提出了一种径向基函数神经网络与归零神经网络相结合的闭环预测模型^[12-15],利用闭环模型能够有效地消除由径向基函数神经网络开环模型导致的预测误差。通过实验与分析,验证了该方法的有效性,进而能够精准地识别出人体下肢的主动运动意图,为后续人机交互系统的研究提供价值参考。

1 实验方法

1.1 数据采集 本次实验所采用的数据来自2名健康受试者,通过采集正常人的数据来提供一种有效的意图识别方法,为进一步的康复研究奠定基础。对于中风患者而言,伸腿与踏车两种训练模式对恢复身体机能具有积极作用,所以本次实验要求受试者模拟踏车运动。关节运动是通过协调不同部位肌肉共同完成的,在同一运动模式下,人体表面肌电信号与关节运动量之间存在不同的相关性。因此,经过相关性计算,选取人体下肢的股直肌与股外侧肌来估计髋关节与膝关节的关节角度。

下肢的sEMG信号是利用Biopac系统获取的,该设备是美国生产的一种无线生理数据采集分析系统。Biopac系统的数据采集频率为2000 Hz,并且可以同时测量10个通道的生理信号。由于信号采集过程容易受到外部环境干扰,因此应提前对所选取肌肉的皮肤表面进行清洁处理,随后将电极片粘贴在皮肤表面并记录相应肌肉的sEMG信号。此外,关节的实际角度是使用采样频率为100 Hz的惯性测量单元获得的,将传感器分别绑定在下肢髋关节与膝关节上,利用设备获取受试者1的双通道原始sEMG信号和实际关节运动角度(如图1、图2),受试者2的实验数据如图3、图4所示。由图1和图3可得知,原始sEMG信号易受到噪声干扰,不能直接用作输入信号,需要进行滤波去噪。

1.2 数据处理 原始sEMG信号是一种微弱且不平稳的信号,其内部包含噪声干扰,而且与针电极相比,工频干扰会更加严重。因此,需要对原始sEMG信号进行降噪处理。实验中,对原始sEMG信号采用巴特沃斯数字滤波器,相应的低截止频率和高截止频率分别设置为20 Hz和475 Hz。随后对信号进行全波整流处理,以更加直观地反映信号幅值变化。

由于采集肌电信号设备的采样频率为2000 Hz,角度传感器的采样频率为100 Hz,两者相差20倍,所以还需要利用时间窗的方式对




图1 受试者1原始表面肌电信号

Figure 1 Raw sEMG signal of subject 1




图2 受试者1实际关节角度

Figure 2 Actual joint angles of subject 1




图3 受试者2原始表面肌电信号

Figure 3 Raw sEMG signal of subject 2




图4 受试者2实际关节角度

Figure 4 Actual joint angles of subject 2

信号进行降采样处理，具体过程如下：

$$sEMG_s(n) = \frac{1}{W_l} \sum_{i=nW_l-W_l+1}^{nW_l} |sEMG(i)| \quad (1.1)$$

其中 $W_l=20$ 为时间窗长度， $sEMG_s(n)$ 是第 n 个 sEMG 信号数据段的平均值。经过降采样处理使得两种信号的采样频率保持一致，随后将 sEMG 信号进行归一化处理并将其用作关节运动估计的输入。最终经过一系列预处理后，2 名受试者的双通道 sEMG 信号如图 5、图 6 所示。

1.3 建立动力学模型 根据解剖学，人体由骨骼、骨连接和骨骼肌组成。骨骼通过关节相互连接，从而形成坚硬的人体骨架。肌肉收缩产

生的力使连接的关节产生扭矩，进而拉动骨骼产生关节运动。因此，建立下肢动力学方程对研究人体运动过程中关节运动信息的变化具有重要意义。本研究仅考虑了髋关节和膝关节的运动，建立人体下肢骨骼动力学模型，表示关节扭矩与关节运动量之间的关系。

基于拉格朗日-欧拉公式，下肢的骨骼动力学模型可以表述为：

$$M(\delta)\ddot{\delta} + C(\delta, \dot{\delta})\dot{\delta} + G(\delta) = \tau_l \quad (1.2)$$

其中 M 为惯性矩阵， C 表示向心-科里奥利矩阵， δ 、 $\dot{\delta}$ 和 $\ddot{\delta}$ 分别代表关节的角度、角速度和角加速度， G 是重力矩阵， τ_l 是作用在关节上的扭矩。




图5 受试者1 预处理信号
Figure 5 Preprocessed signal of subject 1




图6 受试者2 预处理信号
Figure 6 Preprocessed signal of subject 2

当作用在关节上的扭矩已知，公式 (1.2) 中的角度和角速度可以重新表述为：

$$\begin{cases} \dot{\delta}_1 = \delta_2 \\ \dot{\delta}_2 = -M^{-1} [C(\delta_1, \dot{\delta}_1) \dot{\delta}_1 + G(\delta_1)] + M^{-1} \tau_l \end{cases} \quad (1.3)$$

其中 δ_1 和 δ_2 表示关节角度和关节角速度。

2 建立预测模型

2.1 径向基函数神经网络 在本次实验中，采用径向基函数神经网络 (Radial Basis Function Neural Network, RBFNN) 建立 sEMG 信号与下肢关节运动量之间的映射关系。利用 RBFNN 模型，预测出髌关节和膝关节的运动量，从而识别出人体的运动意图。然后，估计扭矩可以通过估计出的关节角度、关节角速度并通过公式 1.2 来求解。实验中，假设实验设备采集到的数据如下：

$$\begin{cases} c_i = [c_{i,1}, \dots, c_{i,j}, \dots, c_{i,t}] & i = 1, \dots, k \\ J_m = [J_1, \dots, J_j, \dots, J_t] & t = 3700 \end{cases} \quad (2.1)$$

其中 c_i 表示 37 s 采集的第 i 块肌肉的 sEMG 信号， $J_m = [\delta_1; \delta_2]$ 为 37 s 采集的下肢关节运动量， k 为实验中应用的肌肉通道数。

考虑到 sEMG 信号的振幅具有独特的特性，肌肉收缩会导致幅值的变化。此外，在肌肉收

缩过程中，关节角度和角速度等运动量也会发生变化。因此，关节运动量与 sEMG 信号之间的关系可以通过以下非线性函数得到：

$$J_{est}(i) = g(c_{1,i}, \dots, c_{1,i-m+1}; c_{2,i}, \dots, c_{2,i-m+1}; \dots c_{k,i}, \dots, c_{k,i-m+1};) \quad i = m \dots t \quad (2.2)$$

其中 $J_{est}(i)$ 表示第 i 时刻模型预测出的关节运动量， g 是待定非线性函数， m 代表模型的阶数。

建立 RBFNN 模型是为了估计人体下肢的运动意图，即两个关节的运动量，其拓扑结构如图 7 所示。RBFNN 由输入层、隐含层以及输出层共同构成。




图7 径向基函数神经网络框图
Figure 7 Block diagram of RBFNN

隐含层中第 i 个节点的输出如下：

$$a_i(q) = \exp \left[- \left(\frac{(q - d_i)^T (q - d_i)}{2\sigma_i^2} \right) \right], \quad i = 1, 2, \dots, p \quad (2.3)$$

其中 $a_i(q)$ 代表网络隐含层中的节点输出, σ_i 为高斯函数的半径宽度, p 是网络隐含层中的节点个数, d_i 为隐含节点中高斯函数的中心点。

$q=[q_1, q_2, \dots, q_l]^T$ 代表网络模型的输入矩阵, 基于以上描述, RBFNN 的最终输出如下所示:

$$J_{est} = \sum_{i=1}^p w_i a_i - h_{out} \quad (2.4)$$

其中 J_{est} 代表网络模型待估计的髌关节与膝关节的关节运动量, w_i 是权重矩阵, h_{out} 表示为网络隐藏层中的阈值矩阵。

2.2 归零神经网络 基于 RBFNN 模型的下肢运动意图识别方法是一个开环预测系统。通常, 模型的预测值都会与实际测量值存在误差, 而模型的简化、传感器之间的噪声等会使预测误差增大。由于开环模型没有自主校正能力, 进而会导致估计的下肢运动意图不准确, 无法将预测结果应用于后续的人机交互系统。因此, 可以利用闭环估计方法来有效地消除累积误差。在闭环系统中, 如果检测到预测值与实际测量值存在偏差, 就会产生相应的控制函数来消除误差。

归零神经网络 (Zeroing Neural Network, ZNN) 是一种特殊的递归神经网络, 具有指数收敛性。ZNN 的主要目的是构造一个误差函数, 例如使 RBFNN 模型的预测误差接近于 0。寻零问题定义如下:

$$y(\rho(t), t) = 0 \in \mathbb{R}^n, t \in [0, +\infty) \quad (2.5)$$

其中 $\rho(t)$ 为时变状态变量, y 是时变非线性映射函数并且可微分。对于 $t \in [0, +\infty)$ 处, 都存在寻零问题的解 $\rho^*(t)$ 。因此, 误差函数可构建为:

$$e(t) = y(\rho^*(t), t) - y(\alpha(t), t) = 0 - y(\alpha(t), t) \quad (2.6)$$

此外, 根据公式 (2.5) 和 (2.6), 寻零问题可重新被描述为以下经典的非线性动力系统:

$$\begin{cases} \dot{\rho} = u(t) \\ \varphi(t) = y(\rho(t), t) = -e(t) \end{cases} \quad (2.7)$$

其中 $\rho(t)$ 为系统的时变状态变量, $u(t)$ 和 $e(t)$ 分别为非线性动力系统的输入函数和输出函数。为了确保误差函数趋近于 0, 归零动力学模型公式设计如下:

$$\dot{e}(t) = -\gamma e(t) \quad (2.8)$$

其中 $\gamma > 0$ 代表了模型的收敛速度。通过以上分析, 根据公式 (2.7) 和 (2.8) 可以得到非线性动力系统的输入 $u(t)$, 使得系统的输出函数 $e(t)$ 趋近于 0。非线性动力系统的 ZNN 控制率可表示为:

$$u(t) = -\left(\frac{\partial y(\rho(t), t)}{\partial \rho}\right)^{-1} \left(\gamma \cdot y(\rho(t), t) + \frac{\partial y(\rho(t), t)}{\partial t} \right) \quad (2.9)$$

2.3 RBFNN-ZNN 模型 在神经网络预测模型中引入 ZNN 的闭环控制, 可极大程度上消除误差影响, 从而提高意图识别的准确率。RBFNN-ZNN 闭环系统具有减少干扰、增强模型预测性能等特点。基于公式 (1.2), 通过 RBFNN 估计出的总扭矩 $\tau_{M,i}$ 可以表示如下:

$$\tau_{M,i} = M(\delta_{1,i}) \ddot{\delta}_{1,i} + C(\delta_{1,i}, \delta_{2,i}) \dot{\delta}_{2,i} + G(\delta_{1,i}) \quad (2.10)$$

其中 $\delta_{1,i}$ 、 $\delta_{2,i}$ 和 $\ddot{\delta}_{1,i}$ 分别代表 RBFNN 模型预测的关节角度、角速度和角加速度。根据动力学模型, 上式可重新描述为:

$$\begin{cases} \dot{\delta}_{1,i} = \delta_{2,i} \\ \dot{\delta}_{2,i} = -M^{-1} [C(\delta_{1,i}, \dot{\delta}_{1,i}) \dot{\delta}_{1,i} + G(\delta_{1,i})] + M^{-1} \tau_{M,i} \end{cases} \quad (2.11)$$

利用一阶欧拉差分, 将非线性动力系统 (2.7) 离散化, 并结合公式 (2.11), 得到 RBFNN-ZNN 闭环模型:

$$\begin{cases} \delta_{k+1} = \delta_k + \dot{\delta}_k T_s \\ \dot{\delta}_{k+1} = y(\delta_k, t_k) + u(t_k) \end{cases} \quad (2.12)$$

其中 T_s 为采样时间, $\delta_k = [\delta_{i,k}; \dot{\delta}_{i,k}]$ 表示时变状态变量, 且 $y(\delta_k, t_k)$ 可描述如下:

$$y(\delta_k, t_k) = \begin{bmatrix} \delta_{2,i,k}; -M^{-1} \left[C(\delta_{1,i,k}, \dot{\delta}_{1,i,k}) \dot{\delta}_{1,i,k} + G(\delta_{1,i,k}) \right] + M^{-1} \tau_{i,k} \end{bmatrix} \quad (2.13)$$

结合公式 (2.9) 和离散化技术, 并令 $e(t_k) = \delta_{d,k} - \delta_k$, 其中 $\delta_{d,k} = [\delta_1; \delta_2]$ 代表期望的状态变量, 控制器可描述为:

$$u_{ZNN}(t_k) = \dot{\delta}_{d,k} + \gamma(\delta_{d,k} - \delta_k) \quad (2.14)$$

ZNN 控制器可以被理解为提供了一个控制框架来处理离散时间模型的收敛性和鲁棒性问题, 达到了更加准确地识别出人体运动意图的目的。

3 实验结果

为证明上述方法的可行性, 搭建图 8 所示的实验框图。实验中, 要求 2 名受试者做模拟踏车运动并持续 37 s, 利用 2 名受试者的数据验证该方法的可靠性。根据实验处理部分可知, sEMG 信号系统与角度传感器的采样频率变为同步, 均为 100 Hz。因此, 当受试者完成指定动作时, 分别得到 3700 组关于 sEMG 信号与关节运动量之间的数据, 将收集到的前半数据用作预测网络的训练数据, 其余的一半用作测试数据来观测网络性能。基于所构建的实验框图, 利用 RBFNN 模型进行下肢运动意图识别实验, 并探索 RBFNN-ZNN 模型的优越性。

由图 8 可知, 实验流程分为以下几个步骤: 首先, 利用实验设备测量所需运动数据, 然后对 sEMG 信号进行预处理, 并将其作为输入信号。其次, 根据 RBFNN 开环模型估计出的关节运动量计算出相应扭矩, 接着利用 RBFNN-ZNN 闭环模型来消除开环模型的预测误差。最后, 根据预测扭矩得到关节角度, 并与实际测量值做对比, 识别出人体下肢关节角度。基于以上描述, 图 9 和图 10 分别代表了受试者 1 的髋关节与膝关节的角度预测值, 受试者 2 的角度估计值分别如图 11 和图 12 所示。

由 2 名受试者的关节角度预测值可见, 蓝色曲线代表实际关节角度, 绿色曲线代表 RBFNN 模型的角度预测结果, 红色曲线代表 RBFNN-ZNN 模型的角度预测结果。实验中, 将 RBFNN 开环模型的模型阶数设置为 10。从角度预测结果中可以发现, RBFNN 模型预测出的关节角度与实际角度的轨迹趋势大致相同, 但总体的预测效果并不理想。由于 RBFNN 模型精度受到模型阶数隐藏层神经元个数影响, 这种不确定性会导致开环模型存在预测误差。因此, 在关节运动的临界处会出现抖振现象, 预测曲线明显偏离实际曲线。作为对比实验, RBFNN-ZNN 闭环模型的预测值与实际值更加吻合, 这是由于 ZNN 模型 (2.9) 对于非线性时变问题的求解具有较高的精度和较强的鲁棒性。因此,




图 8 下肢运动意图实验流程框图

Figure 8 Block diagram of lower limb motion intention recognition experiment




图9 受试者1髋关节角度预测

Figure 9 Estimated hip joint angle of subject 1




图10 受试者1膝关节角度预测

Figure 10 Estimated knee joint angle of subject 1




图11 受试者2髋关节角度预测

Figure 11 Estimated hip joint angle of subject 2




图12 受试者2膝关节角度预测

Figure 12 Estimated knee joint angle of subject 2

闭环模型对于关节角度的预测效果明显优于开环模型。闭环模型极大程度上消除了预测误差，从而有效地提高了预测精度，并证明了 RBFNN-ZNN 模型的先进性。

图 13 和图 14 代表了受试者 1 的髋关节与膝关节的预测误差，受试者 2 的角度预测误差分别如图 15 和图 16 所示，其中蓝色曲线代表开环模型的预测值与真实测量值的误差，红线为闭环模型的估计值与真实值的误差，可更加直观地反映该模型的角度预测性能。

从 2 名受试者的误差结果中可清楚发现，闭环模型的误差曲线在 0 附近以极小幅度摆动且变化稳定，而开环模型的误差曲线波动较大

且变化杂乱。因此，闭环模型具有更好的预测精度和鲁棒性。根据 2 名受试者的实验数据，验证了本研究中的预测方法是有效的，能够准确识别下肢运动意图。

4 总结与展望

本研究提出了一种 RBFNN 与 ZNN 相结合的新颖预测方法，用于估计和识别人体下肢主动运动意图。通过实验分析及结果，所提出的 RBFNN-ZNN 闭环模型能够有效地消除由于 RBFNN 开环模型所导致的预测误差。RBFNN-ZNN 模型的整体性能明显优于 RBFNN 模型，并对于不确定因素具有较强的鲁棒性，进而能够




图 13 受试者 1 髋关节误差

Figure 13 Prediction error of hip joint of subject 1




图 14 受试者 1 膝关节误差

Figure 14 Prediction error of knee joint of subject 1




图 15 受试者 2 髋关节误差

Figure 15 Prediction error of hip joint of subject 2




图 16 受试者 2 膝关节误差

Figure 16 Prediction error of knee joint of subject 2

更加准确地估计出人体的主动运动意图。未来的工作重点是收集实际患者的临床数据, 提高预测模型性能, 为后续的人机交互系统的研究提供可靠的、有价值的参考。

利益冲突声明: 本文不存在任何利益冲突。

作者贡献声明: ①张鑫负责论文初稿写作, 数据采集与整理分析; ②李婉婷、陈岩负责数据采集与整理分析; ③孙中波负责论文撰写, 方法指导和方案确定。

参考文献

[1] NIU C M, BAO Y, ZHUANG C, et al. Synergy-based FES for post-stroke rehabilitation of upper-limb motor

functions [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(2): 256–264.


- [2] WEN Y, LI M H, SI J, et al. Wearer-Prosthesis interaction for symmetrical gait: a study enabled by reinforcement learning prosthesis control [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(4): 904–913.
- [3] WEI D, LI Z J, WEI Q, et al. Human-in-the-loop control strategy of unilateral exoskeleton robots for gait rehabilitation [J]. IEEE Transactions on Cognitive and Developmental Systems, 2019, 13(1): 57–66.
- [4] YU X B, HE W, LI Y A, et al. Bayesian estimation of human impedance and motion intention for human-robot collaboration [J]. IEEE Transactions on Cybernetics, 2019, 51(4): 1822–1834.

- [5] LIN M W, RUAN S J, TU Y W. A 3DCNN-LSTM hybrid framework for sEMG-based noises recognition in exercise [J]. IEEE Access, 2020. DOI: 10.1109/ACCESS.2020.3021344.
- [6] Park S, Wan K C, Kim K. Training-Free Bayesian self-adaptive classification for sEMG pattern recognition including motion transition [J]. IEEE Transactions on Biomedical Engineering, 2019, 67(6): 1775–1786.
- [7] HU X H, ZENG H, SONG A G, et al. Robust continuous hand motion recognition using wearable array myoelectric sensor [J]. IEEE Sensors Journal, 2021, 21(18): 20596–20605.
- [8] XI X G, JIANG W J, HUA X, et al. Simultaneous and continuous estimation of joint angles based on surface electromyography state-space model [J]. IEEE Sensors Journal, 2021, 21(6): 8089–8099.
- [9] LI Z Y, ZHANG D H, ZHAO X G, et al. A temporally smoothed MLP regression scheme for continuous knee/ankle angles estimation by using multi-channel sEMG[J]. IEEE Access, 2020. DOI: 10.1109/ACCESS.2020.2979008.
- [10] MA C F, GUO W Y, ZHANG H, et al. A novel and efficient feature extraction method for deep learning based continuous estimation [J]. IEEE Robotics and Automation Letters, 2021, 6(4): 7341–7348.
- [11] WANG W Q, HOU Z G, CHENG L, et al. Toward patients' motion intention recognition: dynamics modeling and identification of iLeg—an llrr under motion constraints [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 46(7): 980–992.
- [12] WANG G, LIU Y B, SHI T, et al. A novel estimation approach of sEMG-based joint movements via RBF neural network [C]. 2019 Chinese Automation Congress (CAC), 2019.
- [13] CHAI Y Y, LIU K P, LI C X, et al. A novel method based on long short term memory network and discrete-time zeroing neural algorithm for upper-limb continuous estimation using sEMG signals [J]. Biomedical Signal Processing and Control, 2021. DOI: 10.1016/j.bspc.2021.102416.
- [14] JIN L, LI S, HU B. RNN models for dynamic matrix inversion: a control-theoretical perspective [J]. IEEE Transactions on Industrial Informatics, 2017, 14(1): 189–199.
- [15] JIN L, YAN J K, DU X J, et al. RNN for solving time-variant generalized Sylvester equation with applications to robots and acoustic source localization [J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6359–6369.

编辑：刘静凯

《微创妇科学：循证视角》译著购书信息

《微创妇科学：循证视角》译著于2023年8月发行。该书由巴西南大河联邦大学和阿雷格里联邦医科大学的多位肿瘤学专家主笔，并且邀请来自欧洲、南美洲和北美洲等地区妇科领域的知名学者共同编写而成。全书包括32章，涵盖了妇科解剖结构和手术路径、子宫内膜异位症、一般妇科手术、泌尿妇科学手术、妇科肿瘤学手术以及手术并发症共6部分内容。本书结构层次清晰，语言通俗易懂，内容丰富新颖，翔实的文字内容与高清彩色插图的完美结合，再现了术中解剖操作的关键步骤，为广大妇科医师开展妇科微创手术提供了有益的理论依据。



订阅电话：029-87286478 QQ：2713004807

本刊编辑部