

## 深度学习算法在脑电信号解码中的应用

韦梦莹 李琳玲 黄淦 唐 翡 张治国\*

(深圳大学医学部生物医学工程学院, 医学超声关键技术国家地方联合工程实验室,  
广东省医学信息检测与超声成像重点实验室, 广东 深圳 518060)

**摘要:** 近年来深度学习算法得到飞速发展, 在生物医学工程领域的应用也越来越广泛。其中, 利用深度学习算法从脑电信号 (EEG) 中解码生理、心理或病理状态也受到越来越多的关注。综述近年来深度学习算法在 EEG 解码中的应用, 介绍常用算法、典型应用场景、重要进展和现存的问题。首先, 论述常用于 EEG 解码的几类深度学习算法的基本原理, 包括卷积神经网络、深度信念网络、自编码器和循环神经网络等。然后, 讨论深度学习算法的几个典型 EEG 解码应用场景, 包括脑机接口、情绪与认知识别、疾病辅助诊断。结合应用实例, 归纳深度学习算法在 EEG 解码中的常见问题、解决方案、主要进展和研究趋势。最后, 总结深度学习应用于 EEG 信号解码中仍待解决的一些关键问题, 如参数复杂度、训练时间以及泛化能力等。

**关键词:** 深度学习; 神经网络; 脑电; 解码; 脑机接口

中图分类号: R318 文献标志码: A 文章编号: 0258-8021(2019) 04-0464-09

## Deep Learning in EEG Decoding: A Review

Wei Mengying Li Linling Huang Gan Tang Fei Zhang Zhiguo\*

(School of Biomedical Engineering, Health Science Center, Shenzhen University,  
National Regional Key Technology Engineering Laboratory for Medical Ultrasound,  
Guangdong Provincial Key Laboratory of Biomedical Measurements and Ultrasound Imaging, Shenzhen 518060, China)

**Abstract:** In recent years, deep learning algorithms have been developed rapidly, and they are becoming a powerful tool in biomedical engineering. Especially, there has been an increasing focus on the use of deep learning algorithms for decoding physiological, psychological or pathological states of the brain from EEG. This paper overviews current applications of deep learning algorithms in various EEG decoding tasks, and introduces commonly used algorithms, typical application scenarios, important progresses and existing problems. Firstly, we briefly describe the basic principles of deep learning algorithms used in EEG decoding, including convolutional neural network, deep belief network, auto-encoder and recurrent neural network. Then this paper discusses existing applications of deep learning on EEG, including brain-computer interfaces, cognitive neuroscience and diagnosis of brain disorders. Finally, this paper outlines some key issues that need to be addressed in future applications of deep learning for EEG decoding, such as parameter selection, computational complexity, and the capability of generalization.

**Key words:** deep learning; neural network; EEG; decoding; brain-computer interface

### 引言

脑电 (electroencephalography, EEG) 是大脑自发性、节律性的电活动<sup>[1-2]</sup>。由于 EEG 技术的简便、易操作和信号的高时间分辨率, 因此在临床和基础

科学研究方面发挥了极大的作用。例如, EEG 在临床中可以作为癫痫<sup>[3-4]</sup>、睡眠障碍<sup>[5-6]</sup>等疾病检测和监护的指标。EEG 可用于康复设备的研发中, 如发展脑机接口 (brain-computer interface, BCI) 和神经反馈等技术, 实现患者运动认知等功能的恢复<sup>[7]</sup>。

在以上 EEG 的临床应用和科学研究中,经常需要使用机器学习算法对 EEG 信号进行解码,以便精准识别生理、心理或病理状态。

但是,由于 EEG 信号存在着低信噪比和低空间分辨率等缺点<sup>[8]</sup>,使得机器学习解码的准确率有较大局限,造成实际应用上的诸多困难。随着机器学习近年来的迅猛发展,研究者逐渐将新型高效的机器学习算法(如深度学习)应用于 EEG 解码中,并初步展现出其强于传统机器学习的优势。

下面首先简介应用于 EEG 解码的传统机器学习算法,并根据其在实际应用中的局限性阐述深度学习的优势;然后简述目前已在 EEG 解码中应用的深度学习算法的基本原理;再介绍这些算法在几个典型 EEG 解码应用场景中的应用;最后分析深度学习方法应用在 EEG 解码中面临的问题,并对未来的发展进行展望。

## 1 应用于 EEG 解码的传统机器学习算法

多类经典的机器学习算法,如线性判别分析(linear discriminant analysis, LDA)、支持向量机(support vector machines, SVM)、隐马尔科夫模型(hidden Markov models, HMM)、最邻近分类器( $k$ -nearest neighbor, KNN)和神经网络(artificial neural networks, ANN)等,都在 EEG 解码中得到应用。其中,LDA 和 SVM 是目前 BCI 应用中最流行的分类器,因为其适用于在线和实时的 EEG 解码<sup>[9]</sup>。也有 BCI 研究将 HMM 应用于基于 EEG 想象运动的在线分类<sup>[10]</sup>。神经网络是深度学习的基础,其中只含有 1 或 2 个隐藏层的多层感知器(multi-layer perceptron, MLP),不仅能够应用于 BCI 解码,也能应用于基于 EEG 的癫痫发作的识别<sup>[11]</sup>。

机器学习算法应用于 EEG 解码中也存在着一些局限。例如,在传统的 EEG 解码应用中,特征提取和特征分类是分开进行的,而且在特征提取和降维时会加入较多的人工经验或先验知识,但是这两者在很多应用中是难以获得的。在这种情况下,将特征提取和特征分类合并起来,以纯粹数据驱动的方式在一个步骤中完成对脑电信号进行处理和分类是一种可行的策略,这也是深度学习算法近几年来能够在 EEG 解码的应用中崭露头角的主要原因。下面介绍目前已在 EEG 解码中应用的深度学习算法及其实例。

## 2 应用于 EEG 解码的深度学习算法

深度学习是一种侧重于学习深层次数据模型

的机器学习范式<sup>[12]</sup>,它主要是利用由许多隐藏层组成的深层架构,使用非线性处理单元进行特征提取和变换,在监督(如分类)和/或无监督(如模式分析)的方式下自动学习原始数据的多层次表示。深度学习能够直接从原始信号中理解和学习该信号的复杂表示,并具有自动提取分类所需的高级特征的优势,在过去 10 年中被广泛应用于计算机视觉、语音识别和语言处理等各种领域中<sup>[13]</sup>,并被越来越多地应用于 EEG 信号解码中。目前 EEG 信号解码中常用的深度学习算法主要包含以下几类:卷积神经网络(convolutional neural network, CNN)、深度信念网络(deep belief networks, DBN)、自编码器(auto-encoder, AE)和循环神经网络(recurrent neural network, RNN)等,如图 1 所示。

### 2.1 卷积神经网络

卷积神经网络(CNN)是一种对于图像分类非常有效的人工神经网络模型,主要是它能够利用卷积在数据中学习局部模式。CNN 的典型结构主要包含 3 个层次:卷积层、池化层和完全连接层,其基本框架见图 1(a)。CNN 不同的应用场景需要不同数量的卷积层,例如:只具有一个卷积层的浅层结构,可以应用于语音识别<sup>[14]</sup>;具有多个连续卷积层甚至超过 1 000 层的深层结构,能够发展成为残差网络<sup>[15]</sup>,用于复杂图形(如医学图像)的分类识别。

卷积网络首先通过正向传播计算损失函数。为了训练网络,通过对卷积核中的权重求导,并计算输入图像的梯度对误差进行反向传播。卷积神经网络在多类应用中表现优异,主要是通过 3 个方面帮助改进机器学习系统:系数交互、参数共享、等变表示。此外,卷积的方式提供了一种处理大小可变的输入的方法。

CNN 不仅具有良好的解码性能,还易于进行迭代训练,能较大程度地改善由于跨实验应用出现的信号分布变化造成的解码困难,因此受到 EEG 研究者的青睐。然而,CNN 在应用中也存在着一些问题:首先,CNN 可能会产生假阳性,即过高的置信度可能会导致错误的预测<sup>[16-17]</sup>,这一点在计算机视觉的应用中显得尤为突出;其次,训练 CNN 网络可能需要较多的数据,而且在一个简单的模型上也可能需要很长的时间进行训练;最后,网络中包含很多超参数,如层数或者激活函数的类型,这会导致计算复杂度的增加,也会带来调参的困难。

### 2.2 深度信念网络

深度信念网络(DBN)是一种由受限玻尔兹曼

机 (restricted boltzmann machine, RBM) 组成的经典生成概率模型。RBM 是一种包含可视层和隐藏层的深度概率模型组件,其单元间的连接被限制在不同的层上,在同一层的单元之间无连接。DBN 就是将多个 RBM 堆叠而成,其基本框架见图 1(b)。在 DBN 中,高维度的数据通过可视层单元输入到 RBM 的隐藏层,隐藏层单元根据连接权重识别不同类别的信号特征。对 DBN 中的 RBM 连接权重进行调整,首先是根据可视层和隐藏层的能量函数的概率下降给出,再使用逐层无监督学习来预先训练网络的权重,并利用全局监督学习进行微调。目前,DBN 已经成功应用于降维、图像压缩、数字识别、声学表示等问题中<sup>[18]</sup>。

DBN 不仅能够借助无监督学习的优势来充分利用无标签数据,而且还能够应用于较少样本的数据中<sup>[19]</sup>。因此,DBN 在未来的 EEG 研究中可以发挥特定作用,但仍需要正视其一些潜在问题:首先,作为深度学习网络的一种,DBN 也需要较长的时间去训练;其次,随着层数的增加,内存占用和计算量也随之增加,这是实际应用中不期望的;最后,经过训练的 DBN 都要基于训练的模型进行应用,这会影响其在跨被试应用中的有效传输。

### 2.3 自编码器

自编码器(AE)由一个编码器函数和一个解码器函数组合而成,最简单的结构是与 MLP 类似的前馈非循环的神经网络:具有输入层、输出层以及连接输入输出层的一个或多个隐藏层,其基本框架见图 1(c)。AE 是一种全连接的无监督学习神经网络,它将目标值设置为与输入相等的值,能够在分类任务的预训练中学习更好的数据集表示<sup>[20]</sup>。目前,根据 AE 获取信息和学习表达的能力,存在几种不同的 AE 模型:去噪自编码器(denoising auto-encoders, DAE)<sup>[22]</sup>、稀疏自编码器(sparse auto-encoder, SAE)<sup>[23]</sup>、收缩自编码器(contractive auto-encoder, CAE)等。AE 通常用于降维,但是目前已经越来越广泛地用于学习数据的生成模型。

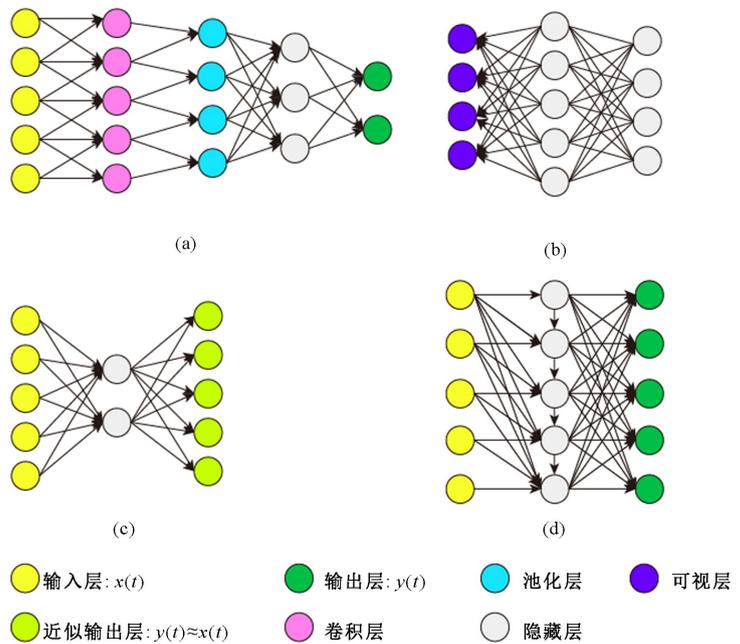


图 1 几类常见深度学习算法的框架 (a) CNN; (b) DBN; (c) AE; (d) RNN

Fig.1 The architectures of several popular deep learning algorithms. (a) CNN; (b) DBN; (c) AE; (d) RNN

AE 可有效识别 EEG 特征,因此 AE 网络越来越多地应用在 EEG 解码中。但是,若将信号直接作为 AE 的输入,则有可能会出现丢失邻近信息的情况,进而影响到信号的解码质量。同时,目前的研究也表明,单纯使用 AE 的某种框架很难满足应用的需求;而结合其他先进的算法进行互补,不仅能够实现性能最优,还能够将网络的框架扩展到其他应用领域中,增强其泛化的能力。

### 2.4 循环神经网络

循环神经网络(RNN)是一类用于处理序列数据的神经网络,较为简单的 RNN 除了输入层、输出层,还包含了一个自连接的隐藏层。不同于 MLP 只能从输入映射到输出,RNN 可以从之前全部的历史输入映射到每个输出,其基本框架见图 1(d)。随着实际应用的需要,研究者提出了许多种 RNN 的框架,比如 Elman 网络<sup>[24]</sup>、Jordan 网络<sup>[25]</sup>、时延神经网络(time delay neural network, TDNN)<sup>[26]</sup>和回声状态网络(echo status network, ESN)<sup>[27]</sup>等。

RNN 不仅能提供前馈连接,还可以提供反馈连接,在处理时间序列<sup>[28-31]</sup>和 EEG 信号<sup>[32-33]</sup>时具有很强的鲁棒性。同时,RNN 可以有效地利用输入序列中的时间信息,因此在 EEG 的研究中有望扮演重要的角色。

### 3 深度学习算法在 EEG 解码中的应用

不同深度学习模型各有其优势和局限性,因此在 EEG 解码中,不同的应用场景和需求会使用不同的深度学习模型。下面将论述在脑机接口、认知心理学和疾病检测等应用领域中所涉及到的深度学习模型。

#### 3.1 脑机接口

在脑机接口(BCI)应用(见表 1)中,为了提高信号质量和特征的可分离性,主要通过以下两种策略进行优化:一是优化特征提取和信号处理的过程,二是选择更为合适的分类器以提高分类精度。

从第一种策略角度,回顾目前的深度学习算法在 BCI 中的应用,发现能够应用于优化特征提取和信号处理过程的深度学习算法只有 DBN 和 RNN。DBN 的优势表现在可以通过参数共享来减少参数、减少计算负担,以无监督的方式来利用大量无标签的数据。例如,Ren 等<sup>[34]</sup>提出一种在 DBN 网络中结合卷积架构实现参数共享的卷积深度信念网络(convolutional deep belief networks, CDBN),应用于 BCI 竞赛数据集上的 EEG 信号特征学习;结果显示,与传统的特征提取算法相比,使用 CDBN 学习的特征具有更好的性能。而 RNN 可以在预处理阶段

表 1 深度学习算法在 BCI 应用中的总结

Tab.1 A summary of deep learning algorithms applied in BCI

神经网络	应用	特征	参考文献
AE	想象运动分类	频谱能量	[20]
	手指运动检测	功率谱密度	[21]
DBN	特征提取	时域幅值	[34]
	ERP 检测	时域波形	[35]
	运动起始视觉诱发电位检测	压缩感知特征	[36]
	想象运动分类	FFT 能量	[37]
	图像连续视觉呈现分类	时-频特征	[38]
RNN	想象运动信号滤波	时域幅值	[39]
CNN	P300、ERN、MRCP、SMR 的分类	时域幅值	[40]
	SSVEP 分类	FFT 能量	[41]
	P300 的检测	时域幅值	[42]
	想象运动分类	时域幅值	[43-44]
	运动检测	时域幅值	[45]
	Eriksen Flanker 任务和在线控制机器人	时域幅值	[46]
	想象运动分类	FFT 能量图	[47]
	想象运动分类	时-频特征	[48]

增强 EEG 信号,从而提高 BCI 的性能;此外,RNN 不会对混合在待滤波信号中的噪声性质做任何的假设,因此十分适用于处理类似 EEG 信号这样的混合未知特性噪声的信号。例如,Gandhi 等<sup>[39]</sup>受量子力学启发,提出了一种新型神经信息处理架构,即量子递归神经网络(recurrent quantum neural network, RQNN)。当 RQNN 应用于 EEG 信号预处理以增强 EEG 的信噪比时,充当的是滤波器的角色,与仅使用原始 EEG 或使用 Savitzky-Golay 滤波的 EEG 的跨实验结果相比,利用具有被试特异性的 RQNN 对 EEG 进行滤波,能够显著提高 BCI 的性能。

从第二种策略来看,选择合适的深度学习算法模型,一方面是为了提高分类精度,另一方面是为了拓展跨范式和跨被试的应用。纵观目前深度学习应用的发展趋势,由于深度学习能够从原始信号中自动提取应用于分类的特征,因此通常选择在时域进行分析。例如,Lawhern 等<sup>[40]</sup>利用含有 4 层紧凑全卷积的 EEGNet 作为一种通用的模型,对 4 种不同的 BCI 范式(即 P300、错误相关负反馈(error-related negativity responses, ERN)、运动相关皮层电位(movement-related cortical potentials, MRCP)和感觉运动节律(sensory motor rhythms, SMR))进行分类,为跨任务和跨被试提供了较好的帮助。随着研究和应用发展的不断深入,延伸出了可以利用频域或时频域进行分析的方法。比如,Cecotti 等<sup>[41]</sup>提出了一种新的卷积神经网络结构,即在两个隐藏层之间加入快速傅里叶变换(fast Fourier transform, FFT),使得信号分析从网络内部的时域变换到频域上。这种策略对 5 种不同类型的稳态视觉诱发电位(steady-state visual evoked potential, SSVEP)的平均识别率为 95.61%,胜过了其他经典的神经网络架构。因为部分 BCI 范式在频域和时频域的特征比在时域的特征更具有典型性和区分性,所以变换到频域可以降低特征维度,减少计算复杂度。

#### 3.2 认知心理学

EEG 可以用于评估和理解大脑中与心理、生理状态相关的变化,如不同的精神状态——焦虑、抑郁、疼痛<sup>[49]</sup>等,还可以作为探究认知过程的神经机制的有效工具(见表 2)。

在基于 EEG 的情绪识别研究中,利用传统的分类器进行应用是比较困难的,主要原因是不同情绪的边界较为模糊,如何提取并有效识别与情绪相关

表2 深度学习算法在认知心理学研究中的总结

Tab.2 A summary of deep learning algorithms applied in cognitive neuroscience

神经网络	应用	特征	参考文献
AE	情绪识别分类	功率谱密度、微分熵	[50]
	情绪识别分类	能量谱	[51]
	情绪识别分类	微分熵	[52]
	疲劳状态评估	功率谱	[53]
DBN	情绪识别分类	微分熵	[54]
	驾驶员疲劳状态分类	AR 特征	[55]
RNN	嗅觉感知分类	功率谱密度、AR 特征	[56]
	精神负荷分类	频谱能量的地形图	[57]
CNN	预测驾驶表现相关的驾驶员认知状态	频域能量	[58]
	预测驾驶员的心理状态	时域幅值	[59]
	无意识期间的大脑活动检测	时-频特征	[60]
	情绪识别分类	相关系数矩阵	[61]
	情绪识别分类	时域幅值	[62]
	节奏感知分类	频谱能量	[63]
	跨任务的心理评估	时-频特征	[64]
	疲劳驾驶识别	时域特征	[65]

的特征是一个巨大的挑战。因此,研究者提出使用深度学习利用多尺度特征对情绪进行分类识别。比如,Zheng 等<sup>[54]</sup>以 EEG 的微分熵特征作为 DBN 的输入,并在网络中整合了 HMM,从而准确捕捉更为可靠的情感状态切换,对情绪进行二分类(正面、负面)。与 DBN-HMM、DBN、SVM 和 KNN 的分类精度相比,无论是 DBN 模型还是结合 HMM 的 DBN-HMM 模型,都提高了情绪分类的准确性。同时,DBN 能够进行特征选择,筛选出不相关的特征,以取得更好的结果。

除了情绪识别,深度学习的一个重要 EEG 应用是识别驾驶员的疲劳程度。Chai 等<sup>[55]</sup>提出使用自回归模型对 EEG 信号进行特征提取,并将提取到的特征作为稀疏 DBN 的输入。与其他算法的结果相比,稀疏 DBN 具有显著高的分类性能。Zeng 等<sup>[59]</sup>提出使用 CNN 结合残差网络对驾驶员的心理状态进行预测,结果显示提出的方法具有较好的预测性能。

在认知心理学领域的研究中,频域特征往往比时域特征更具有区分性。因此,在未来的研究中,可以针对不同的认知状态,对 EEG 信号进行变换分

析,从而提高解码性能,并降低实际应用成本。

### 3.3 疾病检测

在临床应用中,EEG 可以对多种神经和精神疾病进行辅助诊断,如阿尔兹海默症 (Alzheimer's disease)<sup>[66]</sup>、癫痫 (epilepsy)<sup>[67]</sup> 以及精神分裂症 (schizophrenia)<sup>[68]</sup> 等,它还可以用于与睡眠诊断相关的睡眠阶段分类(见表 3)。

在癫痫的检测与分类中,Turner 等<sup>[70]</sup>提出应用 DBN 对癫痫发作进行检测,可以达到较合适的计算复杂度和较好的准确性。同时,在使用其他患者的数据训练得到的模型来测试新来患者的情况下(即所谓的“留一法”),DBN 的表现优于使用相同特征集的逻辑回归算法。除了对癫痫波形进行检测以辅助临床需要外,深度学习算法还可以通过对局灶性癫痫患者进行分类,以达到服务临床手术决定的目的。Taqi 等<sup>[72]</sup>应用 3 种不同的 CNN 模型,对局灶性和非局灶性癫痫患者的脑电信号进行分类,不仅能够使用较少的训练数据达到最佳的分类性能,还可以提升计算速度以减少分类过程所需的时间,从而以最佳分类性能为局灶性癫痫疾病诊断提供帮助。

在睡眠障碍相关的研究中,深度学习被认为是在人类睡眠阶段进行分类时最具前景的分类器之一<sup>[73]</sup>,目前应用于 EEG 解码的多数为 RNN。例如,Hsu 等<sup>[73]</sup>利用 Elman RNN 对人类睡眠阶段进行分类,并与广泛应用于生物医学分类的前馈神经网络

表3 深度学习算法在临床疾病检测应用中的总结

Tab.3 A summary of deep learning algorithms applied in clinical research

神经网络	应用	特征	参考文献
AE	癫痫发作检测	跨能量矩阵	[69]
DBN	癫痫发作检测	时域尖峰	[70]
	异常波形检测	时域波形	[71]
RNN	睡眠阶段分类	能量特征(波形)	[73]
	癫痫发作检测	时域幅值	[75]
	癫痫发作检测	时域幅值	[76]
	癫痫发作检测	时域特征	[77]
	ICU 病房患者的镇静检测	频谱特征	[78]
CNN	癫痫发作检测	时域波形	[79-80]
	癫痫波形检测	时域幅值	[81]
	新生儿癫痫发作检测	时域幅值	[82]
	帕金森自动检测	时域幅值	[83]
	痴呆阶段分类	功率谱图像	[84]
	自闭症患者疗效预测	时域幅值	[85]

(feedforward neural network, FNN) 和主要用于处理分类问题的概率神经网络 (probabilistic neural network, PNN) 进行性能的比较,结果显示,RNN 可以使用单通道 EEG 能量特征对睡眠阶段进行高效准确的分类。此外,结合 DBN 和 HMM 的方法也被成功应用在基于 EEG 的睡眠阶段分类中<sup>[74]</sup>。

基于以上研究,可以发现深度学习应用于疾病诊断已有初步成果。但是,由于多数临床数据集较小,对现有模型的多中心大样本泛化能力还是巨大的挑战。另外,目前的研究多为离线测试而非在线应用,但在实际的临床应用中更希望能够及时给出结果以辅助临床诊断。因此,未来需要进行更多在线研究,并验证这些深度学习方法具有足够的计算效率来满足实时应用。

## 4 深度学习算法应用中面临的问题

尽管深度学习在 EEG 解码中已经取得了一些成功,但它的应用依旧面临着许多挑战。除了由于 EEG 信号高维度和低信噪比的特性造成的解码困难,还有来自复杂的实际应用场景和算法本身的局限性造成的研究与发展的困难。

1) 目前仍然缺乏大样本的标注 EEG 数据集,这使得现有深度学习算法的效果未能得到完全的体现。深度学习的效能极大地依赖于高质量的标注数据,而现有研究特别是临床研究中,标注完备准确的脑电数据仍稀缺,且样本量都较少。在未来的研究中,除了采集整理大样本脑电数据外,还需要应用迁移学习等新型机器学习算法,弥补样本量小这一缺陷。

2) 在多中心和纵向数据上,现有模型的泛化能力和可重复性仍然缺乏严格的验证。脑电数据受设备和实验人员的影响较大,因此不同实验室/医院和主试采集的脑电数据呈现不同的特性。而且,脑电数据有极大的个体间差异性和个体内差异性,但现有模型多是基于同一中心、同一时间点采集的数据发展起来的,其效果需要在多中心纵向数据上进行检验,以确保模型有较好的泛化能力和可重复性。

3) 深度学习模型的复杂度仍然较高,实时解码较困难。深度学习可以根据应用不断调整模型的深度、复杂度和激活函数,虽然可提升模型的性能,但也造成了训练时间增长、训练速度下降、实时执行困难等缺陷。这些问题会增加 EEG 信号解码的资源,限制其实际应用(如 BCI)。

4) 深度学习在脑电研究中的可解释性需要加强。在基于脑电的心理学和医学研究中,分类准确率并非是最主要的目标。通过机器学习模型,得到对心理或疾病状态有预测力的脑电特征,以揭示神经机制,是此类研究的一个重要目标。因此,深度学习模型需要增加可解释性,从而使其成为研究神经机制的一个有力工具。

5) 现有深度学习模型缺乏在无标签脑电数据上的应用。在现有研究中,使用的 EEG 数据集中多数为有标签数据,因此深度学习模型多是有监督学习。但是,仍有大量脑电数据是无标签或标签不准确的(特别是在医学研究中)。因此,无监督或半监督的深度学习方法也需要不断发展,使其应用于标注缺失或不准确的脑电数据中,如对疾病进行分型。

综上所述,目前深度学习在 EEG 解码的应用以 CNN、DBN、AE、RNN 的网络框架为主,在 BCI 的几种经典范式分类、情绪疲劳等认知状态的分类预测以及临床癫痫发作检测和睡眠分类中已有很多成功的应用。但现有的研究还有很多问题,如缺乏多中心验证、复杂度高等。为了克服深度学习在脑电解码中的局限和问题,需要数据采集整理、深度学习算法改进和脑科学机制进展等几方面的合力。在未来的研究工作中,需要不断发展稳健和高效的深度学习算法,以适应实时在线应用的需求,并适用于多中心、大样本的多源纵向数据集。另外,单纯的某一类深度学习算法或无法满足应用的需求。因此,除了优化模型的架构外,还可以将几种不同的模型整合起来,利用集成学习和强化学习的思路,综合利用不同模型的优点,以达到更高的性能。

## 参考文献

- [1] Sheehy N. Electroencephalography: Basic principles, clinical applications and related fields [J]. J Neurol Neurosurg Psychiatry, 1984, 47(6): 654-654.
- [2] Buzsaki G, Draguhn A. Neuronal oscillations in cortical networks [J]. Science, 2004, 304(5679): 1926-1929.
- [3] Ghshdastidar S, Adeli H, Dadmehr N. Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection [J]. IEEE Trans Biomed Eng, 2007, 54(9): 1545-1551.
- [4] Adeli H, Zhou Ziqin, Dadmehr N. Analysis of EEG records in an epileptic patient using wavelet transform [J]. J Neurosci Methods, 2003, 123(1): 69-87.
- [5] Charbonnier S, Zoubek L, Lesecq S, et al. Self-evaluated automatic classifier as a decision-support tool for sleep/wake staging [J]. Comput Biol Med, 2011, 41(6): 380-389.

- [ 6 ] Sinha RK. EEG power spectrum and neural network based sleep-hypnogram analysis for a model of heat stress [J]. *J Clin Monit Comput*, 2008, 22(4): 261-268.
- [ 7 ] McFarland DJ, Wolpaw JR. EEG-based brain-computer interfaces [J]. *Curr Opin Biomed Eng*, 2017, 4: 194-200.
- [ 8 ] McMenamin BW, Shackman AJ, Greischar LL, et al. Electromyogenic artifacts and electroencephalographic inferences revisited [J]. *Neuroimage*, 2011, 54(1): 4-9.
- [ 9 ] Lotte F, Bougrain L, Cichocki A, et al. A review of classification algorithms for EEG-based brain-computer interfaces: A 10-year update [J]. *J Neural Eng*, 2018, 15(3): 031005.
- [ 10 ] Obermaier B, Guger C, Neuper C, et al. Hidden markov models for online classification of single trial EEG data [J]. *Pattern Recognit Lett*, 2001, 22(12): 1299-1309.
- [ 11 ] Osman AH, Alzahrani AA. New approach for automated epileptic disease diagnosis using an integrated self-organization map and radial basis function neural network algorithm [J]. *IEEE Access*, 2019, 7: 4741-4747.
- [ 12 ] Palm RB. Prediction as a candidate for learning deep hierarchical models of data [D]. Copenhagen: Technical University of Denmark, 2012.
- [ 13 ] Lu Na, Li Tengfei, Ren Xiaodong, et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2017, 25(6): 566-576.
- [ 14 ] Abdelhamid O, Mohamed A, Jiang Hui, et al. Convolutional neural networks for speech recognition [J]. *IEEE Trans Audio Speech Lang Process*, 2014, 22(10): 1533-1545.
- [ 15 ] Chen LC, Papandreou G, Kokkinos I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs [J]. *IEEE Trans Pattern Anal Mach Intell*, 2018, 40(4): 834-848.
- [ 16 ] Szegedy C, Zaremba W, Sutskever I, et al. Intriguing properties of neural networks [J]. *arXiv*, 2013, 1312: 6199.
- [ 17 ] Guo Yanming, Liu Yu, Oerlemans A, et al. Deep learning for visual understanding: A review [J]. *Neurocomputing*, 2016, 187: 27-48.
- [ 18 ] Kuremoto T, Kimura S, Kobayashi K, et al. Time series forecasting using a deep belief network with restricted Boltzmann machines [J]. *Neurocomputing*, 2014, 137(15): 47-56.
- [ 19 ] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-436.
- [ 20 ] Li Junhua, Struzik Z, Zhang Liqing, et al. Feature learning from incomplete EEG with denoising autoencoder [J]. *Neurocomputing*, 2015, 165: 23-31.
- [ 21 ] Wang Zuoyuan, Lyu S, Schalk G, et al. Deep feature learning using target priors with applications in ECoG signal decoding for BCI [C] // Proceedings of the Twenty-third International Joint Conference on Artificial Intelligence. Beijing: AAAI Press, 2013, 1785-1791.
- [ 22 ] Vincent P, Larochelle H, Lajoie I, et al. Stacked Denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion [J]. *J Mach Learn Res*, 2010, 11: 3371-3408.
- [ 23 ] Hasperue W. The master algorithm: how the quest for the ultimate learning machine will remake our world [J]. *J Comput Sci Tech*, 2015, 15(2): 157-158.
- [ 24 ] Elman JL. Finding structure in time [J]. *Cogn Sci*, 1990, 14(2): 179-211.
- [ 25 ] Ruiz L, Cuellar M, Calvo-Flores M. An application of non-linear autoregressive neural networks to predict energy consumption in public buildings [J]. *Energies*, 2016, 9(9): 684-684.
- [ 26 ] Lang KJ, Waibel A, Hinton GE. A time-delay neural network architecture for isolated word recognition [J]. *Neural Networks*, 1990, 3(1): 23-43.
- [ 27 ] Maass W, Natschläger T, Markram H. Real-time computing without stable states: A new framework for neural computation based on perturbations [J]. *Neural computation*, 2002, 14(11): 2531-2560.
- [ 28 ] Li Xiaodong, Ho JKL, Chow TWS. Approximation of dynamical time-variant systems by continuous-time recurrent neural networks [J]. *IEEE Trans Circuits Syst II Express Briefs*, 2005, 52(10): 656-660.
- [ 29 ] Feldkamp LA, Puskorius GV. A signal processing framework based on dynamic neural networks with application to problems in adaptation, filtering, and classification [J]. *Proc IEEE*, 1998, 86(11): 2259-2277.
- [ 30 ] Hüskens M, Stagge P. Recurrent neural networks for time series classification [J]. *Neurocomputing*, 2003, 50: 223-235.
- [ 31 ] Jin L, Nikiforuk PN, Gupta MM. Approximation of discrete-time state-space trajectories using dynamic recurrent neural networks [J]. *IEEE Trans Automat Contr*, 1995, 40(7): 1266-1270.
- [ 32 ] Schafer AM, Zimmermann H. Recurrent neural networks are universal approximators [J]. *Int J Neural Syst*, 2007, 17(4): 253-263.
- [ 33 ] Guler NF, Ibeyli ED, Guler I. Recurrent neural networks employing Lyapunov exponents for EEG signals classification [J]. *Expert Syst Appl*, 2005, 29(3): 506-514.
- [ 34 ] Ren Yuanfang, Wu Yan. Convolutional deep belief networks for feature extraction of EEG signal [C] // 2014 International Joint Conference on Neural Networks (IJCNN). Beijing: IEEE, 2014, 2850-2853.
- [ 35 ] Li Jingcong, Yu Zhu Liang, Gu Zhenghui, et al. A hybrid network for ERP detection and analysis based on restricted boltzmann machine [J]. *IEEE Trans Neural Syst Rehab Eng*, 2018, 26(3): 563-572.
- [ 36 ] Ma Teng, Li Hui, Yang Hao, et al. The extraction of motion-onset VEP BCI features based on deep learning and compressed sensing [J]. *J Neurosci Methods*, 2017, 275: 80-92.
- [ 37 ] Lu Na, Li Tengfei, Ren Xiaodong, et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines [J]. *IEEE Trans Neural Syst Rehab Eng*, 2017, 25(6): 566-576.
- [ 38 ] Ahmed S, Merino LM, Mao Zijing, et al. A deep learning

- method for classification of images RSVP events with EEG data. [C] //2013 IEEE Global Conference on Signal and Information Processing. Austin;IEEE, 2014: 33-36.
- [39] Gandhi V, Prasad G, Coyle D, et al. Quantum neural network-based EEG filtering for a brain-computer interface [J]. IEEE Trans Neural Netw Learn Syst, 2014, 25(2): 278-288.
- [40] Lawhern VJ, Solon AJ, Waytowich NR, et al. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces[J]. J Neural Eng, 2018, 15(5): 056013.
- [41] Cecotti H. A time-frequency convolutional neural network for the offline classification of steady-state visual evoked potential responses [J]. Pattern Recognit Lett, 2011, 32(8): 1145-1153.
- [42] Cecotti H, Graser A. Convolutional neural networks for P300 detection with application to brain-computer interfaces [J]. IEEE Trans Pattern Anal Mach Intell, 2011, 33(3): 433-445.
- [43] Tang Zhichuan, Li Chao, Sun Shouqian. Single-trial EEG classification of motor imagery using deep convolutional neural networks [J]. Optik, 2017, 130:11-18.
- [44] Hartmann KG, Schirmer RT, Ball T. Hierarchical internal representation of spectral features in deep convolutional networks trained for EEG decoding [C] // International Conference on Brain Computer Interface. South Korea; Gangwon, 2018: 1-6.
- [45] Nurse E, Mashford BS, Yepes AJ, et al. Decoding EEG and LFP signals using deep learning [C] // Proceedings of the ACM International Conference on Computing Frontiers. Como; ACM, 2016: 259-266.
- [46] Völker M, Schirmer RT, Fiederer LDJ, et al. Deep transfer learning for error decoding from non-invasive EEG [C] //2018 6th International Conference on Brain-Computer Interface (BCI). Gangwon; IEEE, 2018: 1-6.
- [47] Abbas W, Khan NA. DeepMI: deep learning for multiclass motor imagery classification [C]//Proceedings of the 2018 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Hawaii;IEEE, 2018: 219-222.
- [48] Xu Baoguo, Zhang Linlin, Song Aiguo, et al. Wavelet Transform Time-Frequency Image and Convolutional Network-Based Motor Imagery EEG Classification[J]. IEEE Access, 2019, 7: 6084-6093.
- [49] Peng Weiwei, Hu Li, Zhang Zhiguo, et al. Changes of spontaneous oscillatory activity to tonic heat pain [J]. PLoS ONE, 2014, 9(3):e91052.
- [50] Liu Wei, Zheng Weilong, Lu Baoliang. Multimodal emotion recognition using multimodal deep learning [J]. arXiv, 2016, 1602:08225.
- [51] Jirayucharoensak S, PanNgum S, Israsena P. EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation [J]. Scientific World Journal, 2014, 2014:627892.
- [52] Chai Xin, Wang Qisong, Zhao Yongping, et al. Unsupervised domain adaptation techniques based on auto-encoder for non-stationary EEG-based emotion recognition [J]. Comput Biol Med, 2016, 79:205-214.
- [53] Wu EQ, Peng XY, Zhang CZ, et al. Pilots' Fatigue Status Recognition Using Deep Contractive Autoencoder Network [J]. IEEE Trans Instrum Meas, 2019, 1-13.
- [54] Zheng Weilong, Zhu Jjiayi, Peng Yong, et al. EEG-based emotion classification using deep belief networks [C] //IEEE International Conference on Multimedia and Expo (ICME). Chengdu; IEEE, 2014: 1-6.
- [55] Chai Rifai, Ling SH, San PP, et al. Improving EEG-based driver fatigue classification using sparse-deep belief networks [J]. Front Neurosci, 2017, 11:103-103.
- [56] Saha A, Konar A, Chatterjee A, et al. EEG analysis for olfactory perceptual-ability measurement using a recurrent neural classifier [J]. IEEE Trans Hum Mach Syst, 2014, 44(6): 717-730.
- [57] Bashivan P, Rish I, Yeasin M, et al. Learning representations from EEG with deep recurrent-convolutional neural networks [J]. arXiv, 2015, 1511:06448.
- [58] Hajinoroozi M, Mao Zijing, Jung TP, et al. EEG-based prediction of driver's cognitive performance by deep convolutional neural network [J]. Signal Process Image Commun, 2016, 47: 549-555.
- [59] Zeng Hong, Yang Chen, Dai Guojun, et al. EEG classification of driver mental states by deep learning [J]. Cogn Neurodyn. 2018, 12(6):597-606.
- [60] Lee M, Yeom SK, Baird B, et al. Spatio-temporal analysis of EEG signal during consciousness using convolutional neural network [C]//2018 6th International Conference on Brain-Computer Interface (BCI). Gangwon; IEEE, 2018:1-3.
- [61] Han Mei, Xu Xiangmin. EEG-based emotion classification using convolutional neural network [C] //2017 International Conference on Security, Pattern Analysis, and Cybernetics. Shenzhen; IEEE, 2017: 130-135.
- [62] Tripathi S, Acharya S, Sharma RD, et al. Using deep and convolutional neural networks for accurate emotion classification on DEAP dataset [C] // Proceedings of the 29th AAAI Conference on Artificial Intelligence. San Francisco: AAAI Press, 2017: 4746-4752.
- [63] Stober S, Cameron DJ, Grahm JA. Using convolutional neural networks to recognize rhythm stimuli from electroencephalography recordings [C] //Neural Information Processing Ssystems. Montreal; MIT Press Cambridge, 2014: 1449-1457.
- [64] Zhang Pengbo, Wang Xue, Zhang Weihang, et al. Learning Spatial - Spectral - Temporal EEG Features With Recurrent 3D Convolutional Neural Networks for Cross-Task Mental Workload Assessment[J]. IEEE Trans Neural Syst Rehab Eng, 2019, 27(1): 31-42.
- [65] Gao Zhongke, Wang Xinmin, Yang Yuxuan, et al. EEG-based spatio-temporal convolutional neural network for driver fatigue evaluation[J]. IEEE Trans Neural Netw Learn Syst, 2019, 1-9.
- [66] Aljumeily D, Iram S, Vialatte F, et al. A novel method of early diagnosis of Alzheimer's disease based on EEG signals [J]. Scientific World Journal, 2015, 2015:931387.

- [67] Samiee K, Kovacs P, Gabbouj M. Epileptic seizure classification of EEG time-series using rational discrete short-time fourier transform [J]. *IEEE Trans Biomed Eng*, 2015, 62(2): 541-552.
- [68] Shim M, Hwang HJ, Kim DW, et al. Machine-learning-based diagnosis of schizophrenia using combined sensor-level and source-level EEG features [J]. *Schizophr Res*, 2016, 176(2-3): 314-319.
- [69] Qi Yu, Wang Yueming, Zhang Jianmin, et al. Robust deep network with maximum correntropy criterion for seizure detection [J]. *Biomed Res Int*, 2014, 2014:703816.
- [70] Turner JT, Page A, Mohsenin T, et al. Deep belief networks used on high resolution multichannel electroencephalography data for seizure detection [J]. *arXiv*, 2017, 1708:08430.
- [71] Wulsin D, Gupta JR, Mani R, et al. Modeling electroencephalography waveforms with semi-supervised deep belief nets; fast classification and anomaly measurement [J]. *J Neural Eng*, 2011, 8(3): 036015.
- [72] Taqi AM, AL-Azzo F, Mariofanna M, et al. Classification and discrimination of focal and non-focal EEG signals based on deep neural network [C] //International Conference on Current Research in Computer Science and Information Technology. Slemani: IEEE, 2017; 86-92..
- [73] Hsu YL, Yang YT, Wang JS, et al. Automatic sleep stage recurrent neural classifier using energy features of EEG signals [J]. *Neurocomputing*, 2013, 104:105-114.
- [74] Langkvist M, Karlsson L, Loutfi A. Sleep stage classification using unsupervised feature learning [J]. *Advances in Artificial Neural Systems*, 2012,2012: 107046.
- [75] Rajaguru H, Prabhakar SK. A Unique Approach to epilepsy classification from EEG signals using dimensionality reduction and neural networks [J]. *Circuits Syst*, 2016, 7(08): 1455-1464.
- [76] Ahmedt-Aristizabal D, Fookes C, Nguyen K, et al. Deep classification of epileptic signals [C]//Proceedings of the 2018 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Hawaii:IEEE, 2018; 332-335.
- [77] Hussein R, Palangi H, Ward RK, et al. Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals [J]. *Clinical Neurophysiology*, 2019, 130(1): 25-37.
- [78] Sun Haoqi, Nagaraj SB, Akeju O, et al. Brain monitoring of sedation in the intensive care unit using a recurrent neural network [C] //Proceedings of the 2018 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Hawaii:IEEE, 2018; 4772-4775.
- [79] Page A, Shea C, Mohsenin T. Wearable seizure detection using convolutional neural networks with transfer learning [C] //2016 IEEE International Symposium on Circuits and Systems (ISCAS). Montréal: IEEE, 2016; 1086-1089.
- [80] Acharya UR, Oh SL, Hagiwara Y, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals [J]. *Comput Biol Med*, 2018, 100: 270-278.
- [81] Thomas J, Comoretto L, Jin Jing, et al. EEG classification via convolutional neural network-based interictal epileptiform event detection [C] //Proceedings of the 2018 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Hawaii:IEEE, 2018; 3148-3151.
- [82] O'Shea A, Lightbody G, Boylan G, et al. Investigating the impact of CNN depth on neonatal seizure detection performance [C] //Proceedings of the 2018 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Hawaii:IEEE, 2018; 5862-5865.
- [83] Chanbon S, Thorey V, Arnal PJ, et al. A deep learning architecture to detect events in EEG signals during sleep [J]. *arXiv*, 2018, 1807:05981.
- [84] Ieracitano C, Mammone N, Bramanti A, et al. A Convolutional Neural Network approach for classification of dementia stages based on 2D-spectral representation of EEG recordings [J]. *Neurocomputing*, 2019, 323: 96-107.
- [85] Li Yitong, Murias M, Major S, et al. Targeting EEG/LFP synchrony with neural nets [C] //The 31st Annual Conference on Neural Information Processing Systems. Long Beach; Curran Associates, 2017; 1-11.