

· 康复医学工程 ·

基于隐马尔可夫模型-径向基神经网络的表面肌电信号识别*

李 芳¹ 王人成¹ 姜 力² 刘 宏² 朱德有³

摘要 目的:利用隐马尔可夫模型-径向基神经网络(HMM-RBFN)混合模型对7种手指动作进行辨识,探索控制HIT多自由度灵巧手的有效控制策略。**方法**:8例健康实验对象参加了试验,4例女性,4例男性。每例实验对象按提示完成7种手指动作,每种动作重复50次。通过表面肌电信号(sEMG)采集系统,提取实验对象前臂4块肌肉的sEMG,在对其进行预处理并提取小波变换特征向量后,分别送入HMM模型分类器及HMM-RBFN混合模型分类器进行训练。**结果**:HMM-RBFN混合模型识别效果和稳定性都大大优于HMM模型,验证了HMM-RBFN混合模型的有效性。**结论**:①HMM模型在sEMG识别中的效果没有其在语音信号识别中的好,有必要对其进行改进,以便更好的应用于sEMG的识别;②将HMM模型和神经网络组成混合分类器,可以弥补彼此的不足,获得更好的性能。

关键词 隐马尔可夫模型;径向基神经网络;表面肌电信号;假手

中图分类号:R496,R318 文献标识码:A 文章编号:1001-1242(2006)-11-1016-03

A HMM-RBFN hybrid classifier for surface electromyography signals classification/LI Fang, WANG Rencheng, JIANG Li, et al. //Chinese Journal of Rehabilitation Medicine, 2006, 21(11):1016-1018

Abstract Objective: To classify surface electromyography(sEMG) signals by using HMM-RBFN hybrid classifier and to explore the strategy of effectively controlling hand prosthesis. **Method:** Eight subjects (male 4, female 4) with normal upper limbs were selected in the experiments. Each subject was instructed to perform 7 kinds of fingers movement and each motion was repeated 50 times. The sEMG signals were recorded on 4 forearm muscles. Features of sEMG signals were extracted using wavelet transform and conveyed to HMM classifier and HMM-RBFN hybrid classifier for training. **Result:** HMM-RBFN hybrid classifier provided better results than that from the single HMM classifier. **Conclusion:** ①The performance of HMM classifier is not so excellent in sEMG signal discrimination. ②The HMM-RBFN hybrid classifier combine the advantages of two individual classifiers and offset their disadvantages, hence it achieves higher discrimination, accuracy and stability.

Author's address Division of Intelligent and Biomechanical System, State Key Laboratory of Tribology, Tsinghua University, Beijing, 100084

Key words hidden Markov model; radial basis function networks; surface electromyography; hand prosthesis

利用表面肌电信号(surface electromyography, sEMG)控制多自由度假肢是目前假肢技术研究中的一个热点问题^[1-2]。其中,人工神经网络(artificial neural network, ANN)已经被认为是解决sEMG动作识别问题的一个强有力的工具,但是它通常难以处理sEMG这种非线性时变信号。尽管已经有人提出在网络结构中引入反馈来提高ANN对动态序列的记忆能力,但是当前的ANN拓扑结构对于时间序列的建模是难以胜任的;而隐马尔可夫模型(hidden Markov model, HMM)对于时间序列的变化提供了一个良好的概率描述,并已被广泛地应用于语音识别和说话人识别,但是HMM的分类能力却比较弱^[3-4]。因而将ANN与HMM相结合,可以改善对时变信号模式分类的性能。从这一点出发,本文提出了一种基于隐马尔可夫模型-径向基神经网络(hidden Markov

model-radial basis function networks, HMM-RBFN)混合模型的sEMG识别系统,用于对7种手指动作进行辨识。

1 HMM

HMM是一种用参数表示的、用于描述随机过程统计特性的概率模型^[4-5],它是一个双重随机过程。其中之一是Markov链,它描述状态的转移。另一随机

* 基金项目:国家自然科学基金资助项目(50435040);黑龙江省教育厅资助项目(1512225)

1 清华大学摩擦学国家重点实验室智能与生物机械分室,北京,100084

2 哈尔滨工业大学机器人研究所

3 黑龙江工程学院

作者简介:李芳,女,硕士研究生

收稿日期:2006-05-08

过程描述状态和观察值之间的统计对应关系。

HMM 可以由 $\lambda=(N, M, \pi, A, B)$ 来表示。其中 N 为模型中 Markov 链状态数目; M 为每个状态对应的可能的观察值数目; π 为初始状态概率矢量; A 为状态转移概率矩阵; B 为观测值概率矩阵。

2 识别方法

在基于 HMM 模型的识别方法中, 一般是对待识别的 L 种动作模式分别建立相应的 HMM 模型, 形成 HMM 模型库。当输入未知的观察序列(sEMG)时, 首先分别计算出该观察序列在各个模型下的对数似然概率值, 然后取输出值最大的动作模式对应的 HMM 模型作为该序列的动作判别结论。由于检测到的 sEMG 往往受到噪声污染, 当对其进行辨识时, 有可能若干个 HMM 模型的输出概率相差不大, 如果只凭概率最大来做决定, 就有可能误判^[6]。而基于 RBFN 的 sEMG 识别方法, 由于忽视信号前后时刻的关系, 得到的判别结果可能是实际中根本不会发生的, 从而也导致误判。如果将 HMM 与 RBFN 相结合, 利用两者的优点, 互相弥补彼此不足, 可以获得更好的识别性能。

基于 HMM-RBFN 的混合 sEMG 辨识系统的原理: 首先将 4 通道 sEMG 进行预处理后提取小波变换特征作为训练样本, 分别训练 HMM 模型库和 RBFANN。在识别时, 对未知信号作预处理和特征提取后, 分别输入训练好的 HMM 模型库。对于 HMM 模型, 计算各动作对应的 HMM 模型与未知信号的匹配程度, 排除概率小的类别后, 得到候选类别集 C 。对于 RBF 网络, 则直接得到唯一的类别判别结果 Y 。然后将 RBFN 的判别结果与 HMM 的候选类别集进行比较, 如果 Y 在候选类别集 C 中, 则将 Y 作为最终判别结果; 否则, 取候选集 C 中概率最大的类别作为最终判别结果。

3 信号识别

sEMG 识别系统的目的是为了控制哈尔滨工业大学研制的 HIT 欠驱动仿人灵巧手。HIT 手有 5 个手指, 拇指有两个指节, 其他 4 指均为 3 指节。拇指、食指及中指可以独立运动, 分别由 1 个电机驱动。无名指和小指没有电机, 通过连杆和弹簧与中指联动。整个手有 14 个关节, 3 个独立自由度, 其余为被动自由度。

结合日常生活中人手的功能, 针对 HIT 灵巧手的机构特点, 对以下 7 种手指动作进行辨识, 即: 拇指伸(thumb extension, TE)、拇指屈(thumb flexion,

TF), 食指伸(index extension, IE), 拇-食指对捏/伸展(two fingers pinch/ two fingers extension, TFP/TFE), 强力抓取(power grasp, PG), 平掌(flatten hand, FH)。表面 sEMG 由 4 个有源电极拾取、滤波、放大后, 送入到 A/D 采样, 采样速率 2400Hz。4 个电极用护腕分别固定于拇短伸肌、指伸肌、指浅屈肌和尺侧腕屈肌 4 块肌肉肌腹的上方。

实验对象为 8 例健康志愿者, 其中男性 4 例, 女性 4 例。每个实验对象都完成上述 7 种动作, 每个动作持续 1min, 重复 50 次, 共得到 500 组数据。其中, 将每个动作的前 30 次数据用于训练, 后 20 次用于测试。由于实验对象均为健康者, 实验的结果反映了实际所能达到的最好效果。

3.1 特征提取

小波分解具有很好的时频分辨率, 可以较好地表征 sEMG 的非平稳特性, 因此应用小波变换来提取特征: 首先求出 N 点 sEMG 在尺度 $a=1, \dots, 5$ 时的连续小波变化系数, 得到大小为 $N \times 5$ 的系数矩阵, 然后计算系数矩阵的奇异值, 最后将 4 通道系数矩阵的奇异值组合为该 N 点 sEMG 的小波分解特征向量。

采用 4 阶 Coiflet 母小波进行小波分解, 能获得比其他阶次、其他母小波更好的精度。因此, 在实验中选用 coif4 母小波进行连续小波分解。

对于 RBF 网络, 直接提取在动作开始后的 256 点信号作 5 级连续小波分解。对于 HMM 模型, 截取动作开始后的 4 帧信号, 每帧信号长度为 64 点。对每帧信号进行 5 级连续分解提取特征并归一化, 然后将 4 帧信号特征向量作为一个观察值, 形成 $T=4$ 的观察值序列。

3.2 模型训练

sEMG 是连续时变信号, 尽管可以通过矢量量化将其进行离散并符号化, 但这可能会降低信号的信息特征。因此, 在 sEMG 识别中, 选用左-右型、连续 HMM 模型。模型状态数为 4, 每状态观察值概率矩阵由 3 个高斯概率密度函数联合决定。

对于左-右型 HMM, 初始概率分布向量 π 取为 $\pi=[1, 0, 0, 0]$, 实际计算中, 不对参数 π 进行估计。状态转移概率矩阵 A 初值随意选取。而每状态观察值概率矩阵 B (即高斯概率密度函数参数) 初值由分段 K 均值方法确定。HMM 的训练采用多个观测值序列的 Baum-Welch 重估算法^[4]。对于每个手指动作, 训练一个 HMM 模型, 得到有 7 个 HMM 模型组成的 HMM 模型库。

对于 RBF 网络, 采用 MATLAB ANN 工具箱的

newrb 函数进行训练。通过交叉验证的方法,最后确定不同实验对象 RBF 网络的扩展常数和隐层最大节点数如表 1 所示。

表 1 RBFN 参数设置

	zy	lx	lxy	lf	hxg	zjd	hx	cfw
扩展常数	7.5	28.8	6.2	14.4	21	16.4	20	10.1
隐层节点	70	40	60	80	80	100	40	40

3.3 辨识流程

首先将预处理后的待识别信号划分为 4 帧,每帧 64 点,分别提取小波变换特征并归一化,形成观察值序列 $O(T=4)$ 。将 O 送入 HMM 模型库,用前向-后向算法计算各动作对应 HMM 模型下此观察值序列的概率 $P(O/\lambda_k)$,排除概率最小的 3 类动作,剩下 4 类作为候选动作集。同时将这 256 点待识别信号直接提取小波变换特征,然后送入 RBF 网络进行辨识,得到判别结果。最后将 RBFN 的判别结果与 HMM 的候选类别集进行比较,如果它在候选动作集中,则将它作为最终判别结果;否则,取候选动作集中概率最大的类别作为最终判别结果。

4 实验结果

4.1 HMM

本实验采用左-右型连续 HMM 模型,状态数为 $N=4$,高斯混合概率数为 3,每个动作的前 30 次数据作为训练集,后 20 次数据作为测试集,8 例实验对象测试集的识别结果如表 2 所示。

从表 2 可以看出,不同实验对象的识别效果差异很大,且对于大多数实验对象,HMM 模型的识别效果均不是很理想。

4.2 HMM-RBFN

将 8 例实验对象 7 个动作的 350 组数据送入 HMM-RBFN 进行识别。其中 HMM 的参数设置同单个 HMM 模型的参数。针对不同实验对象,RBF 网络参数设置见表 2,8 例实验对象的识别结果见表 3。

结果表明,混合结构比单用 HMM 平均识别率提高 10.18%(4.28%—17.5%)。采用 HMM-RBFN 混合模型,能有效改善单个 HMM 分类器的性能。

表 2 8 例实验对象基于 HMM 的 sEMG 识别结果

实验对象	拇指屈(TF)	拇指伸(TE)	拇-食指对捏(TFP)	拇-食指伸展(TFE)	食指伸(IE)	强力抓取(PG)	平掌(FH)	识别率(%)
zy	20	8	17	7	15	14	18	70.71
lx	20	14	20	14	9	11	12	71.43
lxy	19	17	19	16	19	12	19	86.43
lf	19	11	16	7	8	19	13	66.43
hxg	13	17	20	13	20	5	14	72.86
zjd	17	18	17	8	14	11	14	70.71
hx	14	20	19	20	18	20	20	93.57
cfw	9	20	10	6	20	19	11	67.86

表 3 8 例实验对象基于 HMM-RBFN 的 sEMG 识别结果

实验对象	拇指屈(TF)	拇指伸(TE)	拇-食指对捏(TFP)	拇-食指伸展(TFE)	食指伸(IE)	强力抓取(PG)	平掌(FH)	识别率(%)
zy	19	17	18	13	19	17	20	87.86
lx	20	17	19	16	14	13	14	80.71
lxy	18	20	20	17	20	13	19	90.71
lf	19	16	17	9	16	20	16	80.71
hxg	8	17	20	14	20	16	16	79.29
zjd	20	19	18	14	14	10	17	80.00
hx	20	19	20	20	20	20	20	99.26
cfw	17	20	9	15	20	17	18	82.86

识别器性能的衡量标准之一,是其在对不同的模式进行识别时,是否具有相对的稳定性^[5]。sEMG 可重复性差,个体差异大,在两个不同的时刻、同一动作的 sEMG 特征也可能很不相同。一般情况下,用于训练分类器的 sEMG 来自不同实验对象、不同时刻的多个样本,以便使分类器对不同动作、不同实验对象都具有较好的一致性。结果表明,HMM-RBFN 混合结构识别器比单一 HMM 识别器的方差均要小,对不同的实验对象的适应能力,以及对不同动作的识别稳定性都得到了提高。

5 结论

尽管在语音信号识别领域,HMM 分类器具有非常优秀的识别性能,但其在 sEMG 识别方面的效果却不够理想。将 HMM 结合 RBF 网络组合成 HMM-RBFN 混合分类器后,识别正确率和稳定性都大为提高。说明采用多分类器集成的方法来设计 sEMG 识别系统,是提高 sEMG 识别准确性的行之有效的途径。另外,从 HMM 和 HMM-RBFN 的识别结果也可看到,同一分类器结构,不同实验对象间识别效果相差很大。这主要是由不同实验对象在做动作时的熟练程度和准确程度的差异造成的。因此,在使用 sEMG 假肢前,必须对患者进行专门的肌肉训练,以提高 sEMG 假手的使用性能。

参考文献

- [1] 王敬章,李芳,王人成,等. 人工神经网络在表面肌电信号辨识中的研究进展[J]. 中国康复医学杂志,2006,21(1):81—83.
- [2] 李芳,王人成. 肌电信号及其运动模式辨识方法的发展趋势[J]. 中国康复医学杂志,2005,20(7):492—493.
- [3] 包威权,陈珂,迟惠生. 基于 HMM-MLFNN 混合结构的说话人辨认研究[J]. 北京大学学报(自然科学版),1997,33(3):361—370.
- [4] Rabiner LA. Tutorial on Hidden Markov models and selected application in speech recognition [J]. Proceedings of the IEEE, 1989,77:257—286.
- [5] 谢锦辉. Markov 模型(HMM)及其在语音处理中的应用[M]. 武汉:华中理工出版社,1995.4—5.
- [6] 柳新民,邱静,刘冠军. 基于 HMM-SVM 的混合故障诊断模型及应用[J]. 航空学报,2005,26(4):496—500.