

基于脑电信号深度迁移学习的驾驶疲劳检测

王 斐^{*①} 吴仕超^① 刘少林^② 张亚徽^② 魏 颖^②

^①(东北大学机器人科学与工程学院 沈阳 110169)

^②(东北大学信息科学与工程学院 沈阳 110819)

摘 要: 脑电信号一直被誉为疲劳检测的“金标准”, 驾驶者的精神状态可通过对脑电信号的分析得到。但由于脑电信号具有非线性、非平稳性和空间分辨率低等特点, 传统的机器学习方法在运用脑电信号进行疲劳检测时还存在识别率低, 特征提取操作繁琐等不足。为此, 该文基于脑电信号的电极-频率分布图, 提出运用深度迁移学习实现的驾驶疲劳检测方法, 即搭建深度卷积神经网络, 并利用SEED脑电情绪数据集对其进行预训练, 然后通过迁移学习方法将其用于驾驶疲劳检测。实验结果表明, 卷积神经网络模型能够很好地从电极-频率分布图中获得与疲劳状态相关的特征信息, 达到较好的识别效果。此外, 基于迁移学习策略可以将训练好的深度网络模型迁移到其他识别任务上, 有助于推动脑电信号在驾驶疲劳检测系统中的应用。

关键词: 脑电信号; 疲劳检测; 迁移学习; 卷积神经网络; 电极-频率分布图

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2019)09-2264-09

DOI: [10.11999/JEIT180900](https://doi.org/10.11999/JEIT180900)

Driver Fatigue Detection Through Deep Transfer Learning in an Electroencephalogram-based System

WANG Fei^① WU Shichao^① LIU Shaolin^② ZHANG Yahui^② WEI Ying^②

^①(Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110169 China)

^②(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: ElectroEncephaloGram (EEG) is regarded as a “gold standard” of fatigue detection and drivers’ vigilance states can be detected through the analysis of EEG signals. However, due to the characteristics of non-linear, non-stationary and low spatial resolution of EEG signals, traditional machine learning methods still have the disadvantages of low recognition rate and complicated feature extraction operations in EEG-based fatigue detection task. To tackle this problem, a fatigue detection method with transfer learning based on the Electrode-Frequency Distribution Maps (EFDMs) of EEG signals is proposed. A deep convolutional neural network is designed and pre-trained with SEED dataset, and then it is used for fatigue detection with transfer learning strategy. Experimental results show that the proposed convolutional neural network can automatically obtain vigilance related features from EFDMs, and achieve much better recognition results than traditional machine learning methods. Moreover, based on the transfer learning strategy, this model can also be used for other recognition tasks, which is helpful for promoting the application of EEG signals to the driver fatigue detection system.

Key words: ElectroEncephaloGram (EEG); Fatigue detection; Transfer learning; Convolutional neural network; Electrode-frequency distribution maps

收稿日期: 2018-09-20; 改回日期: 2019-02-17; 网络出版: 2019-03-21

*通信作者: 王斐 wangfei@mail.neu.edu.cn

基金项目: 中央高校基本科研业务费专项基金(N172608005), 辽宁省科学事业公益研究基金(20170021)

Foundation Items: The Fundamental Research Funds for the Central Universities (N172608005), The Scientific Research Foundation for Public Welfare of Liaoning Province (20170021)

1 引言

疲劳是一个相当复杂的生理、心理状态, 通常可分为脑力疲劳和体力疲劳。一般情况下, 脑力疲劳与体力疲劳是交织在一起同时出现的, 通常所说的脑力疲劳或体力疲劳分别是指以脑力疲劳或体力疲劳为主的主观疲劳感觉^[1]。脑力疲劳往往是由大脑长时间的认知活动积累所致, 大脑疲劳后认知功

能受限、警觉性水平下降。驾驶员在长时间的驾驶过程中容易同时引发两种疲劳状态,但以脑力疲劳为主,当前有关驾驶疲劳检测的研究也主要集中于脑力疲劳。因此,为脑力疲劳监测提供一种客观有效的指标,以实现驾驶员精神状态的监测,避免疲劳状态对安全驾驶造成的影响是一项具有巨大应用前景的重要课题。

脑电信号作为人脑活动的直接体现,可以快速地反映出人的生理及心理变化过程,被广泛地用于疾病和心理状态的检测研究。此外,脑电信号具有良好的时间分辨率,它的采集过程具有无创、操作简便等优点,因而是判断大脑活动的一个有力手段^[2]。传统基于脑电信号的疲劳检测方法主要通过提取不同频率范围内的脑电特征,然后使用分类器对其进行分类。例如,相关学者基于功率谱密度特征、熵特征,结合SVM、随机森林、多层感知器(MLP)等浅层机器学习分类方法实现了对疲劳状态的识别^[3,4]。除了基于单一生理特征^[5]或车辆驾驶参数^[6]的疲劳检测方法外,融合多源数据信息的检测方法也受到了相关研究者的关注^[7,8]。由于脑电信号的独特性质,基于专家知识的手工特征提取与浅层机器学习方法在对脑电信号进行特征提取和分类方面还存在特征提取依赖专家知识、操作繁琐,识别准确率低等不足,为此本文拟通过深度神经网络自动学习对疲劳状态识别有利的特征信息。

深度学习作为一种表示学习方法,能够通过训练自动提取信号的特征,实现对信号的识别^[9]。卷积神经网络作为深度网络模型的一个典型代表,其在计算机视觉、图像处理与语音识别方面已经取得了十分优异的结果^[10]。近些年,已经有一些学者将深度学习技术应用到基于脑电信号的驾驶疲劳检测研究。例如,Du等人^[11]提出了一种基于深度自编码器的多模态融合方法以融合脑电和眼电信号特征,并通过实验验证了其对于疲劳检测的有效性。Mao等人^[12]基于原始脑电信号提出了一种卷积神经网络模型用于驾驶疲劳检测。典型的脑电信号特征分析方法主要分为时域、频域和时频域分析法^[13-15]。频域内的脑电信号具有特征明显、可分辨性强等特点,其对脑电信号的分析具有重要的意义,不同频段的脑电信号可以有效地反映人的精神状态及兴奋程度^[16]。文献^[17,18]基于由小波变换得到的脑电信号时频图,运用卷积神经网络实现了对情绪的识别。但时频图无法有效地反映不同电极之间脑电信号的相关性。为此,本文提出了电极-频率分布图(Electrode-Frequency Distribution Maps, EFDMs)的概念,即通过对不同通道的脑电信号进行离散傅

里叶变换,并对变换结果进行标准化处理以获得电极-频率分布图。

由于不同任务下的刺激范式、被试、脑电采集设备等都可能存在差异,因此,已训练好的检测模型在新任务下往往不能达到很好的识别效果,检测模型的准确性和泛化能力有待进一步提高。此外,由于深度神经网络的学习过程比较复杂,一般需要大量带标注的训练数据,而脑电信号的获取不像图像、语音及文本信号那么容易。因此,如何实现少样本学习也是疲劳检测系统需要考虑的问题。为此,本文提出了深度迁移学习来解决上述问题。迁移学习,是指利用数据、任务或模型之间的相似性,将在旧领域学习过的知识应用于新领域的一种学习过程^[19]。按学习方法的分类形式,Pan等人^[19]将迁移学习方法分为4个大类:基于样本的迁移学习方法(Instance based Transfer Learning, ITL)、基于特征的迁移学习方法(Feature based Transfer Learning, FTL)、基于模型的迁移学习方法(Model based Transfer Learning, MTL)和基于关系的迁移学习方法(Relation based Transfer Learning, RTL)。基于模型的迁移学习方法是将已经训练好的模型迁移到新任务的过程,并针对具体任务进行自适应更新,从而取得更好的效果。基于模型的迁移学习通过将已训练好的模型参数迁移到新的领域以帮助模型训练,大大加快了模型的学习效率。自Yosinski等人^[20]发表了有关深度神经网络中的特征如何迁移的文章后,基于卷积神经网络的迁移学习算法在图像领域取得了快速的发展,而有关迁移学习方法在基于脑电信号的驾驶疲劳检测任务中的研究相对较少。

本文基于多通道脑电信号,首先提出了电极-频率分布图的概念,并在此基础上提出了运用迁移学习方法实现的驾驶疲劳检测系统。本文通过模拟驾驶实验平台获得疲劳驾驶实验数据,并利用深度卷积神经网络基于上海交通大学的SEED脑电数据集建立情绪识别模型,然后通过微调神经网络的迁移学习方法将其用于本文的疲劳状态检测任务,并与传统特征提取与模式识别方法的检测结果相比较。实验结果表明,本文的方法可以在利用少量样本的情况下实现对人体疲劳状态的有效识别。

2 基于深度迁移学习的疲劳检测系统

2.1 基于卷积神经网络的脑电信号识别

在图像处理中,卷积运算可以有效地对图像信息进行滤波,而卷积神经网络正是利用了卷积运算的这种特性实现了对图像特征的自动提取。为运用

卷积神经网络对脑电信号进行特征提取与模式分类，本文基于多通道脑电信号首先提出了电极-频率分布图的概念。多通道脑电信号的电极-频率分布图可以看作是一幅灰度图像，其变换结果可类比为图像像素的灰度值，因此，以电极-频率分布图作为卷积神经网络的输入，可以实现基于卷积神经网络构建疲劳检测模型的目的。

在神经网络的设计上，本文基于深度残差网络设计了一种包含2个残差块的卷积神经网络，其结构如图1(a)所示。该网络包含2个残差块，2个最大池化层以及2个全连接层，最后是Softmax层。其中，残差块的结构如图1(b)所示，残差块中卷积核的大小分别为3, 3, 1，卷积核滑动步长为1，在每个卷积层后面均包含批归一化(Batch Normalization, BN)处理。池化窗口大小为2×2，窗口滑动步长为2。此外，所有的中间层都以修正线性单元(Rectified Linear Unit, ReLU)作为激活函数。基于2层残差块的卷积神经网络模型的详细结构参数如表1所示。

2.2 迁移学习策略

机器学习的目标是构建一个尽可能通用的模型，使得其尽可能满足不同用户群体、不同环境的特殊需求。然而，这样理想的模型在现实应用中往往不能达到预期要求。因此，如何构建普适化的通用模型以适应不同分类任务下被试、信号采集设备等可能存在的差异，并实现少样本学习也是基于深度神经网络的疲劳检测系统需要考虑的问题。研究表明，在图像处理领域，浅层卷积层能够提取图像的基础特征，而深层卷积层能够提取抽象特征；因此可以通过微调预训练卷积神经网络模型的部分层来完成图像识别任务，从而减少对训练样本的需求量。此外，当微调的层数越多，其识别精度越高，甚至超过基于随机初始化的训练模型。为此，本文首先利用上海交通大学提供的SEED脑电情绪数据集对上述深度网络模型进行预训练，并分别通过微调网络的全连接层及整个网络的迁移学习策略将其用于驾驶疲劳检测任务。本文采用的基于卷积神经网络的迁移学习策略如图2所示。




图 1 基于2层残差块的深度卷积神经网络模型

表 1 基于2层残差块的卷积神经网络模型的详细结构参数

网络层类型		特征层数	特征层尺寸
输入层			100×30
残差块1	卷积层Conv1_1(3×3)、批归一化(32)	32	100×30
	卷积层Conv1_2(3×3)、批归一化(32)	32	100×30
	卷积层Conv2(1×1)、批归一化(32)	32	100×30
池化层1	最大池化(2, 2)	32	50×15
残差块2	卷积层Conv1_1(3×3)、批归一化(64)	64	50×15
	卷积层Conv1_2(3×3)、批归一化(64)	64	50×15
	卷积层Conv2(1×1)、批归一化(64)	64	50×15
池化层2	最大池化(2, 2)	64	25×7
全连接层1	全连接		1024
全连接层2	全连接		3
输出层	Softmax		3




图 2 基于卷积神经网络的迁移学习策略

3 脑电采集实验设计与数据处理

3.1 测试者情况

被试的年龄、身体状况、睡眠习惯和质量等因素均对实验的开展有着十分重要的影响。因此，在开展实验前需要对被试进行严格的筛选。经调查和筛选，最终选择实验室内10名研究生为被试人员(6名男生、4名女生)，年龄在22~24岁，身体健康状况良好，视力均为正常水平，或已通过矫正的方式达到了正常水平；没有任何运动障碍，对于模拟驾驶实验的操作方法有一定的了解。他(她)们处于同一生活、学习环境，拥有包括作息时间一致在内的许多共同点，这对实验开展来说非常有利。被试均已取得机动车驾驶证，且在驾龄期间内无任何违反交通法规的不良驾驶记录。此外，被试在实验期间需要避免使用任何能对中枢神经系统产生兴奋或抑制的药品或食品；尽量保持心情舒畅，避免精神紧张状态。所有被试在实验前均已悉知该项实验的操作流程与目的，并签署书面知情同意书。

3.2 实验方案与流程

为获得疲劳驾驶实验数据集，本文通过Logitech模拟驾驶器和PS4实验设备搭建模拟驾驶实验平台，被试连续驾驶《驾驶俱乐部》模拟驾驶实验游戏2.5 h，同时通过信号采集设备和摄像头同步采集被试在驾驶过程中的脑电、眼电和面部图像。本文使用Neuroscan NuAmps采集脑电和眼电数据，采样频率为1 kHz，共采集了36通道的数据信息(包括4通道眼电数据)，电极安放位置符合国际10-20电极位置分布系统，如图3所示。其中，A1，

A2为参考电极，实验数据采集前要求所有实验电极的阻抗均降到5 kΩ以下。

研究表明，午餐后的1 h是被试在连续驾驶过程中最易出现疲劳的时间段。为准确诱发疲劳状态，本文的所有驾驶实验均安排在午餐后进行，实验数据采集时间为12:30~15:00，数据采集时长为2.5 h。模拟驾驶实验的详细时间安排如表2所示。

表 2 疲劳驾驶实验时间安排表

时间	事件
11:30~12:10	搭建实验平台，向被试说明实验要求和实验过程中的注意事项等；
12:10~12:20	被试者针对模拟驾驶环境进行适应性练习；
12:20~15:10	开始测试，被试者进行持续驾驶，实验组织人员记录实验相关数据；
15:10~	整理实验设备，实验完成。

3.3 数据预处理

在单调的认知活动中，随着时间的推移，人们的精神疲劳呈现逐渐加深的状态。因此，在“清醒”和“疲劳”两种状态之间并没有一个绝对的界限。大量研究表明，当被试者处于“疲劳”状态时，其眼睑在单位时间内的闭合程度(PERCLOS)与眨眼频率相对于“清醒”状态而言均会产生较大的变化。因此，本文采用专家知识，运用主观评估的方法，基于在疲劳驾驶实验过程中同步采集的眼电和被试者面部图像等信息综合判断被试者的精神状态，并为相应的脑电数据片段添加“清醒”或“疲劳”状态标签。

图4显示了本文基于同步采集的眼电和被试者面部图像进行主观评估得到的2种不同类型的数据片段。可以看出，“疲劳”状态下，被试者眼睑的闭合程度明显比“清醒”状态高，且存在上眼睑下垂，虹膜区域被上眼睑遮盖较多，目光呆滞，嘴角下垂，并略显内收缩的现象。此外，根据视频分析，在实验后期，被试者开始出现打哈欠，下意识点头等疲劳症状。从眼电的变化可以看出，在处于精神疲劳时，被试者的眨眼频率明显增加，且睁闭眼时间有所延长。




图 3 32通道脑电电极分布图




图4 基于同步采集的眼电(HEOG水平眼电, VEOG垂直眼电)和面部图像进行主观划分得到的2种不同数据片段

由于通过EEG电极采集到的原始脑电信号往往受到多种伪迹和噪声信号的影响,如工频干扰、电磁噪声、眼电和肌电等生理伪迹,为准确地获得大脑的精神状态,在进行特征提取和模式分类之前需要对脑电信号进行数据预处理操作。为此,本文首先对原始脑电信号进行降采样处理,将采样频率降到200 Hz,并手动去除受肌电和眼电严重干扰的数据片段,然后运用0.5~45 Hz的带通滤波器去除部分噪声和伪迹干扰。之后,运用独立成分分析法(ICA)将脑电信号分解为多个独立成分,识别并去除伪迹成分,然后运用剩余独立成分进行信号重构,得到纯净的脑电信号。最后,再以非重叠的方式将各通道的脑电数据划分为1 s长度的数据片段,获得每位被试者在两种精神状态下的数据样本各600个。

4 实验结果与分析

本文首先运用上文提出的卷积神经网络基于SEED脑电数据集建立情绪识别模型,然后通过迁移学习方法将其用于疲劳状态识别,并与传统以功率谱密度、样本熵为特征,支持向量机、深度信念网络为分类器的疲劳检测方法,以及当前比较流行的深度神经网络AlexNet和VGGNet进行对比分析。

4.1 基于SEED数据集的情绪识别

4.1.1 数据集描述

SEED数据集(SJTU Emotion EEG Dataset)是由Zheng等人^[21]公开提供的用于情绪识别研究的脑电数据集。该数据集由15个评定为带有特定情绪(积极、中性和消极)的中文电影片段(每类情绪的电影片段各5个)在15名被试者(7名男性和8名女性)中试验得到,每名被试者参与实验3次,每次实验之间间隔约为7天。脑电信号采集设备为ESI NeuroScan,采集频率为1000 Hz。单次实验包含15个电影片段,在每个片段开始之前有5 s的提示时间,片段结束之后有45 s的信息反馈时间(被试者

根据产生特定情绪的程度进行自我评估),休息15 s后开始下一个电影片段的测试。在数据预处理过程中,原始脑电信号被降采样为200 Hz,并运用0~75 Hz的带通滤波器对其进行滤波处理。

4.1.2 数据预处理

由于在各刺激片段下采得的脑电信号长度并不一致,因此,本文首先统计所有脑电信号的长度,并对它们进行裁剪操作(取其前37000个样本点),以保证最后得到的各类情绪的样本数量一致。之后,再以非重叠的方式将各通道中的EEG数据划分为长度为1 s的数据片段。单次实验的每个电影片段下共获得185个数据样本,因此各类情绪状态下共获得41625个样本。最后,对所有数据样本进行快速傅里叶变换,并对变换结果进行标准化处理以获得电极-频率分布图。图5显示了3种情绪下的电极-频率分布图。

4.1.3 实验结果与分析

首先对前文所述的卷积神经网络进行训练,训练过程以Adam算法为优化方法,学习率设置为0.001,损失函数为交叉熵损失函数,最终获得的网络训练曲线如图6所示。

到目前为止,已经有很多学者基于SEED脑电数据集开展了有关情绪识别的研究,部分基于该数据集运用不同方法实现的情绪识别结果如表3所示。Zheng等人^[16]以典型的机器学习特征提取方法(功率谱密度PSD、微分熵DE、微分熵不对称差DASM、微分熵不对称商RASM)和分类器(SVM, DBN)构建了多个分类模型以实现情绪的识别。其中,微分熵结合DBN取得了86.08%的最佳基线识别准确率。Thejaswini等人^[22]结合多种时域特征和时频域特征(Hjorth参数、微分熵、DASM, RASM),以人工神经网络为分类器实现了91.20%的分类准确率。Tang等人^[23]在情绪识别过程中引入了眼动信息,并采用双模态深度去噪自动编码器(Bimodal Deep Denoising AutoEncoder,




图 5 3种情绪下的电极-频率分布图




图 6 深度情绪识别网络的训练过程

BDDAE)对脑电数据和眼动数据的特征进行融合,最后以引入时间信息的Bimodal-LSTM分类器进行识别,取得了93.97%的最佳识别准确率。本文基于电极-频率分布图结合卷积神经网络构建的情绪识别模型取得的识别准确率为90.59%,比基于微分熵和DBN方法的基线识别准确率高4.51%,且基于电极-频率分布图的特征提取方法相对于其它方法而言,所需数据长度更短,特征提取方法更加简单。即说明了电极-频率分布图结合卷积神经网络这一方法对于脑电模式识别的有效性。

表 3 不同方法在SEED数据集上的识别结果

方法	特征	分类器	信号	平均准确率(%)
Zheng方法 ^[16]	DE	DBN	EEG(1s)	86.08
Thejaswini方法 ^[22]	Statistical features, Hjorth parameters, DE, DASM, RASM	ANN	NA	91.20
Tang方法 ^[23]	PSD, DE, Mean, SD	Bimodal-LSTM	EEG(4s)+Eye movement	93.97
本文方法	EFDMs	CNN	EEG(1s)	90.59

4.2 基于迁移学习的疲劳状态识别

由于本文所用脑电信号采集系统(30通道)与文献^[21]有所不同(62通道),为此,本文仅采用SEED数据集中的部分通道用于分析,以获得相同尺寸的电极-频率分布图,便于模型的迁移学习。选择出的电极通道为本文和文献^[21]所共有的30个电极: Fp1, Fp2, F7, F3, Fz, F4, F8, FT7, FC3, FCz, FC4, FT8, T7(T3), C3, CZ, C4, T8(T4), TP7, CP3, CPz, CP4, TP8, P7(T5), P3, PZ, P4, P8(T6), O1, OZ, O2。按照前文所述方法,分别获得脑电信号在“清醒”和“疲劳”两种状态下的电极-频率分布图,然后基于前文获得的情绪识别网络,分别通过微调全连接层、微调全部网络的迁移学习方法和随机初始化建立网络模型的方法实现对

疲劳状态的识别,3种网络的训练过程如图7所示。可以看出,在微调全连接层和微调全部网络的迁移学习策略下,微调网络模型的优化速度相对于随机




图 7 微调网络和随机初始化网络的训练过程

初始化网络模型而言有着明显的提升。然而,由于在脑电信号的疲劳特征和情绪特征之间具有一定的差异性,而基于SEED数据集训练得到的模型,其卷积部分所提取的特征具有特异性,这种特异性导致了微调网络全连接层的迁移学习策略的识别准确率有所下降;而基于微调全部网络的迁移学习策略可以在保证优化速度的前提下提高识别准确率。

为验证本文方法对于疲劳状态识别的有效性,作为对比实验,本文以脑电信号的功率谱密度(Power Spectral Density, PSD)和样本熵(Sample Entropy, SampEn)为特征,支持向量机(SVM)为分类器进行疲劳状态识别。本文还搭建了具有2个隐藏层(隐层神经元数为300-30)的深度信念网络(DBN)用于疲劳状态识别,并利用先逐层预训练,后微调全部网络的学习策略进行训练。为获得脑电信号各节律波的特征数据,首先依据频率将脑电信号分为不同的节律波: δ (0.5~4 Hz), θ (4~8 Hz), α (8~12 Hz), β (12~31 Hz), λ (31~45 Hz),然后计算各节律波的功率谱密度和样本熵特征。实验过程中所使用的功率谱密度和样本熵特征均为5种脑电节律下各种特征的直接连接。此外, AlexNet和VGGNet-11两种深度神经网络亦被用于疲劳状态识别。由于两者均是基于图像数据建立的,要求输入为3通道数据,因此,本文以电极-频率分布图代表彩色图像的R, G, B分量以构成伪彩色图像,并采用图像插值的方法来解决图像尺寸与网络输入要求不一致的问题。各种不同的模式识别方法对疲劳状态的识别结果如表4所示。

从表4中可以看出,在基于卷积神经网络的疲劳状态识别方法中,微调全部网络的迁移学习方法取得了83.90%的最佳识别准确率,而仅通过微调全连接层的迁移学习方法达到的识别准确率为77.15%,比随机初始化神经网络方法的识别结果(82.60%)要差一些,这表明卷积神经网络在处理不同的模式识

别任务时,卷积层所提取的脑电信号特征存在一定的差异。从图7可以看出,虽然微调全连接层模型的识别准确率比随机初始化训练模型的识别准确率低,但在初始训练过程中,在达到相同识别准确率的前提下,微调模型所需要的训练步数要少得多。作为对比实验,分别以PSD和SampEn为特征, SVM为分类器的疲劳识别模型达到的平均识别准确率分别为75.53%和63.69%;以深度信念网络(DBN)构建的疲劳检测模型的平均识别准确率为79.01%。从表4中结果还可以看出,基于自动提取特征的深度学习模型的识别准确率远高于基于人工特征模型的识别准确率;基于随机初始化训练和微调全部网络的训练策略所得到的卷积神经网络模型的识别准确率均高于DBN的识别准确率,但基于微调全连接层的训练策略所得到的疲劳检测模型的识别准确率略低于基于DBN的识别准确率。此外,基于AlexNet, VGGNet和电极-频率分布图构建的疲劳识别模型取得的平均识别准确率分别为83.59%和82.67%,均低于本文提出的采用微调全部网络的迁移学习策略构建的疲劳检测模型。

5 结束语

针对脑电信号的独特性,以及传统机器学习方法在基于脑电信号进行疲劳状态识别方面还存在识别率低,特征提取操作繁琐等不足,本文提出了基于电极-频率分布图和迁移学习策略实现的疲劳状态检测模型。本文首先基于SEED脑电情绪数据集建立用于情绪识别的深度网络模型,然后通过微调全连接层和微调全部网络的迁移学习方法将其用于本文的疲劳状态检测任务,并将其与基于功率谱密度、样本熵和SVM与DBN的传统模式识别方法,以及AlexNet, VGGNet两种深度神经网络的检测结果相对比,以说明本文方法对于疲劳状态检测的有效性。实验结果表明,基于电极-频率分布图的深度网络模型对疲劳状态的识别准确率明显高于传统基于特征工程方法的识别准确率,此外,通过仅微调全连接层的迁移学习策略构建的深度网络模型的识别效果相对于随机初始化网络模型而言要低一些,这也说明了不同任务下的脑电信号特征存在较大的差异。本文提出的基于脑电信号和迁移学习策略的驾驶疲劳识别模型可以很好地完成对驾驶疲劳状态的识别任务。目前,本文的工作仅针对基于脑电信号的驾驶疲劳识别任务,后续将针对多领域脑电信号识别任务来进行模型迁移,以通过迁移学习方法在新领域内通过少量样本的训练,实现对样本数量不足和拥有不同数据分布特征的任务识别。

表4 不同的模式识别方法对疲劳状态的识别结果

方法	平均准确率(%)
EFDMs+随机初始化训练	82.60
EFDMs+微调全连接层	77.15
EFDMs+微调全部网络	83.90
PSD+SVM	75.53
SampEn+SVM	63.69
EEG+DBN	79.01
EFDMs+AlexNet	83.59
EFDMs+VGGNet	82.67

参 考 文 献

- [1] 李刚. 基于脑功能网络的脑力疲劳检测技术及其形成机理研究[D]. [博士学位], 山东大学, 2017.
LI Gang. Study on the mental fatigue detecting technology and its formation mechanism based on brain functional network[D]. [Ph. D. dissertation], Shandong University, 2017.
- [2] BALANDONG R P, AHMAD R F, SAAD M N M, *et al.* A review on EEG-based automatic sleepiness detection systems for driver[J]. *IEEE Access*, 2018, 6: 22908–22919. doi: [10.1109/ACCESS.2018.2811723](https://doi.org/10.1109/ACCESS.2018.2811723).
- [3] HU Jianfeng. Comparison of different features and classifiers for driver fatigue detection based on a single EEG channel[J]. *Computational and Mathematical Methods in Medicine*, 2017: 5109530. doi: [10.1155/2017/5109530](https://doi.org/10.1155/2017/5109530).
- [4] XIONG Yijun, GAO Junfeng, YANG Yong, *et al.* Classifying driving fatigue based on combined entropy measure using EEG signals[J]. *International Journal of Control and Automation*, 2016, 9(3): 329–338. doi: [10.14257/ijca](https://doi.org/10.14257/ijca).
- [5] FU Rongrong, WANG Hong, and ZHAO Wenbo. Dynamic driver fatigue detection using hidden Markov model in real driving condition[J]. *Expert Systems with Applications*, 2016, 63: 397–411. doi: [10.1016/j.eswa.2016.06.042](https://doi.org/10.1016/j.eswa.2016.06.042).
- [6] LI Zuojin, LI S M, LI Renjie, *et al.* Online detection of driver fatigue using steering wheel angles for real driving conditions[J]. *Sensors*, 2017, 17(3): 495–508. doi: [10.3390/s17030495](https://doi.org/10.3390/s17030495).
- [7] 王斐, 王少楠, 王惜慧, 等. 基于脑电图识别结合操纵特征的驾驶疲劳检测[J]. 仪器仪表学报, 2014, 35(2): 398–404.
WANG Fei, WANG Shaonan, WANG Xihui, *et al.* Driving fatigue detection based on EEG recognition and vehicle handling characteristics[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(2): 398–404.
- [8] LI Zuojin, CHEN Liukui, PENG Jun, *et al.* Automatic detection of driver fatigue using driving operation information for transportation safety[J]. *Sensors*, 2017, 17(6): 1212–1222. doi: [10.3390/s17061212](https://doi.org/10.3390/s17061212).
- [9] ZHANG Qingchen, YANG L T, CHEN Zhikui, *et al.* A survey on deep learning for big data[J]. *Information Fusion*, 2018, 42: 146–157. doi: [10.1016/j.inffus.2017.10.006](https://doi.org/10.1016/j.inffus.2017.10.006).
- [10] HATCHER W G and YU Wei. A survey of deep learning: Platforms, applications and emerging research trends[J]. *IEEE Access*, 2018, 6: 24411–24432. doi: [10.1109/ACCESS.2018.2830661](https://doi.org/10.1109/ACCESS.2018.2830661).
- [11] DU Lihuan, LIU Wei, ZHENG Weilong, *et al.* Detecting driving fatigue with multimodal deep learning[C]. The 8th International IEEE/EMBS Conference on Neural Engineering (NER), Shanghai, China, 2017: 74–77. doi: [10.1109/NER.2017.8008295](https://doi.org/10.1109/NER.2017.8008295).
- [12] MAO Zijing, YAO Wanxiang, and HUANG Yufei. EEG-based biometric identification with deep learning[C]. The 8th International IEEE/EMBS Conference on Neural Engineering (NER), Shanghai, China, 2017: 609–612. doi: [10.1109/NER.2017.8008425](https://doi.org/10.1109/NER.2017.8008425).
- [13] WANG Haixian. Optimizing spatial filters for single-trial EEG classification via a discriminant extension to CSP: The Fisher criterion[J]. *Medical & Biological Engineering & Computing*, 2011, 49(9): 997–1001. doi: [10.1007/s11517-1-0766-7](https://doi.org/10.1007/s11517-1-0766-7).
- [14] CHUANG C H, KO L W, LIN Yuanpin, *et al.* Independent component ensemble of EEG for brain-computer interface[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 22(2): 230–238. doi: [10.1109/TNSRE.2013.2293139](https://doi.org/10.1109/TNSRE.2013.2293139).
- [15] LI Mingyang, CHEN Wanzhong, and ZHANG Tao. Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble[J]. *Biomedical Signal Processing and Control*, 2017, 31: 357–365. doi: [10.1016/j.bspc.2016.09.008](https://doi.org/10.1016/j.bspc.2016.09.008).
- [16] ZHENG Weilong and LU Baoliang. 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. doi: [10.1109/TAMD.2015.2431497](https://doi.org/10.1109/TAMD.2015.2431497).
- [17] ZHANG Benyu, JIANG Huiping, and DONG Linshan. Classification of EEG signal by WT-CNN model in emotion recognition system[C]. The 2017 IEEE 16th International Conference on Cognitive Informatics & Cognitive Computing (ICCI*CC), Oxford, UK, 2017: 109–114. doi: [10.1109/ICCI-CC.2017.8109738](https://doi.org/10.1109/ICCI-CC.2017.8109738).
- [18] LEE H K and CHOI Y S. A convolution neural networks scheme for classification of motor imagery EEG based on wavelet time-frequency image[C]. 2018 International Conference on Information Networking (ICOIN), Chiang Mai, Thailand, 2018: 906–909. doi: [10.1109/ICOIN.2018.8343254](https://doi.org/10.1109/ICOIN.2018.8343254).
- [19] PAN S J and YANG Qiang. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345–1359. doi: [10.1109/TKDE.2009.191](https://doi.org/10.1109/TKDE.2009.191).
- [20] YOSINSKI J, CLUNE J, BENGIO Y, *et al.* How transferable are features in deep neural networks?[C]. The 27th International Conference on Neural Information Processing Systems, Cambridge, USA, 2014: 3320–3328.
- [21] ZHENG Weilong, ZHU Jiayi, and LU Baoliang. Identifying

- stable patterns over time for emotion recognition from EEG[J]. *IEEE Transactions on Affective Computing*, 2017. doi: [10.1109/TAFFC.2017.2712143](https://doi.org/10.1109/TAFFC.2017.2712143).
- [22] THEJASWINI S, RAVI KUMAR K M, RUPALI S, *et al.* EEG Based Emotion Recognition Using Wavelets and Neural Networks Classifier[M]. GURUMOORTHY S, RAO B N K, GAO Xiaozhi. *Cognitive Science and Artificial Intelligence: Advances and Applications*. Singapore: Springer, 2018: 101–112.
- [23] TANG Hao, LIU Wei, ZHENG Weilong, *et al.* Multimodal emotion recognition using deep neural networks[C]. The 24th International Conference on International Conference on International Conference on Neural Information Processing, Guangzhou, China, 2017: 811–819. doi: [10.1007/978-3-319-70093-9_86](https://doi.org/10.1007/978-3-319-70093-9_86).
- 王 斐: 男, 1974年生, 博士, 副教授, 研究方向为人机交互感知与协作理论与技术、仿人机器人理论与技术.
- 吴仕超: 男, 1996年生, 硕士生, 研究方向为机器学习、脑电认知.
- 刘少林: 男, 1993年生, 硕士生, 研究方向为模式识别、深度学习.
- 张亚徽: 女, 1995年生, 硕士生, 研究方向为机器学习、脑机接口.
- 魏 颖: 女, 1968年生, 博士, 教授, 主要研究方向为图像处理与模式识别、医学影像计算与分析.