

基于多源域自适应的跨被试情感脑电识别

高寒冰¹, 张驰¹, 靳明艳¹, 肖杨¹, 丛丰裕^{1,2}

(1. 大连理工大学电子信息与电气工程学部生物医学工程学院, 辽宁 大连 116024;

2. 大连理工大学电子信息与电气工程学部人工智能学院, 辽宁 大连 116024)

摘要: 在基于脑电信号的情感检测过程中, 受被试间脑电信号的差异影响, 传统的机器学习和深度学习方法不能很好地针对脑电数据建立通用的分类检测模型。针对此问题, 将每个被试看作独立的域, 建立针对脑电数据的多源域自适应的跨被试情感脑电识别模型, 并在公开数据集上进行验证。验证结果表明, 与单源域模型相比, 提出的模型有更好的跨被试特征提取及分类能力。

关键词: 多源域; 跨被试; 域自适应; 神经网络; 情感脑机接口; 脑电信号

中图分类号: R318

文献标识码: A

doi: 10.11959/j.issn.2096-6652.202106

Cross-subject emotional EEG recognition based on multi-source domain adaptation

GAO Hanbing¹, ZHANG Chi¹, JIN Mingyan¹, XIAO Yang¹, CONG Fengyu^{1,2}

1. School of Biomedical Engineering, Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, China

2. School of Artificial Intelligence, Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, China

Abstract: During the recognition of emotion based on electroencephalography (EEG) signals, traditional machine learning and deep learning methods cannot establish a general classification and detection model for EEG data due to the differences in EEG signals among subjects. Each subject was treated as an independent domain, a multi-source cross-subject emotional EEG recognition model was established, and the model was verified on the public dataset. The evaluation results show that compared with single-source domain model, the proposed model has better cross-subject feature extraction and classification capabilities.

Key words: multi-source domain, cross-subject, domain adaptation, neural network, affective brain-computer interface, EEG signal

1 引言

作为人类日常生活的基础, 情绪在制定决策、人际沟通交流中都起着非常关键的作用, 甚至会关系到人的精神健康状况。因此, 通过对情绪进行分类研究, 不仅能够增强人机情感交互^[1], 也能够为精神疾病的治疗与诊断提供量化评价辅助方法^[2]。近年来, 情绪识

别的研究方法主要包括基于语言的情绪分类^[3]、基于面部表情及姿态的情绪分类^[4]以及基于脑电信号(electroencephalography signal, EEG signal)的情绪分类^[5]等。由于情感的产生与大脑的许多内部和外部活动相关, 与语言和面部表情及姿态相比, 脑电信号更能诚实地反映出与情感相关的状态变化^[6], 无法伪装。近年来, 越来越多的研究者开始关注基于脑电信号

收稿日期: 2021-01-21; 修回日期: 2021-02-24

通信作者: 张驰, chizhang@dlut.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61703069); 国家重点研发计划基金资助项目 (No.JCKY2019110B009)

Foundation Items: The National Natural Science Foundation of China (No.61703069), The National Key Research and Development Program of China (No.JCKY2019110B009)

的情感分析。情感脑机接口(affective brain-computer interface, aBCI)研究的正是如何从脑电信号中解析和识别用户的情感状态的。

脑电信号虽然可以真实地反映情感状态的变化,但由于它存在很强的个体间差异性,相同的情绪产生于不同的被试,脑电信号呈现的特征可能不尽相同。而传统的机器学习方法的前提是用于学习和测试的样本是服从独立同分布的,在跨被试脑电信号识别中,该方法的效果并不理想。针对这样的问题,域自适应(domain adaptation)算法通过降低域间的差异,同时保持针对任务的区分能力^[7],能够在一定程度上解决脑电信号的“域”的不统一问题。域对抗神经网络(domain adversarial neural network, DANN)^[8]就是一个典型的域自适应算法,通过域分类器与任务分类器之间的对抗,提高模型对不同域的数据的分类能力。

然而 DANN 只能完成单源域迁移学习,针对有多个源域的场景(如脑电数据通常来自多名不同的被试),DANN 无法在多个域间进行对抗学习。如果被试间的相关性较低,单源域迁移学习可能会造成负迁移现象^[9]。而多源域迁移学习可以弥补这些缺点,从而达到较好的迁移效果。本文提出将多源域自适应神经网络应用于跨被试的情感脑电识别,将不同被试的数据分别标记为不同的域进行对抗学习,建立跨被试情感脑电识别模型。

2 情感脑电数据集及数据处理

2.1 情感脑电数据集

本文使用公开数据集 SEED (SJTU Emotion EEG dataset)^[10]进行研究。SEED 包括 15 名被试(7 名男性,8 名女性),使用基于国际 10~20 系统的 62 通道 ESI-NeuroScan 系统记录每位被试在实验过程中的脑电数据,采样频率为 1 000 Hz。实验选取 6 个能够诱发不同情绪的视频片段(消极情感 2 个,中性情感 1 个,积极情感 3 个),每个片段 4 min 左右。在实验过程中,被试会在视频播放前 5 s 看到播放开始的提示,每个视频播放结束后,有 45 s 的时间进行自我评估,然后有 15 s 的休息时间。针对每名被试,实验分 3 次进行,每次间隔一周,数据集共包括 45 组数据。本文使用第一次采集的 15 组数据进行实验。

2.2 数据预处理及特征提取

在情感诱发实验中,每两个引起不同情绪的视

频之间,被试仅有 60 s(45 s 自我评估+15 s 休息)的时间进行心情平复,为了尽量保证数据与标签的一致性,本文使用每个视频对应诱发脑电的后 2 min 数据进行模型的训练与结果的验证。

针对实验采集的原始脑电数据,首先降采样至 200 Hz;为了降低噪声带来的干扰,对数据整体进行了低通 75 Hz、高通 1 Hz、陷波 50 Hz 的滤波。在特征提取部分,使用长度为 10、重叠为 5 个样本点的滑动窗口对每个通道的脑电数据进行微分熵计算,在前人的研究中发现,相较于传统的频谱分析提取特征,微分熵表现的性能更优^[11]。微分熵的计算式如下:

$$h(X) = - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \log \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx = \frac{1}{2} \log 2\pi e \sigma^2 \quad (1)$$

其中,输入 X 是一维时间序列,应服从高斯分布 $N(\mu, \sigma^2)$ 。将提取完特征的脑电特征片段切分为不重叠的 1 s 片段,即每个片段的特征长度为 21,通道数为 62,作为一个情感脑电特征样本,大小为 62×21 。由于针对实验中的每个视频,只取后一半的数据作为与标签统一的脑电数据,特征提取完成后,每个被试的样本数量为 1 707 个。

3 域自适应模型及训练设计

在域自适应领域,大多数算法是为了图片的分类而设计的,很少有针对时间序列的域自适应网络模型。少有的一些应用于时间序列的网络模型使用的是循环神经网络(recurrent neural network, RNN),然而,这种网络结构在处理真实问题时速度非常慢。近年来,研究者们发现卷积神经网络(convolutional neural network, CNN)能够在达到与 RNN 同样效果的前提下,相对快速地完成训练和验证任务^[12]。针对时间序列的卷积深度域自适应模型(convolutional deep domain adaptation model for time series data, CoDATS)^[13]在完成对时间序列的研究检测的同时,使用 CNN 进行数据的特征提取,在跨被试的活动检测、手势检测等多个数据集上,与其他单源域迁移算法和基于 RNN 的迁移算法相比具有更高的检测性能。因此,本文将该方法引入情感脑电检测领域,对多源域的情感脑电数据进行分析检测,下面将具体介绍该模型的结构及如何适

用于时间序列数据。

3.1 域自适应方法

首先给出输入数据 $\mathbf{X}$ 和分类标签 $Y=1,2,\dots,L$ 以及 n 个源域,则在输入数据上,有 n 个由 $\mathbf{X} \times Y$ 组成的源域分布,记为 $\mathcal{D}_{S_i}$, 其中 $i \in 1,2,\dots,n$, 还有一个目标域分布 $\mathcal{D}_T$ 。训练时,使用来自各个源域分布 $\mathcal{D}_{S_i}$ 的有标签的样本和来自目标域分布 $\mathcal{D}_T$ 的无标签样本,则可以在每个源域上得到 s_i 个源域样本 S_i (其中 $i \in 1,2,\dots,n$) 和 t 个目标域样本 T :

$$S_i = \left\{ (\mathbf{x}_j, y_j) \right\}_{j=1}^{s_i} \sim \mathcal{D}_{S_i}, \forall i \in 1,2,\dots,n \quad (2)$$

$$T = \left\{ (\mathbf{x}_j) \right\}_{j=1}^t \sim \mathcal{D}_T^X \quad (3)$$

其中,当 $n=1$ 时,以上计算式代表单源域自适应中的样本;当 $n>1$ 时,代表多源域自适应中的样本。在验证模型效果时,使用的测试集 T_{test} 包括 t 个测试样本,这些样本来自目标域分布 $\mathcal{D}_T$,且这些样本不参与模型的训练过程:

$$T_{\text{test}} = \left\{ (\mathbf{x}_j, y_j) \right\}_{j=1}^t \sim \mathcal{D}_T \quad (4)$$

在本实验中,模型针对时间序列进行计算,因此,输入 $\mathbf{X}$ 代表时间序列数据。其中,时间序列可以为单一时间序列,即 $\mathbf{X}=[x_1, x_2, \dots, x_H]$, H 为时间序列长度;也可以为多元时间序列 $\mathbf{X}=[X^1, X^2, \dots, X^K]$, 包括 K 个单一时间序列,每个时间序列长度为 $H^{[14]}$ 。在本实验中,脑电特征样本数据源于 62 个脑电通道,即每个样本包括 62 个相同长度的时间序列, $K=62$ 。

域不变迁移学习方法通常通过训练特征提取网络来提取样本的域不变特征,以达到目的。为了学习到域不变特征,除了特征提取网络,还需要一个对抗部分——域分类器进行对抗。目前,比较普遍使用的域不变方法是 DANN,但它只能完成单源域的域自适应。2017 年, Xie Q Z 等人^[15]对 DANN 做了改进,使其能够接受的域标签不再仅仅是二分类,这就使得 DANN 模型可以进行多源域自适应学习,本文使用的 CoDATS 正是基于该结构实现多源域迁移学习的。

图 1 展示了 CoDATS 的训练及测试流程。CoDATS 模型包括 3 个神经网络部分:特征提取器 F、任务分类器 C 和域分类器 D。在训练过程中,任务分类器和域分类器会进行对抗,而特征提取器正是

基于这两个分类器的对抗进行更新的。其中,特征提取器和任务分类器会不断地更新来提高对带标签的源域样本的分类正确率;域分类器也会在反向传播过程中进行更新,对来自不同域的样本进行分类。同时,特征提取器也会根据域分类器不断进行更新,而特征提取器的更新使得域分类器无法正确地分类样本的来源。这一对抗过程是通过一个梯度反转层 (gradient reversal layer, GRL)^[16]实现的, GRL 被放置在特征提取器和域分类器之间,在反向传播过程中, GRL 使得域分类器向特征提取器传播的梯度反转,从而达到对抗的目的。




图1 CoDATS 的训练及测试流程

3.2 模型结构

起初的 DANN 模型是针对图片数据进行设计的,与有 3 个维度(长、宽和通道数)的图片数据相比,时间序列数据只有两个维度(时间序列和特征),针对本文使用的情感脑电数据来讲,就是时间序列上的微分熵特征(维度一)和 62 个源于不同头皮位置的脑电电极通道(维度二)。

由于 RNN 具有处理时间序列数据等能力,针对时间数据,通常会使用 RNN 来学习。但是 RNN 在处理长距离信息时,在反向传播过程中可能会产生梯度消失或梯度爆炸的问题^[12]。针对这一问题进行改进后,却发现改进的 RNN 在性能上比不上长短期记忆(long short time memory, LSTM)网络。因此,为了改进模型对时间序列的处理能力,CoDATS 采用了类似 CNN 的前馈神经网络——一维卷积神经网络。与 RNN 相比,一维卷积神经网络处理长距离记忆的能力更强^[12]。

CoDATS 的模型结构如图 2 所示。在特征提取器部分,使用了全卷积网络(fully convolutional network, FCN)^[17],该网络在前人关于时间序列迁移学习的研究中已有应用,被证明性能优异^[18]。在任务分类器部分,将 1 层映射层(dense layer)接在特征提取器的 FCN 后面。而在作为对抗的域分类器部分,使用多层感知机(multilayer perceptron,

MLP)^[17]模型, 同样接在特征提取器的 FCN 后面。与任务分类器不同的是, 在特征提取的 FCN 和域分类的 MLP 之间, 有一个梯度反转层, 在训练的反向传播过程中, 其起到反转域分类器向前传播的权重的作用。




图2 CoDATS 模型结构

而针对本文用来作对比的单源域迁移学习模型, 为了保持可比性, 使用与上述 CoDATS 基本一致的模型结构, 不同之处在于, 在单源域迁移学习的输入中, 源域只有一个, 因此, 在域分类器部分, MLP 做的是二分类。同时, 用于对比的不迁移 (no-transfer) 学习模型在结构上也与 CoDATS 基本一致, 不同点为不迁移学习模型不存在域自适应的过程, 在模型中没有对抗, 因此, 不需要模型的域分类器部分; 在训练过程中, 输入数据也完全是带标签的源域数据, 没有不带标签的目标域数据参与。

3.3 模型训练设计

为了实现跨被试迁移学习, 本实验将数据集的 15 名被试分别划分为 15 个独立的域。为了防止测试集和训练集有过度相似的情况, 从每位被试的 15 段不同情绪诱发脑电中, 分别划出 3 个不同情绪的脑电数据片段作为测试集; 将每位被试其余的 12 段脑电数据随机打乱, 按 8:2 的比例将数据划分为训练集、验证集。每个被试都将被作为目标域分别训练跨被试多源域自适应模型, 为了降低结果的随机性, 每个被试作为目标域时, 源域将随机选择并分别进行 30 次跨被试训练, 对应地, 被选作源域的几个被试的数据还将进行无对抗的特征提取和任务分类训练, 训练好的模型在目标域的测试集上进行测试, 测试结果与跨被试训练模型 CoDATS 在目标域的测试集上的测试结果进行对比, 从而评估多源域迁移学习的效果。

当源域数量过多时, 由于域分类器的分类数量

太多, 分类器无法真正达到域分类的目的, 本文将源域数量设置为 2~5 个, 即针对每个目标域被试, 随机从其余的 14 个被试中选出相应数量的被试, 将他们的样本作为多个源域的样本进行训练, 并重复 30 次, 避免训练结果受特定源域被试数据的影响。当源域数量为 1 时, 模型即原始的单源域 DANN 模型。为了与多源域的结果进行对比, 在单源域的条件下, 每个被试作为目标域时, 随机选择 1 个被试作为源域训练 DANN 模型, 并重复 30 次。除源域数量外, 不同模型的超参数设置完全一致。

4 实验结果分析

不同源域数量下各目标域平均正确率如图 3 所示。由图 3 可知, 针对本实验的数据, 当源域只有 1 个, 也就是单源域自适应时, 在目标域上取得的效果最差; 随着源域数量的增加, 模型在目标域上的平均正确率有逐渐上升的趋势; 但随着源域数量的上升, 域分类器的任务变得复杂, 在相同训练参数下, 多源域自适应方法在目标域上的效果不如只在源域上进行训练、在目标域上进行测试得到的效果好。分析原因, 可能是对抗导致训练过程变慢, 在相同训练次数的变量控制下对模型进行对比时, 多源域方法的训练效果不如不迁移的训练效果理想; 并且, 源域数量过多会导致分类器分类效果下降, 影响迁移效果。另外, 可以注意到, 无论源域的数量取多少, 多源域自适应的方法都要比单源域自适应方法在目标域上取得的效果好。




图3 不同源域数量下各目标域平均正确率

在对 1~5 个源域数量下目标域平均正确率的分析中发现, 当源域数量为 3 时, 平均正确率为 53.42%, 标准差为 9.93; 而当源域数量为 4 时, 平均正确率为 53.40%, 标准差为 9.81。与 3 个源域的

情况相比,取4个源域时,平均正确率的差别很小且在不同目标域上结果更稳定。接下来,对源域个数为4的情况进行进一步分析。图4展示了取4个源域时各被试作为目标域情况下的目标域平均正确率,对应的只用4个源域做训练集训练的模型(不迁移)在目标域测试集上的平均正确率,以及随机单源域做训练集(DANN)在目标域测试集上的平均正确率。通过分析发现,多源域训练模型在目标域的测试结果整体高于单源域自适应模型在目标域测试集上的结果,所有被试平均的分类正确率提升了2.69%。




图4 当源域数量为4时,多源域迁移及对应的不迁移单源域在各目标域上的平均正确率

由以上实验结果可知,通过域自适应迁移学习可以在一定程度上解决由被试间差异带来的样本间差异过大问题。而被试间的差异不只是两个域之间的差异,因此单源域迁移学习并不能很好地解决这一问题,通过多源域迁移学习,选择合适的源域数量,可以更好地使模型提取到域不变特征,从而实现跨被试的情感脑电检测。

5 讨论与下一步工作

传统的域自适应方法已经被证明可以进行跨被试的情感脑电识别,并取得了较好的效果。例如,Li H 等人^[19]使用 DANN 在情感脑电数据集上得到了 79.19% 的分类精度。然而,像 DANN 这样的传统域自适应方法只能完成单源域迁移学习。如前文所述,针对有多个源域的场景,被试间的相关性较低,单源域迁移学习可能会造成负迁移现象,影响识别效果。DANN 在本文特征数据集的最高分类精度仅为 75.15%,而采用多源域自适应方法 CoDATS 时,最高分类精度达到了 80.99%。所有被试平均的分类精度提升了 2.69%,证明了多源域自适应方法

的有效性。

在这里,笔者定义的多源域的每个域并不一定是单个被试。如图3所示,通过比较不同源域数量得到的结果发现,当源域数量为4时,效果较好,源域数量继续增加时,可能会因分类数量过多导致分类器训练效果不理想,因此,源域的数量存在最佳范围。划定源域的数量范围也可以解决域分类器的分类数量过多而无法真正实现域分类的问题。

未来的研究将考虑在训练多源域迁移学习模型之前,通过多源域选择算法,计算源域间的相似度,选择合适的被试作为源域,进一步提升多源域自适应迁移学习在跨被试任务上的效果。此外,本文在实验过程中只与单源域方法 DANN 进行了比较,没有对比其他迁移学习方法,如迁移成分分析 (transfer component analysis, TCA)^[20]等,在后续工作中,将通过复现不同的单源域及多源域迁移学习方法,在经过相同处理的情感脑电数据上进行分析比较,进一步得出更加客观、有效的结论。

6 结束语

本文将针对时间序列数据的多源域自适应方法 CoDATS 引入跨被试情感脑电分类问题,并与无域自适应模型和单源域自适应方法进行了对比。结果表明,与单源域自适应相比,将多个被试作为多源域进行域间对抗的方法可以达到较好的提取域不变特征的目的,在目标域上能够获得相对较好的性能。

参考文献:

- [1] WIDGE A S, DOUGHERTY D D, MORITZ C T. Affective brain-computer interfaces as enabling technology for responsive psychiatric stimulation[J]. Brain-Computer Interfaces, 2014, 1(2): 126-136.
- [2] ALGHOWINEM S, GOECKE R, WAGNER M, et al. Multimodal depression detection: fusion analysis of paralinguistic, head pose and eye gaze behaviors[J]. IEEE Transactions on Affective Computing, 2018, 9(4): 478-490.
- [3] CAPONETTI L, BUSCICCHIO C A, CASTELLANO G. Biologically inspired emotion recognition from speech[J]. EURASIP Journal on Advances in Signal Processing, 2011(1): 1-10.
- [4] ARRIAGA O, VALDENEGRO-TORO M, PLOGER P. Real-time convolutional neural networks for emotion and gender classification[J]. arXiv preprint, 2017, arXiv:1710.07557.
- [5] LAN Z R, SOURINA O, WANG L P, et al. Domain adaptation techniques for EEG-based emotion recognition: a comparative study on two public datasets[J]. IEEE Transactions on Cognitive and Developmental Systems, 2019, 11(1): 85-94.
- [6] 娄晓光, 陈兰岚, 宋振振. 基于多源域迁移学习的脑电情感识别[J]. 计算机工程与设计, 2020, 41(7): 2011-2018.

LOU X G, CHEN L L, SONG Z Z. EEG emotion recognition based on multi-source domain transfer learning[J]. Computer Engineering and Design, 2020, 41(7): 2011-2018.

- [7] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [8] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//Proceedings of the 32nd International Conference on Machine Learning. [S.l.:s.n.], 2015: 325-333.
- [9] GUI L, XU R F, LU Q, et al. Negative transfer detection in transductive transfer learning[J]. International Journal of Machine Learning & Cybernetics, 2018, 9(2): 185-197.
- [10] ZHENG W L, LYU B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Transactions on Autonomous Mental Development, 2015, 7(3): 162-175.
- [11] DUAN R N, ZHU J Y, LYU B L. Differential entropy feature for EEG-based emotion classification[C]//Proceedings of the 6th International IEEE/ EMBS Conference on Neural Engineering. Piscataway: IEEE Press, 2013.
- [12] BAI S J, KOLTER J Z, KOLTUN V, et al. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv preprint, 2018, arXiv:1803.01271.
- [13] WILSON G, DOPPA J R, COOK D. Multi-source deep domain adaptation with weak supervision for time-series sensor data[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data. New York: ACM Press, 2020: 6-19.
- [14] FAWAZ H I, FORESTIER G, WEBER J, et al. Deep learning for time series classification: a review[J]. Data Mining and Knowledge Discovery, 2019, 33(4): 917-963.
- [15] XIE Q Z, DAI Z H, DU Y L, et al. Controllbale invariance through adversarial feature learning[J]. arXiv preprint, 2017, arXiv:1705.11122.
- [16] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. Journal of Machine Learning Research, 2017, 17(1): 2096-2030.
- [17] WANG Z G, YAN W Z, OATES T. Time series classification from scratch with deep neural networks: a strong baseline[C]//Proceedings of the 2017 International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2017.
- [18] FAWAZ H I, FORESTIER G, WEBER J, et al. Transfer learning for time series classification[C]//Proceedings of the 2018 IEEE International Conference on Big Data. Piscataway: IEEE Press, 2018.
- [19] LI H, JIN Y M, ZHENG W L, et al. Cross-subject emotion recognition using deep adaptation networks[C]//Proceedings of the 25th International Conference on Neural Information Processing. Cham: Springer, 2018: 403-413.
- [20] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis[J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.

[作者简介]



高寒冰(1996-),女,大连理工大学电子信息与电气工程学部生物医学工程学院硕士生,主要研究方向为脑电和视频分析与处理。



张驰(1987-),男,博士,大连理工大学电子信息与电气工程学部生物医学工程学院讲师,主要研究方向为脑机接口和生物电信号处理。



靳明艳(1998-),女,大连理工大学电子信息与电气工程学部生物医学工程学院硕士生,主要研究方向为脑电信号处理。



肖杨(1997-),女,大连理工大学电子信息与电气工程学部生物医学工程学院硕士生,主要研究方向为脑电的分析与处理。



丛丰裕(1978-),男,博士,大连理工大学电子信息与电气工程学部教授、博士生导师,生物医学工程学院和人工智能学院双聘教授,生物医学工程一级学科博士点负责人,人工智能学院脑科学与类脑智能方向责任教授。中国生物医学工程学会青年工作委员会副主任委员,辽宁省神经科学学会副会长,主要研究方向为脑科学、医学和计算机科学等高度交叉的认知神经科学方法学。