

DOI: 10.19650/j.cnki.cjsi.J1905477

基于电学测量的智能手势识别方法研究^{*}

李秀艳¹, 刘宗毓¹, 王琦¹, 汪剑鸣¹, 王化祥²

(1. 天津工业大学电子与信息工程学院 天津市光电检测技术与系统重点实验室 天津 300387;
2. 天津大学电气自动化与信息工程学院 天津 300387)

摘要:随着计算机的广泛应用和可穿戴电子设备的发展,将人机交互和可穿戴设备相结合逐渐成为研究热点,其中手势识别技术在人机交互领域扮演着重要的角色。主要提出基于电学测量的智能手势识别方法,利用传感器设备采集手腕边界电压数据,同时利用深度神经网络将采集到的电压数据进行分类,最终实现手势识别的目的。实验验证了通过电学测量数据对手势分类的可行性,将深度神经网络加入到手势识别系统中后,手势正确识别率达到90%以上,从而证明了系统具有较好的便携性、稳定性和实时性,为智能手势识别系统的设计提供了新思路。

关键词:电学测量;手势识别;电导率分布;深度神经网络;模型构建

中图分类号: TP391.4 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on the intelligent gesture recognition method based on electrical measurement

Li Xiuyan¹, Liu Zongyu¹, Wang Qi¹, Wang Jianming¹, Wang Huaxiang²

(1. Tianjin Key Laboratory of Optoelectronic Detection Technology and System, School of Electronics
and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China;

2. School of Electrical Automation and Information Engineering, Tianjin University, Tianjin 300387, China)

Abstract: With the wide application of computers and the development of wearable electronic devices, the combination of human-computer interaction and wearable devices has become a research hotspot. Gesture recognition technology plays an important role in the field of human-computer interaction. An intelligent gesture recognition method is proposed based on electrical measurement. The sensor device is used to collect the wrist boundary voltage data. At the same time, the deep voltage neural network is used to classify the collected voltage data, and finally the purpose of gesture recognition is realized. The experiment verifies the feasibility of classifying gestures by electrical measurement data. After adding deep neural network to the gesture recognition system, the correct recognition rate of gestures is over 90%, which proves that the system has better portability, stability and real-time. Sexuality provides new ideas for the design of intelligent gesture recognition systems.

Keywords: electrical measurement; gesture recognition; conductivity distribution; deep neural networks; model building

0 引言

目前人机交互技术不断发展,涌现出很多新兴技术,包括语音识别、视觉识别和手势识别等技术。在当前的技术发展环境下,手势识别技术顺应了发展的需要,已经成为人机交互领域中不可忽视的一项技术,从而证明了

可穿戴式的手势识别是人机交互中的一种重要方式^[1]。

手势识别作为人机交互研究的一个重要研究领域,按照输入设备的不同可分为基于视觉的手势识别^[2]和可穿戴式手势识别^[3]。基于视觉的手势识别需要在一个特定的没有遮挡的范围内实现,手势图像的获取对外部环境的依赖比较大,并且识别效果易受光线和复杂背景影响^[4]。而基于可穿戴式传感器的手势识别系统利用固定在手臂上的动作传

收稿日期:2019-08-14 Received Date:2019-08-14

^{*} 基金项目:国家自然科学基金(61872269, 61601324, 61903273)、天津市自然科学基金(18JCYBJC85300)、天津市企业科技特派员项目(18JCTPJC61600)、天津科技计划项目(19PTZWHZ00020)资助

传感器来获取手势数据,受环境影响小。传统的可穿戴设备的手势识别方法主要分为基于加速度传感器^[5]的手势识别、基于超声波的手势识别和基于肌电信号的手势识别。但是这些传统的可穿戴设备的手势识别方法都有各自的局限性,如基于超声波^[6]和加速传感器的手势识别方法具有使用的设备系统设计庞大复杂、造价高等缺点,基于肌电信号的手势识别所需的肌电信号是一种微弱的生物电信号,提取困难并且易受环境噪声和肌肉疲劳的影响^[7]。

针对传统可穿戴设备手势识别方法的不足,本文提出一种基于电学测量的可穿戴智能手势识别方法,根据手势变化引起肌肉松紧程度变化,进而影响手势阻抗分布的特点,通过向佩戴于人体腕部表面的电极阵列中两个相邻电极注入电流激励,测量电极阵列中其余相邻电极上的电压,得到不同手势下手腕的边界电压,采用电阻抗层析成像方法实现不同手势腕部阻抗图像重建^[8],验证通过电学测量方法实现手势分类的可行性,并且利用深度学习的方法对测量数据进行训练,最后实现了多种手势的识别。这种方法可以将系统集成到一个腕带上,进行实时监控和手势识别。这种基于电学测量的可穿戴手势识别技术具有非入侵、无损伤、可实时成像、识别率高、结构简单且成本低廉等优点。

1 基于电学测量的手势识别系统原理

本文设计的手势识别系统基于电学测量原理,通

过深度学习方法处理测量数据,达到手势识别的目的。系统采用电流激励、电压测量方式,在被测物场施加电流激励信号后,当被测物场内的电导率分布发生变化时,会导致内部的电流场发生变化,继而导致内部的电势分布发生变化,最终致使被测物场边界上的电压测量值发生变化,即可通过边界电压测量值的变化推断出被测物场内的电导率的变化。利用这个原理,当手势改变时,手腕内部的阻抗分布会改变,通过测量不同手势下的边界电压,一方面可以利用深度学习的方法对测量所得到的进行分类,最终达到手势识别的效果;另一方面,可以利用电阻抗层析成像技术^[9],对手腕内部电导率分布进行成像。

1.1 硬件系统设计

基于电学测量的手势识别系统主要由传感器阵列、激励模块、数据采集模块、数据处理及控制等模块组成。传感器单元处于系统的最前端,电压/电流激励源从不同的角度扫描被测区域形成空间敏感场,产生原始敏感信号;数据采集和数据处理单元负责转化、采集、处理来自传感器单元的敏感信号,完成相关的解调、滤波处理,最终从原始敏感信号中提取到有用的信息(如实部、虚部、幅值及相位等);控制模块是通过微控制器控制测量通道和激励通道的选择,最终实现循环激励循环测量的数据采集功能。在数据采集和处理之后微控制器通过 USB 串口将数据传给上位机。电学测量系统原理如图 1 所示。




图 1 电学测量系统原理
Fig.1 Schematic diagram of electrical measurement system

1) 电极传感器设计及激励/测量方法研究

电极传感器设计是采集数据准确性的关键,本文方案中设计了可穿戴式电极,将电极镶嵌到一种具有弹性材料的腕带上,使电极可以贴紧用户的皮肤。腕带电极模型如图 2 所示。

由于电学测量系统中的电极阵列需要与被测物场中的媒质相接触,所以在电极阵列和媒质之间必然存在着接触阻抗。该接触阻抗会极大的影响输出电阻很小的电压源的性能,导致电压源不能稳定的输出正弦电压信号。因此,电学测量系统中通常不采用电压激励,而采用输出




图 2 腕带模型
Fig.2 Wristband model

电阻较高的电流源^[10]。所以,本文选择电流激励电压测量作为系统的测量方式,并采用相邻激励,相邻测量的方式作为测量的总体结构,且在此基础上,采用循环激励循环测量的方式采集数据,循环激励循环测量的形式如图 3 所示。




图 3 循环激励循环测量的驱动模型

Fig.3 Drive model for cyclic excitation and cycle measurement

2) 激励源模块设计

在电学测量系统中,本激励源模块的目标是在指定带宽范围内产生符合要求的正弦激励信号并实现峰峰值恒定的电流输出,同时产生满足要求的与激励信号同频同相的正余弦参考信号。

本系统的激励源模块由正弦信号发生模块和压控电流源两部分组成。系统采用 DDS 模块进行正弦信号的合成,选用的 DDS 芯片为 AD9835,DDS 输出信号的相位和频率都可以进行调整。DDS 内部的累加器生成一个锯

齿波,其最高位作为正/余弦查找表的地址,输出信号的频率由累加器的步进量决定。通过查找表的方式从一个存储了余弦系数的双端口 ROM 中生成一个正弦波。系统通过压控电流源模块来产生激励电流,它可以将正弦电压信号转换成峰峰值恒定的电流信号。本系统正弦电压信号峰峰值为 1.0 V,通过压控电流源转换为峰峰值为 0.2 mA 的正弦电流,信号频率为 30 kHz。

3) 数据采集模块设计

本系统的数据采集模块设计是利用一个微控制器通过多路选通模块选择激励通道和测量通道,将激励施加到电极之中,并选择相应的电极进行测量,从而完成对被测对象的测量。

数据采集模块中 AD 模块使用的芯片为 AD637,该芯片为均方根直流转换器,可对输入的交流信号直接求取有效值,输出电压有效值计算公式为:

$$V_{OUT} = \sqrt{V_{IN}^2}$$
 (1)

式中: V_{IN} 为输入电压; V_{OUT} 为求出的有效值。 在本 AD 模块中芯片供电电压为 ± 5 V,输入交流信号的幅值有效值范围为 0.05 ~ 0.15 V,精度达到 1.0%,采样速率为 2 MHz。

多路选通模块中采用了由光电继电器构成的一种矩阵结构的多路开关,光电继电器执行速度快,在高速时钟下可以很好满足多路选通模块中切换电极通路对于时间的要求。矩阵开关结构如图 4 所示其中继电器阵列中每一行的继电器的一端都并联接到一块电极上,而另一端则分别接至激励的正负、数据采集的正负信号端。当某一电极被需要时将相应的继电器闭合,而不需要的电极则将其相应的继电器断开,从而完成选择激励通道和测量通道的任务。




图 4 矩阵开关结构

Fig.4 Matrix switch structure

4) 系统控制模块

本设计使用的控制器芯片是 ST 公司的 STM32 系列。STM32 控制器通过串口接收上位机的指令对数据的循环采样、数据的传输进行控制,控制多路选通模块选择

激励通道和测量通道,控制多路选通模块中相应继电器的闭合与断开,从而完成对电极的激励与测量,通过这种方式组合的矩阵开关可以实现任意的数据采集模式,在本设计中采用循环激励循环测量的数据采集模式,并且和上位机通过串口进行通信。

1.2 基于 DNN 网络的手势识别模型构建

1) 网络模型的选择

本文利用深度学习方法中深度神经网络 (deep neural networks, DNN) 高度逼近复杂非线性函数的能力^[11],建立手腕边界电压序列与手势标签之间的映射关系,实现手势识别。基于 DNN 方法的电学测量手势识别模型^[12]如图 5 所示。首先利用电学测量系统获得手腕边界电压序列,利用微控制器通过 USB 串口将数据发送给上位机,进行数据预处理后输入 DNN 网络进行手势识别。




图 5 基于 DNN 方法的电学测量手势识别模型

Fig.5 Electrical measurement gesture recognition model based on the DNN method

2) 网络模型的构建

本文采用 DNN 作为深度学习网络模型,DNN 是为处理一维数据而特殊设计的一个多层感知器,这种网络结构对平移、比例缩放、倾斜或者其他形式的变形具有高度不变性^[13]。DNN 基本网络模型包括输入层、隐含层和输出层,如图 6 所示。




图 6 DNN 基本模型

Fig.6 Basic mode of DNN

构建深度神经网络模型,需要确定网络模型的网络层数和它们各层节点个数,以及其他网络参数。包括权重、偏置向量等^[14]。构建网络模型首先需要初始化网络并随机初始化网络参数,将测得的电压数据作为网络的输入,设为 $x = \{x_1, x_2, x_3, \dots, x_p\}$,理想输出为 5 类不同手

势分类数据 $z = \{z_1, z_2, z_3, z_4, z_5\}$,网络正向求解出一组输出 $z' = \{z'_1, z'_2, z'_3, z'_4, z'_5\}$,隐含层各层之间是全连的形式。利用大量训练样本设置模型参数,包括选择恰当的激励函数,网络模型的层数,通过网络训练确定网络学习率、最佳迭代次数等。其中激励函数的作用是使神经网络更容易的通过低复杂性的线性组合平滑的求解线性问题。Sigmoid 函数是使用范围最广的一种激活函数,并且与正态分布函数的积分形式相似,计算相对简单,导数易求解,满足神经网络学习算法频繁求导需要,并且函数的域值范围为 (0,1),则其网络的输出可被视为预测概率,再经过网络微调,更容易得到较高置信度的输出,满足本网络的需要,故本文选择 Sigmoid 函数作为本网络的激励函数,Sigmoid 函数的定义为:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

从输入层神经元到隐含层神经元的求解过程如:

$$y_i = f\left(\sum_{j=1}^m w_{ij}x_j + b_i\right) \quad (3)$$

式中: w_{ij} 表示输入层第 j 个神经元和隐含层第 i 个神经元之间的权重; b_i 表示隐含层第 i 个神经元的偏置; x_j 表示输入层第 j 个节点的输入值,并且 y_i 是隐含层求解的结果。

从隐含层神经元到输出层神经元的求解过程如式 (4) 所示。

$$z_j = f\left(\sum_{i=1}^m w_{ij}y_i + b'_j\right) \quad (4)$$

式中: w_{ij}^T 表示隐含层第 i 个神经元与输出层第 j 个神经元的权重; b'_j 表示输出层第 j 个神经元的偏置。

均方误差函数表示为:

$$MSE = \frac{1}{p} \sum_{i=1}^p (y'_i - y_i)^2 \quad (5)$$

依据误差最小原则对权重进行调整,调整量为:

$$\Delta w = -\alpha \frac{\partial MSE}{\partial w_{ij}} = -\alpha (y'_j - y_j) x_j \quad (6)$$

式中: α 为学习率,表示按梯度方向进行搜索的步长因子,一般在 (0,1] 之间取值; w_{ij} 表示为第 j 个节点与前一层第 i 个节点之间的权重值。据此可以得出调整前后的权重关系为:

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad (7)$$

通过反向传播算法最小化损失函数,并采用梯度下降法对网络的参数进行更新:

$$LF(\mathbf{w}, \mathbf{b}) = \frac{1}{M} \sum_{k=1}^M T(\mathbf{x}^k + \mathbf{z}^k) + \frac{\varphi}{2} \|\mathbf{w}\|^2 \quad (8)$$

$$\mathbf{w} = \mathbf{w} - \alpha \frac{\partial LF(\mathbf{w}, \mathbf{b})}{\partial \mathbf{w}} \quad (9)$$

$$\mathbf{b} = \mathbf{b} - \alpha \frac{\partial LF(\mathbf{w}, \mathbf{b})}{\partial \mathbf{b}} \quad (10)$$

式中: LF 表示损失函数; T 表示取参数的 2 范数; φ 表示权重衰减因子。

不断调整学习率和权重等参数,使之满足最小均方误差的要求^[15]。在模型中输入层为测得的电压值,在训练过程中为提高特征的有效性,可设置不同权重系数。输出层是一个分类器模型,其对输入的手势电压值进行分类。另外为了避免模型出现过拟合的问题,本文通过 Dropout 方法对每一层隐含层设置失活概率,随机失活隐含层中的某些网络节点,提高网络的泛化能力。使用 Dropout 方法后,式(3)和(4)也会相应改变,具体如式(11)和(12)所示。

$$y_i = f\left(\sum_{j=1}^m w_{ij} \text{Bernoulli}(p) * x_j + b_i\right) \quad (11)$$

$$z_j = f\left(\sum_{i=1}^m w_{ij}^T \text{Bernoulli}(p) * y_i + b'_j\right) \quad (12)$$

式中: $\text{Bernoulli}()$ 表示随机生成 0 或者 1 的函数,概率 p 为 0.5。

为了提高 DNN 网络模型最优解求解精度,提高求解速度,将手腕边界电压序列 U 进行如式(13)所示的归一化处理。

$$U_i^* = \frac{U_i - U_{\min}}{U_{\max} - U_{\min}} \quad (13)$$

式中: U_i 表示电压序列中第 i 个电压数据; $U_{\min}$ 表示电压序列中最小的电压数据; $U_{\max}$ 表示电压序列中最大的电压数据; U_i^* 表示第 i 个电压数据归一化后的值。

2 基于深度神经网络的手势识别

2.1 获取与处理原始数据

本文设计的电学测量手势识别实验系统如图 7 所示。




图 7 电学测量手势识别实验系统

Fig.7 Electrical measurement gesture recognition experiment system

电极阵列紧贴在用户手腕周围,对电极施加电流激励并测量反馈电压,使用数据采集模块对每个手势动作采集一定的数据。为获得较好的测量数据,测试者按照

既定顺序做出不同的手势,共有 5 种手势,分别是放松、握拳、左弯、右弯、张开。测试者每次做出一种手势,保持 5 s 左右,在此期间系统进行 5 次数据采集,接着测试者进行下一个动作,5 种手势循环出现,每种手势会出现 50 次,则每种手势可得到 250 个测量数据,最后数据集总共得到 1 250 组测量数据,作为网络模型的训练样本,数据采集过程如图 8 所示。




图 8 手势数据采集过程

Fig.8 Process of gesture data acquisition

2.2 训练网络模型


在获得原始数据并进行处理之后,对构建好模型进行训练。本文采用预训练和微调两个训练阶段相结合完成 DNN 网络模型训练^[16]。

在预训练阶段,随机初始化网络模型的权重矩阵和偏置向量,将训练样本送入输入层,并且采用贪逐层的方法进行训练,确定每层的神经元数即节点数,输入层为 40 个节点,输出层为 5 节点,每个隐含层为 20 节点,设置网络的学习率范围为 0.01 至 0.1,将前一层的输出最为后一层的输入,不断通过损失函数公式,权重公式和偏置向量等公式对参数进行调整,依次得到多组权重矩阵和偏置向量, $\{w^l, b^l\}$, 并得到最后一层隐含层的输出。

在微调阶段,将预训练得到的最佳网络参数作为整个 DNN 网络模型的初始化参数,将训练样本送入输入层,随机初始化最后一层隐含层和输出层之间的权重和偏置向量,确定每层的神经元数即节点数,输入层为 40 个节点,输出层为 5 个节点,每个隐含层为 20 个节点,


将网络模型的学习率范围设置为 0.1~1,将最后一个隐含层的输出作为输出层的输入,最后得到输出层的实际输出,根据反向传播算法优化损失函数,使之最小,并采用反向传播算法以自顶向下的方式来微调整个网络的参数,最终得到最佳学习率、权重和偏置向量等参数,得到最终的神经网络模型。

通过实验确定出该网络预训练的最优学习率为 0.01,在该网络参数下,得到不同网络层数、微调阶段学习率在不同迭代次数下的 MSE 曲线,如图 9 所示。



(a) 4层网络模型下均误差随微调学习率与迭代次数变换关系

(a) The relationship between mean square error and fine-tuning learning rate and iteration number under four-layer network model



(b) 最佳微调学习率下,不同层数网络的均方误差与迭代次数变换关系

(b) The relationship between mean square error and iteration times of different layer networks under the optimal fine tuning learning rate

图 9 不同网络层数、微调阶段学习率在不同迭代次数下的 MSE 曲线

Fig.9 Mean square error curve of different network layer and fine tuning stage learning rate under different iteration times

通过网络模型的训练结果可知,随着迭代次数的增加,误差迅速下降。本文选择最佳学习率和最小迭代次数作为最佳参数值,设置的学习率为 0.2,网络模型为 4 层。并通过使用成本函数将模型的输出与实际情况进行比较,使用反向传播调整神经元之间的权重,以加强正确的预测及削弱错误的预测。

3 实验验证

3.1 手势识别测量数据可区分性验证

为了验证基于电学测量的手势识别方法的可行性,本文首先对不同手势条件下,手腕边界电压数据的可区分性进行验证,不同手势条件下边界电压数据曲线如图 10 所示,每种类型的曲线代表不同的手势,横坐标表示该组数据中数据的序列号,纵坐标为电压值。从图 10 中可以看到虽然每种手势的数据趋势具有相似性,但不同手势测量值之间存在一定的区别,从而可以说明通过电学测量数据对手势进行分类是可行的。




图 10 不同手势下电压数据曲线

Fig.10 Voltage data curve under different gestures

为了进一步验证测量数据可区分性产生的原因,本文通过 Tikhonov 算法^[17]对不同手势的边界电压测量数据进行腕部电阻抗层析成像^[18],重构手腕内部电极所在截面电导率图像,结果如图 10 所示。可以看出,不同手势条件下,手腕内部的电导率分布特征存在差异,进而产生了测量数据的差异。这正是本文提出的基于电学测量的手势识别方法的根本依据。但是由于图像重建问题是一个病态的问题,容易引入误差导致通过图像的方法分辨手势的精度降低,所以本文设计了通过使用 DNN 对测量数据进行分类实现手势识别的方法。




图 11 不同手势重建图像对比

Fig.11 Comparison of different gesture reconstruction images

3.2 使用 DNN 网络进行手势识别

利用本文设计的手势识别系统采集放松、握拳、张开、左弯、右弯 5 种手势测试集。要求测试者每种手势保持 5 s,期间采集 5 组测量数据,5 种手势循环出现,共计获

取 500 组测试数据,即每种手势 100 组测试数据。利用第 2 节基于 DNN 网络构建的测量数据与手势类别映射模型,进行手势识别测试实验。

本文采用正确识别率 CRR 衡量手势识别的准确率,定义为:

$$CRR = \frac{N_c}{N} \times 100\%$$

(14)

式中: N_c 表示为正确识别手势的个数; N 表示为手势识别数据总数。

利用获取的五种手势各 100 组测试样本进行手势识别实验,识别结果如图 12 所示。




图 12 手势识别结果
Fig.12 Gesture recognition results

在图 12 中横坐标表示样本序列,纵坐标表示手势类别,纵坐标中的 0~4 依次分别代表放松、握拳、张开、左弯和右弯 5 种手势。从图 12 中可以看出本方法能够有较好的手势识别结果,但由于有噪声、电极与皮肤间的接触阻抗等因素的存在,会产生测量误差,最后导致手势识别结果产生识别偏差。5 种手势的识别准确率如表 1 所示。

表 1 5 种手势识别率

Table 1 Recognition rate of five gestures (%)

手势	CRR	手势平均正确识别率
放松	98	94.4
握拳	92	
张开	90	
左弯	98	
右弯	94	

通过程序最终运行所得到的结果,可以得出相应结论,本文使用的 DNN 模型能够很好的对 5 种手势的数据进行分类,有较高的手势识别率,手势正确识别率可达 90% 以上,能够达到较好的手势识别效果。

4 结 论

本文根据目前现有的手势识别方法的不足,并根据手势的变化会导致人体手腕内部肌肉电导率分布发生显著变化这一特点,提出了一种基于电学测量的智能手势识别方法,并设计了基于电学测量的智能手势识别系统,将深度学习中的深度神经网络加入到电学测量之后的数据处理和分类上,实现了手势识别的功能,提高了手势识别率,为验证该方法,进行了 3 个相关实验。首先在不同手势边界条件下,进行手腕边界电压数据的可区分性验证实验,验证了通过数据分类进行手势识别的可行性;其次为了验证测量数据可区分性产生的原因,对边界电压测量数据进行电阻抗层析成像实验;最后设计了深度神经网络进行测量数据分类实验,完成了基于电学测量的智能手势识别分类,并通过不断地改进测量系统,训练调整网络参数,使得基于电学测量的智能手势识别方法的手势正确识别率可以达到 90% 以上。

本文根据提出的方法所设计的系统具有设计简单体积小、系统运行稳定、实时性好、成本低和识别率高等特点,克服了基于视觉的手势识别易受光线和复杂背景影响的缺点,克服了基于超声波和加速传感器的手势识别系统设计复杂造价高等缺点,验证了电学测量法用于手势识别的可行性。在未来的工作中,将进一步优化系统,提高系统集成度;不断增加样本数据量,优化样本选取与预处理方法;进一步优化电极的选择和设计从而降低电极与皮肤之间的接触阻抗,提高测量的精度,进一步提高手势识别的准确率。

参考文献

[1] 于南翔,陈东义,夏侯士戟. 可穿戴计算技术及其应用的新发展[J]. 数字通信, 2012, 39(4):13-20.
YU N X, CHEN D Y, XIAHOU SH J. New developments in wearable computing technology and its applications[J]. Digital Communications, 2012, 39(4):13-20.

[2] WANG CH, LIU ZH, CHAN S C. Superpixel-based hand gesture recognition with Kinect depth camera [J]. IEEE Transactions on Multimedia, 2014, 17(1): 29-39.

[3] 徐军,刘春花,孟月霞,等.可穿戴手势识别控制器[J]. 电子技术应用, 2016, 42(7): 68-71.
XU J, LIU CH H, MENG Y X, et al. Wearable gesture recognition controller [J]. Electronic Technology Application, 2016, 42(7): 68-71.

[4] BADI H. Recent methods in vision-based hand gesture recognition[J]. International Journal of Data Science & Analytics, 2016, 1(2):77-87.


[5] 陈鹏展,罗漫,李杰. 基于加速度传感器的连续动态手势识别[J]. 传感器与微系统, 2016, 35(1):39-42.

- CHEN P ZH, LUO M, LI J. Continuous dynamic gesture recognition based on acceleration sensor [J]. Journal of Sensors and Microsystems, 2016, 35(1): 39-42.
- [6] 杨晓东,陈益强,于汉超,等. 面向可穿戴设备的超声波手势识别方法[J]. 计算机科学,2015, 42(10):20-24.
YANG X D, CHEN Y Q, YU H CH, et al. Ultrasonic gesture recognition method for wearable devices [J]. Computer Science, 2015, 42(10): 20-24.
- [7] BENATTI S, CASAMASSIMA F, MILOSEVIC B, et al. A versatile embedded platform for EMG acquisition and gesture recognition [J]. IEEE Trans Biomed Circuits Syst, 2015, 9(5): 620-630.
- [8] 邓娟,王妍,吕婧华,等. 三种 EIT 算法重建图像评价的仿真研究[J]. 医疗卫生装备, 2010, 31(5):1-3.
DENG J, WANG Y, LV J H, et al. Simulation study on image evaluation of three EIT algorithms for reconstruction [J]. Medical Equipment, 2010, 31(5): 1-3.
- [9] 唐磊. 电阻抗断层成像算法研究及系统软件设计[D]. 天津:天津大学, 2006.
TANG L. Research on electrical impedance tomography algorithm and system software design [D]. Tianjin: Tianjin University, 2006.
- [10] TOLABIN D E, GÓMEZ B, ROSSI, et al. Design and implementation of an electrical impedance tomography system for lung imaging [C]. IEEE ARGENCON-Congreso Bienal de la Sección Argentina, 2016.
- [11] BENGIO Y. Learning deep architectures for AI [J]. Foundations & Trends in Machine Learning, 2009,2(1): 1-127.
- [12] DENISOV I V, KULCHIN Y N, PANOV A V, et al. Neural network methods of reconstruction tomography problem solutions [J]. Optical Memory & Neural Networks, 2015,14(1): 45-58.
- [13] HAMILTON S J, HAUPTMANN A. Deep D-bar: Real time electrical impedance tomography imaging with deep neural networks [J]. IEEE Transactions on Medical Imaging, 2018, doi:10.1109/TMI.2018.2828303.
- [14] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation Massachusetts Institute of Technology, 2006, 18(7): 1527-1554.
- [15] HINTON G E, SRIVASTAVA A, KRIZHEVSKY I, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4): 212-223.
- [16] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep convolutional neural network for inverse problems in imaging[J]. IEEE Transactions on Image Processing, 2017,26(9): 4509-4522.
- [17] LUKASCHEWITSCH M, MAASS P, PIDCOCK M.

Tikhonov regularization for electrical impedance tomography on unbounded domains [J]. Inverse Problems,2003,19(3): 585-610.

- [18] 温丽梅,周苗苗,李明,等.改进的 Tikhonov 正则化图像重建算法[J].计量学报,2018, 39(5):679-683.
WEN L M, ZHOU M M, LI M, et al. Improved Tikhonov regularized image reconstruction algorithm [J]. Acta Metrological Sinica, 2018, 39(5): 679-683.

作者简介



李秀艳,2003 年于河北科技大学获得学士学位,2007 年于河北工业大学获得硕士学位,2010 年于天津大学获得博士学位,现为天津工业大学讲师,主要研究方向为机器学习、电学层析成像以及智能信息处理。
E-mail: lixiuyan@tjpu.edu.cn

Li Xiuyan received her B. Sc. degree from Hebei University of Science and Technology in 2003, her M. Sc. degree from Hebei University of Technology in 2007, and her Ph. D. degree from Tianjin University in 2010. She is currently a lecturer at Tianjin Polytechnic University. Her main research interests include machine learning, electrical tomography and intelligent information processing.



刘宗毓,2016 年于天津工业大学获得学士学位,现为天津工业大学硕士研究生,主要研究方向为电学层析成像。
E-mail: yinianluochen@163.com

Liu Zongyu received his B. Sc. degree from Tianjin Polytechnic University in 2016. He is currently a M. Sc. candidate at Tianjin Polytechnic University. His main research interest is electrical tomography.



王琦(通信作者),分别在 2007 年、2009 年和 2012 年于天津大学获得学士学位、硕士学位和博士学位,现为天津工业大学副教授,主要研究方向为智能信息处理、电学成像技术。
E-mail: wangqitju@163.com

Wang Qi (Corresponding author) received her B. Sc., M. Sc. And Ph. D. degrees all from Tianjin University in 2007, 2009, and 2012, respectively. She is currently an associate professor at Tianjin Polytechnic University. Her main research interests include intelligent information processing and electrical imaging technology.



王化祥,1982 年于天津大学获得硕士学位,现为天津大学教授、博士生导师,主要研究方向为检测技术与信号处理。
E-mail: hxwang@tju.edu.cn

Wang Huaxiang received his M. Sc. degree from Tianjin University in 1982. He is now a professor and Ph. D. supervisor in Tianjin University. His main research interests include measurement technology and signal processing.