



脑电图信号在疲劳驾驶检测中的应用与挑战*

宗少杰¹⁾ 董芳^{1)**} 程永欣^{1)**} 喻大华¹⁾ 袁凯^{1,2)} 王娟¹⁾ 马宇欣¹⁾ 张飞¹⁾

¹⁾ 内蒙古科技大学数智产业学院(网络安全学院), 内蒙古模式识别与智能图像处理重点实验室, 包头 014010;

²⁾ 西安电子科技大学生命科学与技术学院, 西安 710071)

摘要 当前快节奏生活已经成为日常生活的常态, 对人们的身心健康带来了不少负面影响, 特别是在驾驶过程中容易出现疲劳困倦的情况。因此, 疲劳驾驶检测技术成为了研究的热点, 并取得了显著的进展。本文将介绍基于脑电图(electroencephalogram, EEG)信号的疲劳驾驶检测方法。本文首先概述基于EEG信号的疲劳驾驶检测的总体流程, 包括信号采集、预处理、特征提取和分类等步骤。然后, 详细介绍EEG信号中与疲劳相关的特征及其在疲劳驾驶检测中的应用。这些特征包括频域特征、时域特征、拓扑特征等, 通过分析这些特征可以有效地识别出驾驶员是否处于疲劳状态。接下来, 探讨目前已有的疲劳驾驶检测模型的性能评估和评价指标。针对基于EEG信号的疲劳驾驶检测, 常用的指标包括准确率、灵敏度、特异度等。本文分析不同模型在这些指标上的表现, 并比较它们的优劣。本文还简单介绍了EEG信号分类方法及其应用现状。常见的分类方法包括支持向量机、神经网络、贝叶斯分类器等, 这些方法在疲劳驾驶检测中得到了广泛应用。针对目前基于EEG信号的疲劳驾驶检测面临的问题, 本文提出了一些解决方法。例如, 统一数据标注标准、增加被试数量等。最后, 在总结全文内容的基础上讨论了基于EEG信号的疲劳驾驶技术未来的发展方向。在未来, 可以进一步提升疲劳驾驶检测技术的准确性和实用性, 以更好地应对快节奏社会给驾驶员安全带来的挑战。

关键词 脑电图信号, 疲劳驾驶检测, 脑功能连接, 传统机器学习, 深度学习

中图分类号 U463.6, TN911.7

DOI: 10.16476/j.pibb.2023.0399

相关研究表明, 长时间驾驶容易导致驾驶员的生理和心理疲劳, 从而降低其反应能力和驾驶技术。这种情况被称为疲劳驾驶^[1]。疲劳驾驶是交通事故的主要危险因素之一, 因为它会导致驾驶者的反应能力下降, 注意力不集中和判断力降低, 进而增加发生事故的风险^[2]。据世界卫生组织发布的《2018年全球道路安全现状报告》^[3], 交通事故对全球公共健康造成重大负担, 每年导致5 000万人受伤和135万人死亡。道路交通事故既威胁人的生命, 也给人们的财产造成损失。因此, 对驾驶员在驾驶过程中进行疲劳程度的监测具有重要意义。监测驾驶员的疲劳程度可以帮助减少交通事故的发生, 保障驾驶员和其他道路使用者的安全。

用于检测疲劳驾驶的解决方案包括主观量表^[4]、行为测量^[5-6]、车辆性能测量^[7]以及生理信号测量方法^[8]。主观量表方法是驾驶员通过填写主观量表来分析其实时的疲劳程度。常用的主观量

表包括卡罗林斯卡睡意量表(Karolinska Sleepiness Scale, KSS)、NASA任务负荷指数(NASA Task Load Index, NASA-TLX)和Epworth嗜睡量表(The Epworth Sleeping Scale, ESS)。根据Wang等^[9]的研究, 使用NASA-TLX量表发现, 在长时间驾驶之后, 大多数司机的心理疲劳程度较高。这个结果表明, 长时间的驾驶对驾驶员的心理状态产生了一定的负面影响。行为测量方法主要包括对眼睛闭合时间百分比(percentage of eye closure, PERCLOS)、头部歪斜程度和打哈欠频率

* 国家脑科学和类脑智能技术计划(2022ZD0214500), 国家自然科学基金(82260359, 82371500, U22A20303, 61971451)和内蒙古自然科学基金(2021MS08014, 2023QN08007)资助项目。

** 通讯联系人。

董芳 Tel: 18648481891, E-mail: dongfang@imust.edu.cn

程永欣 Tel: 15047219886, E-mail: chengyongxin@imust.edu.cn

收稿日期: 2023-10-17, 接受日期: 2024-01-09

的测量。其中PERCLOS在不同环境下实现了对疲劳驾驶的实时检测^[10]。此外,研究表明,在实时驾驶时结合PERCLOS、闭眼持续时间、眨眼频率、点头频率、面部位置和固定凝视等6个参数的计算方法,可以得到更加稳健且准确的结果^[11]。这些参数都是通过识别驾驶员面部视频图像中的特征进行计算得出的。车辆性能方法主要通过测量车速、纵向加速度、方向盘转动幅度与频率、车道中心的偏移量、方向盘加速度(steering wheel acceleration, SWA)、横向位置标准差(standard deviation of lateral position, SDLP)、车头时距(time headway, THW)和过道时间(time to lane crossing, TLC)等指标来评估驾驶员的疲劳程度。这些指标可以反映驾驶员的行为模式和注意力。研究人员观察到,在驾驶者清醒状态下,方向盘的角度变化较小且变化频率较快,而在疲劳状态下,方向盘的角度变化较大且变化频率相对较慢^[12]。为了实时检测驾驶员在不同疲劳状态下的情况,研究人员通过将脑电图(electroencephalogram, EEG)信号和方向盘转动特征进行融合分析取得了显著的成果。这一研究表明,通过综合考虑不同的生理和车辆性能特征,可以更加准确地判断驾驶员的疲劳状态。生理信号测量方法包括眼电图(electrooculography, EOG)、肌电图(electromyogram, EMG)、心电图(electrocardiogram, ECG)和EEG等指标。EEG是当前最常用于识别睡意的生理信号之一,其包含了丰富的人的认知状态信息。此外,许多研究还将EOG、ECG和EEG等不同生理信号进行融合分析^[13-15],并且取得了令人满意的效果。同时,也有研究将上述多种疲劳检测方法进行综合融合,旨在实现更好的疲劳检测效果^[16]。这些研究展示了综合利用不同生理信号的重要性和潜力,以更准确地评估驾驶员的疲劳状态。

主观量表方法主要依赖驾驶员自己的主观感受和报告,容易受到主观偏见的干扰,如个人情绪、态度和认知偏差等。行为测量方法则基于驾驶员的行为特征和模式来判断疲劳程度。然而,不同人的行为反应可能存在差异,而且疲劳反应也可能受到其他因素的干扰,如药物、噪音等。部分行为测量方法还需要使用专门的设备和传感器来记录和分析驾驶行为,增加了实验成本。相比之下,基于车辆性能的方法主要通过监测车辆的行驶状态和特征来推测驾驶员的疲劳程度。然而,车辆性能受到其他

因素的影响,如路况、天气等,导致误判或不准确性。此外,这种方法也需要使用专门的设备和传感器,增加了实施成本。与上述方法相比,基于EEG信号方法可以直接测量大脑的电活动,提供更直接和客观的疲劳程度指标。它消除了主观评估和行为模式的可能偏差,更准确地反映驾驶员的疲劳状态。同时,基于EEG信号的方法能够实时疲劳监测,并及时发出警报或提醒驾驶员。通过实时监测,可以及时采取措施防止疲劳驾驶导致的事故和意外发生。EEG信号能够检测到细微的脑内活动变化,具有较高的灵敏度和准确性。通过精细的信号处理和算法分析,可以更准确地评估驾驶员的疲劳程度。基于这些优势,EEG信号被认为是疲劳检测的“金标准”,并且已经广泛应用于疲劳检测中。综上所述,基于EEG信号的方法相较于其他方法,更具有逻辑性和客观性,可以提供更准确的疲劳程度评估,并及时采取措施预防疲劳驾驶导致的事故和意外发生。

本文中涵盖的一部分研究领域可能缺乏与疲劳驾驶的直接关系,包括睡眠剥夺^[17]或外文阅读^[18]等研究。但是,这些不同领域的研究对于调研EEG信号在疲劳驾驶检测中的应用具有参考价值。比较这些研究结果可以发现,长时间驾驶和睡眠剥夺等疲劳情况可能会引起类似的认知和生理反应,从而为EEG信号在疲劳驾驶检测中的应用提供支持。此外,EEG信号作为一种客观的生物标志物,在疲劳方面的研究中也有着广泛的应用潜力。例如,使用同样的方法在公共数据集生理网睡眠数据集(Physionet sleep EEG data, PSED)和模拟虚拟驾驶数据集(simulated virtual driving driver data, SVDD)中进行检测,并且在两个数据中都取得了令人满意的结果^[19]。这说明基于EEG的疲劳检测方法在不同疲劳情境下具有一定的应用潜力。但是需要明确区分这些不同领域的研究的背景和关注点,确保文献综述中的焦点仍然是基于EEG在疲劳驾驶检测中的应用。提前告知读者,一些引用的文献内容可能与疲劳驾驶的直接范畴存在偏差,但引用这些文献旨在支持对EEG在疲劳驾驶检测中前景和可行性的展示。

目前已有多篇文献综述了基于EEG信号的疲劳驾驶检测研究的进展。王忠民等^[20]对不同EEG特征进行了系统的总结,包括频域特征、时域特征和空间特征,并评估了这些特征在疲劳驾驶检测中的有效性。该文还讨论了不同的数据采集和分析方

法, 并探讨了已有研究的优点和局限性。王洪涛等^[21]着重分析了采集设备的便携性和舒适度问题, 并综述了EEG信号采集设备、EEG信号特征提取方法和EEG信号分类方法3个方面的研究现状。Stancin等^[22]对常用的EEG信号特征进行了详细的讨论, 包括频谱特征、时域特征和空间特征, 并探讨了这些特征在驾驶员疲劳检测系统中的应用。该文献还总结了当前研究中的问题和挑战, 并探讨了未来的发展方向, 如更多样化的特征提取方法和机器学习和深度学习等技术的应用。需要注意的是, 文献中引用了147个EEG特征, 但仅有大约50个特征用于疲劳检测中, 这表明目前仍存在大量的研究空间。此外, Balandong等^[23]在其研究中首先总结了6个主要的驾驶员困倦评估技术, 随后从优化EEG电极数量、增加困倦水平的分辨率, 并纳入昼夜节律信息等3个方面详细介绍了基于EEG信号疲劳检测技术的研究现状。该文探讨了目前研究中的问题和挑战, 并提出了未来研究的方向和重点。通过综述这些文献, 我们可以全面了解基于EEG信号的疲劳驾驶检测在不同方面的研究进展, 并为未来的研究提供指导和启示。

本文旨在全面综述基于EEG信号的疲劳驾驶检测方法的每一个步骤。首先介绍了使用EEG信号进行疲劳驾驶检测的总体框架步骤, 旨在为读者提供一个全局性认识。随后, 回顾了从EEG信号中提取的疲劳驾驶检测特征, 并详细介绍了这些特征的原理和应用现状, 为模型的预测结果提供了关键的特征。较之其他的综述工作, 本文还全面地介绍了疲劳驾驶检测模型性能评估和评价指标的原理和应用, 为评估模型的准确性和可靠性提供了指标支持。此外, 对当前EEG信号分类方法的原理和应用现状进行了详细阐述, 以便读者更好地理解模型预测的过程和挑战。最后, 总结了当前研究中的问题和不足之处, 并为研究人员和从业者提供有价值的参考。本文使用了大量篇幅着重介绍EEG信号特征, 因为这些特征决定了模型预测结果的上限, 是模型预测的关键因素, 也是疲劳驾驶检测方法的核心。总体而言, 本文覆盖了基于EEG信号检测方法的每一方面, 为读者提供了全面而深入的了解和学习基于EEG信号的疲劳驾驶检测方法。

1 EEG信号疲劳驾驶检测框架

基于之前的研究可见, EEG信号在许多领域

都受到广泛关注, 如决策^[24]、学习^[25]、记忆^[26], 以及与某些疾病如帕金森病^[27-28]、癫痫^[29]等相关。因此, 人们开始将EEG信号应用于疲劳驾驶检测的研究中。目前, 基于EEG的疲劳驾驶检测主要由数据采集模块、数据预处理模块、特征提取模块以及分类器模块构成。其中EEG信号采集设备主要分为湿电极和干电极^[9]两种类型。相对于湿电极, 干电极不需要使用导电凝胶来保持较低的阻抗水平 ($<10\text{ K}\Omega$), 这使得干电极在临床记录中变得越来越受欢迎。使用湿电极记录EEG需要涂抹导电膏、进行阻抗优化、记录后的清洁等步骤, 这些步骤都比较耗时。因此, 相较于传统的湿电极, 干电极更适合家庭记录。然而, 干电极相对于湿电极来说, 信号质量可能不如湿电极稳定。Hinrichs等^[30]研究中比较了无线干电极EEG系统和传统有线湿电极EEG系统在临床应用方面的差异。研究者发现, 无线干电极系统产生的EEG信号质量与传统湿电极系统相似, 并且在长时间记录中保持稳定。与湿电极相比, 无线干电极系统不需要使用导电凝胶, 操作更为方便, 受试者的舒适度也提高了。然而, 干电极系统的信号质量略低于湿电极系统, 因此在某些高精度临床应用领域可能需要使用湿电极系统。总的来说, 无线干电极EEG系统是一种可靠且方便的工具, 能够满足一般临床应用的需求。由于EEG信号通常会受到其他噪声的干扰, 例如肌电信号、眼电信号和心电信号。因此必须对EEG信号进行预处理。预处理的主要步骤包括通过带通滤波器去除慢波漂移和高频噪声干扰, 通过50 Hz陷波滤波器去除工频干扰。此外, 也可以利用独立分量分析 (independent component analysis, ICA) 将EEG信号分解成多个独立分量, 然后识别并丢弃伪影分量, 最后利用剩余分量重构EEG信号。疲劳驾驶检测的精确度主要受特征提取方法的影响。目前主要存在3种特征提取方法。其中最简单的是直接将经过预处理的EEG信号作为特征向量输入分类器, 而无需对其进行频域转化处理。这种方法由于特征维度较大, 因此需要使用复杂的机器学习模型进行分类, 如卷积神经网络 (convolutional neural network, CNN)^[31]。第二种特征提取方法就是提取局部脑区域内的时域特征、频域特征或熵。最后一种特征提取方法就是提取区域间的功能连接, 将功能连接值作为特征向量, 或构建功能连接网络并应用图论提取拓扑特征。目

前,基于传统机器学习和深度学习方法的疲劳检测模型被广泛应用。基于EEG信号的疲劳驾驶检测的基本流程如图1所示。本文的后续章节将详细介绍

EEG信号特征提取和分类器选择方面的研究进展。




Fig. 1 Fatigue driving detection process based on EEG signals

图1 基于EEG信号的疲劳驾驶检测流程

2 EEG信号疲劳特征提取

EEG信号通常可分为4个频段: δ 波(0.5~4 Hz)、 θ 波(4~8 Hz)、 α 波(8~12 Hz)和 β 波(13~30 Hz)。在EEG疲劳特征提取中,常使用单个或多个频段的特征来反映驾驶员的脑状态变化。不同频段代表不同的脑状态。 α 波主要出现在大脑放松或有意识的状态下,当驾驶员感到放松或专注时, α 波活动增强。 β 波主要出现在紧张状态下,当驾驶员感到紧张或专注于某个任务时, β 波频率增加。 θ 波主要出现在驾驶员昏昏欲睡的状态下,当驾驶员开始感到疲劳或倦意时, θ 波活动增加。 δ 波主要出现在深度睡眠阶段,当驾驶员进入深度睡眠时, δ 波频率占据主导地位。通过提取不同频段的特征,可以了解驾驶员在不同的EEG状态下的变化。这在疲劳驾驶检测和驾驶员状态监测中具有重要意义。然而,需要注意的是,特定频段的活动并不仅仅表明一种状态,还需要结合其他指标和上下文来进行准确的解释和分析。本节介绍现在常用EEG特征的原理和应用现状,EEG特征的计算细节需要参考相关的文献。

2.1 局部脑区域特征

2.1.1 时域特征

EEG信号的时域特征是指对信号在时间域上的统计和形态特征进行分析。疲劳驾驶检测中基于

EEG信号的时域特征主要包括平均值(mean, MEA)、能量(energy, ENG)、方差(variance, VAR)、均方根(root mean square, RMS)、Higuchi分形维数(Higuchi fractal dimension, HFD)、迁移性和Hjorth参数等特征。

其中平均值计算的是EEG信号在给定时间窗口内的平均值,反映了信号的整体水平。能量计算信号在给定时间窗口内的总能量,用于反映信号的强度或活跃性。方差描述了EEG信号在给定时间窗口内的离散程度或波动性,用于描述信号的变化程度。均方根用于描述信号的平均能量或振幅。Higuchi分形维度通过测量信号曲线在不同缩放比例下的长度来估计其几何结构的复杂程度。HFD越高,表示信号展示出更多的分形特性,其变化也越复杂。迁移性是一种用于描述信号在不同时间尺度上的变化模式的特征。

Hjorth参数是一组用于描述EEG信号的时域特征。它包括3个参数:活动度、移动度和复杂度。活动度反映了信号的总体功率或能量,可以通过计算信号的方差或标准差来衡量。移动度描述了信号在时域上的变动程度或变化速度,可以通过计算信号的一阶差分的方差或标准差来衡量。复杂度反映了信号的非线性程度或波形的复杂性,可以通过计算信号的二阶差分的标准差来衡量。

针对驾驶员精神疲劳的识别,许多研究都在探

索基于 EEG 的时域特征提取方法。例如, Zhang 等^[32] 针对驾驶员精神疲劳的识别提出了一种基于 EEG 的多维特征选择与融合方法。该方法通过分解信号并提取不同波段的时域、频域和非线性特征, 结合特征选择和融合方法, 获得了较高的识别准确率。其中时域特征包括平均值、能量、方差和均方根。他们使用由 Cao 等^[33] 分享的公开的驾驶员疲劳 EEG 数据集, 并与使用相同数据集的其他研究进行了比较, 结果表明, 他们的方法准确率比其他研究结果提高了至少 6%。

Venkata 等^[34] 提出了基于单通道 EEG 信号的困倦检测模型。他们利用小波包变换 (wavelet packet transform, WPT) 从 EEG 通道中提取 Higuchi 分形维数、复杂度和迁移性作为特征向量值。实验结果表明, 该模型在公共数据集 PSED 和 SVDD 上分别达到了 94.45% 和 85.36% 的预测正确率。Venkata 等^[35] 还提出了一种基于 Hjorth 参数的特征提取策略, 该研究提取 Hjorth 参数的复杂度和移动度, 并将其与已有的功率谱密度特征进行比较。实验结果表明, 相较于功率谱密度特征, 他们提出的 Hjorth 参数特征具有更高、更强的性能。研究中作者使用的是公共数据集 PSED 的 Pz-OZ 传感器上的 EEG 数据。

上述研究提出了基于 EEG 的多种时域特征提取方法, 用于驾驶员精神疲劳的检测和识别。这些方法结合不同的特征和信号处理技术, 具有较高的预测准确率, 表明基于 EEG 的时域特征提取方法是一种有效和可行的方法。未来的研究可以进一步改进这些方法, 并探索更多的特征和算法, 以提高驾驶员精神疲劳检测的效果。

2.1.2 频域特征

功率谱密度 (power spectral density, PSD) 通常用于计算信号在频域的特征。在不同的应用需求和数据特性下, 可以使用不同的参数和非参数方法来计算信号的功率谱密度。非参数方法通常使用快速傅里叶变换 (fast Fourier transforms, FFT)^[36] 或 Welch 谱方法^[37] 进行计算。而使用自回归 (autoregressive, AR) 模型^[9] 则是用于 PSD 估计的参数方法。EEG 信号功率谱密度描述信号在频域上能量分布的重要指标。它表示了信号在不同频率上的功率谱密度。在当前的研究中, 通常采集 EEG 信号特定频段的功率谱密度, 比如 δ 频段 (0.5~4 Hz)、 θ 频段 (4~8 Hz)、 α 频段 (8~12 Hz)、 β 频段 (13~30 Hz)、 γ 频段 (>30 Hz) 和 σ 频段

(12~14 Hz)。此外, 也有很多研究使用功率比特征来提取 EEG 特征, 常用的功率比特征包括: $(\alpha+\theta)/\beta$ 、 $(\alpha+\beta)/\theta$ 、 $(\alpha+\beta)/\beta$ ^[38]、 $(\alpha+\theta)/(\alpha+\beta)$ 、 θ/β ^[39] 和 $\delta\theta/\alpha\beta$ ^[40]。

可以使用 AR Burg 方法^[41-43] 和周期图法 (periodogram method, PD)^[44-45] 来计算信号的功率谱。AR Burg 方法通过估计 AR 模型的系数来得到信号的功率谱估计, 它基于最小化前向和后向预测误差的原理。递归 Burg 方法估计得到的 AR 参数可以应用于计算功率谱密度。该方法的优点是估计短数据记录, 在低电平信号中解析紧密空间正弦^[46]。PD 本质上是有偏自协方差的傅里叶变换, 是一种非参数方法。PD 方法可以检测信号中频率分量的 EEG 功率密度。PD 方法的优点是计算简单, 但也存在一些缺点。例如, 由于直接从离散傅里叶变换中计算得到, PD 方法的频率分辨率相对较低, 并且在原始信号中存在波动时, 可能会导致功率估计的偏差。

根据现有研究, 疲劳通常会伴随 EEG 波在不同频段的变化。具体来说, 在疲劳时, δ 波和 θ 波的功率会增加, 而 α 波和 β 波的功率会减少^[47]。与之结论相似, Jing 等^[38] 在真实的低压缺氧高原环境下进行了驾驶实验。该研究发现, 随着疲劳驾驶程度的增加, α 波和 β 波的平均功率会降低, θ 波的平均功率则会增加。此外, 当驾驶员处于疲劳状态时, $(\alpha+\theta)/\beta$ 值会明显增大, 而 $(\alpha+\beta)/\theta$ 值会明显减小。因此, $(\alpha+\theta)/\beta$ 和 $(\alpha+\beta)/\theta$ 可以作为低压高原环境下评估疲劳驾驶的有效指标。该实验中采用 KSS 主观评价分数作为标签依据, 并将驾驶过程中的驾驶疲劳程度分为清醒状态、临界状态和疲劳状态 3 种状态, 分别对应于 KSS 的 1、6、9。

尽管以上研究结果认为随着疲劳程度的增加 α 波的功率会减少, 但也有一些实验研究结果与之矛盾。例如, Zhang 等^[36] 的研究发现, 在单调驾驶条件下, 自动驾驶 40 min 后, 驾驶员的 α 波功率显著增加, 同时检测反应任务的准确性下降且反应时间变慢。他们使用接受者操作特性曲线计算被动疲劳时 α 波功率的临界阈值, 进一步明确被动疲劳的发生时间和生理特征, 完善了被动疲劳理论。另外, 还有一项研究提出了一种基于 EEG α 波功率变化的方法来检测驾驶员的精神疲劳程度^[48]。他们通过分析驾驶模拟过程中的 EEG 信号发现, 在驾驶的最后阶段, α 波功率显著增加。这种方法可以有效地推断驾驶员的精神疲劳程度, 为提高驾驶安

全性提供潜在的有用工具。另外一项研究^[49]设计了一个模拟驾驶实验,观察了单调驾驶时EEG功率谱的显著变化。研究表明,当受试者从清醒状态进入困倦状态时,在枕叶和顶叶区域的 α 和 θ 波功率显著增加。这些结果为预防因驾驶员嗜睡而引发交通事故提供了有希望的指标。这些研究结果都表明,困倦水平增加伴随着 α 波功率增加。现有研究结果之间存在着矛盾,有的研究认为随着疲劳程度的增加 α 波功率增加,而有些研究则认为 α 波功率减少,这表明在不同情境和驾驶条件下,疲劳对EEG波的影响可能存在差异。为了更全面地理解驾驶疲劳和EEG波之间的关系,未来的研究可以进一步探索这些差异,并提供更深入的分析 and 解释。

在这个领域的研究中,许多学者们致力于通过EEG信号功率比特征来检测驾驶员的疲劳状态。Wu等^[39]的一项实验选择了 $(\alpha+\theta)/\beta$ 、 $(\alpha+\theta)/(\alpha+\beta)$ 和 θ/β 的功率比来构建脑功率图(brain power map, BPM),并开发了一种新脑功率图网络(BPM network, Bpmnet)来检测大脑的认知状态。实验结果显示,他们的疲劳检测准确率达到了91.05%,比起现有方法有了显著的提升。实验中研究者根据驾驶环境的不同将标签分为了4个等级。另一项研究^[40]设计了一种便携式EEG信号采集系统,通过对EEG信号的中值滤波、带阻滤波和Hilbert-Huang变换进行处理和分析。该研究提取了功率谱密度比 $\delta\theta/\alpha\beta$ 作为特征值,并提出了两种确定疲劳水平的方法。实验结果发现,基于特征值比的方法在睁眼状态下的识别率为79%,基于BP神经网络的方法在疲劳状态下的识别率为83%,闭眼状态的识别率超过97%。为了评估驾驶员的疲劳状态,实验中还使用了ESS、精神运动警觉性测试(psychomotor vigilance test, PVT)和Aurora大学的睡眠测量表。

除了使用功率比来进行疲劳驾驶检测外,在一些研究中也探索了使用特定频段功率来检测疲劳驾驶。比如,在一项研究^[50]中提出了一种使用动态编码器-解码器建模框架进行驾驶员疲劳估计的方法。它通过分析EEG信号来推断驾驶员的疲劳程度。这一方法为提高驾驶安全性和预防交通事故提供了潜在的有效解决方案。同时,研究表明, δ 和 θ 功率可以作为编码PERCLOS的生物标记物。最新一项研究^[51]表明,通过提取EEG信号的功率谱密度特征,并使用K近邻(K-near neighborhood,

KNN)分类器进行分类,疲劳驾驶的检测精度可高达99.99%。这一结果表明,基于EEG功率谱密度特征的方法在疲劳驾驶检测中具有很好的应用潜力。研究者在实验中使用了公开的在线EEG数据^[52]。此外,另一项研究^[53]设计基于虚拟现实的高速公路驾驶实验。结果表明,当检测到疲劳信号时,发出警告信号可以抑制 α 和 θ 波的功率,改善行为表现。然而,随着时间的推移,警告信号的效果降低,伴随着 α 波功率的增加。与非EEG随机方法相比,基于EEG的自适应疲劳缓解系统更具效益。

综上所述,这些研究提供了多种基于EEG信号功率谱的方法来检测驾驶员的疲劳,并取得了较高的准确率。通过分析EEG信号的功率谱密度特征和特定的功率比,可以有效地评估驾驶员的疲劳状态。这些研究结果为提高驾驶安全性提供了潜在的有用工具,并为预防交通事故提供了新的可能性。

2.1.3 熵特征

1948年,香农首次引入熵的概念,将其应用到信息论领域^[54]。在信息论中,香农熵被用来衡量信源不确定性和信息量,其计算方法依赖于信号的概率分布。在信号处理和信息理论中,该概念在信号处理和信息理论中得到广泛应用,例如数据压缩、数据编码和信号分析。随后,研究者在香农熵的基础上,发展出多种熵指标,用于评估EEG信号的特征。这些指标通过对EEG信号的复杂性和随机性进行拓展和变种。

熵指标,近似熵(approximate entropy, AE)、样本熵(sample entropy, SE)、模糊熵(fuzzy entropy, FE)、排列熵(permutation Entropy, PE)、Rényi熵(Rényi entropy, RE)、Tsallis熵(Tsallis entropy, TE)和谱熵(spectral Entropy, SEN)等,被广泛应用于对EEG信号的复杂性和不规则性进行分析和解释。这些指标可以用来评估信号的独立性、无规律性、分布的非均匀性和频谱复杂性等特征。

近似熵通常用于简单的计算,但要求信号长度较高,且计算复杂度较高。为了克服这个问题,样本熵^[55]提出并能够量化信号的独立性和无规律性,并对信号的随机性具有较好的敏感性。但样本熵同样对样本长度有一定要求,且计算复杂度较高。模糊熵^[56]与近似熵和样本熵类似,其特点是针对小参数情况给出了熵的定义。

排列熵^[57]尤其适用于处理混沌时间序列, 而且具有较快的速度和较好的鲁棒性, 适用于大规模数据或无法进行预处理和参数微调的情况。Rényi熵^[58]具有不同参数值时的不同灵敏度。然而, 它对参数选择的要求较高, 且计算复杂度较高。而Tsalli熵^[59]类似于Rényi熵, 是统计热力学中玻尔兹曼-吉布斯熵的推广。谱熵^[60]则通过归一化香农熵的方式评估时间序列的频谱复杂性。此外, 差分熵^[61]是一种用于分析EEG信号动态特性的指标。反映了EEG信号连续时间点之间的变化和复杂性。这些基于熵的特征在脑机接口应用中被广泛应用于分析EEG信号的复杂性^[62-63], 并且较低的熵值表示EEG信号较规则有序, 可能反映了注意力集中或某个特定脑区功能活动^[64], 而较高的熵值则表示EEG信号更加复杂、不规则和随机, 可能与各种脑功能的失调或异常有关。综上所述, 这些熵指标在分析EEG信号特征方面具有非常重要的作用。

有许多基于熵的特征被用于识别疲劳驾驶^[19, 65]。Hu^[66]进行了一个模拟驾驶实验, 从EEG信号中提取了4个特征集, 包括FE、SE、AE、SEN和组合熵(FE+SE+AE+SEN)。然后他使用AdaBoost、决策树(decision trees, DT)、支持向量机(support vector machine, SVM)和朴素贝叶斯(Naive Bayes, NB)分类器进行分类。实验结果表明, FE特征集和组合特征集优于其他特征集。该实验将驾驶过程开始20 min中的最后5 min定义为正常状态, 连续驾驶过程持续60~120 min, 最后5 min的EEG信号被定义为疲劳状态。除此之外, Hu等^[67]还设计了另外一个模拟驾驶实验并且提取了相同的熵特征。然后, 他们将梯度增强决策树和其他先进的分类器进行比较。结果显示, 仅使用一个EEG通道即可检测驾驶员的疲劳状态, 平均最高的识别率达到94.0%, 满足日常应用需求。该研究的驾驶实验持续时间为40~120 min, 作者将驾驶持续10 min时的最后5 min记录为正常状态。当连续驾驶时间为30~120 min, 并且参与者报告出现疲劳时, 根据问卷结果(符合Chalder疲劳量表和Lee主观疲劳量表)将EEG信号标记为疲劳状态。

Mu等^[68]采用SVM分类器对提取的模糊熵特征进行分类, 实验选取FP1和FP2作为分析对象。他们发现混合FP1和FP2特征相比于从单个电极提取特征可以获得更高的检测精度。实验根据Li's主观疲劳量表和Borg's CR-10量表结果判断实验

的有效性。另外, Wang等^[69]采用谱熵、近似熵、样本熵和模糊熵对模拟驾驶时的EEG信号进行分类, 并使用梯度增强决策树(gradient boosted decision trees, GBDT)等集成方法进行比较。实验结果表明, 所提方法仅使用一个电极(T6)和GBDT即可进行驾驶员疲劳检测, 平均分类准确率达到94.3%。他们根据Li's主观疲劳量表和Chalder疲劳量表将EEG数据分为正常状态和疲劳状态。

此外, 现在的研究中也许多结合了EEG信号的熵特征与其他特征来实现疲劳检测。例如, Liu等^[70]在一项实验中记录了持续90 min的模拟驾驶任务期间的EEG数据, 他们利用3个额前EEG通道来检测驾驶员的疲劳状态。通过分析EEG的功率谱密度、功能连通性和样本熵等特征, 研究人员成功地开发出一个机器学习模型, 可以准确地识别驾驶员的疲劳程度。另一项研究^[61]使用了公共数据集SEED VIG中的有限EEG信号来检测驾驶员的警觉度。研究人员提取了频域特征功率谱密度和差分熵, 并使用SVM分类器进行分类。实验结果显示, 在选择频段(即 α 波段)和电极(即T7、TP7和CP1)的EEG信号上, 识别准确率高于使用全部数据时的识别准确率, 其最高准确率为91.31%。该方法在有效检测驾驶员的警觉度和处理数据缺失方面具有潜力。还有一项研究^[37]使用了4种特征提取方法(功率谱密度、功率谱熵、小波和自回归)来研究认知要求较高的计算机任务(AX-连续性能测试、精神运动警觉性测试和Stroop任务)。研究人员使用额叶位置的两个EEG信号通道(F3和F4), 寻找最佳的特征提取方法来分类疲劳和警觉状态。研究中采用了贝叶斯神经网络作为分类器。实验结果表明, 在每个任务中, 自回归作为特征提取方法表现做好。因此, 建议在检测认知要求较高的计算机任务中的疲劳时使用自回归作为特征提取方法。综上所述, 这些研究通过融合或对比其他特征, 与前文中仅使用熵特征进行检测的方法相比, 可以提升特征提取的效果。局部脑区域内特征总结如表1所示。

2.1.4 EEG信号特征提取方法的优缺点

时域特征反映了信号在时域上的波形特性, 其优点在于计算简单, 能够用来描述信号的基本特征, 但是缺点也比较明显, 它忽略了信号频域上的信息, 因此对于那些非常丰富的EEG信号, 时域特征的表现会比较有限。时域特征适用于情感分

Table 1 The features of EEG signals' time domain, frequency domain, and entropy

表1 EEG信号的时域特征、频域特征和熵特征

类别	特征
时域特征	平均值
	能量
	方差
	均方根
	Higuchi分形维数
	迁移性
	Hjorth参数
	活动度
	移动度
	复杂度
频域特征	Delta
	Theta
	Alpha
	Beta
	Gamma
	Sigma
	$(\alpha+\theta)/\beta$
	$(\alpha+\beta)/\theta$
	$(\alpha+\beta)/\beta$
	$(\alpha+\theta)/(\alpha+\beta)$
	θ/β
	$\delta\theta/\alpha\beta$
熵	近似熵
	样本熵
	模糊熵
	排列熵
	Rényi熵
	Tsalli熵
	谱熵
	差分熵

析、脑机接口等场景。频域特征反映了信号在频域上的分布情况，主要包括功率谱密度和频率熵。频域特征的优点是能够提供信号频域上的信息，特别是对于低频分量有很好的表现力。缺点在于需要较复杂的计算过程，对数据有更高的要求。适用于睡眠分析、癫痫检测等场景。熵特征是一类特别的时域特征，描述了信号的复杂性或者不规则程度。其主要优点是能够较好的描述信号的复杂结构和动态变化，但其缺点在于相同的熵值不一定代表相似的信号，因此熵特征需要慎重处理。适用于EEG波分析、疾病检测等场景。总之，不同的特征适合处

理的场景不同。时域特征可以用于描述信号的基本特征，频域特征适合分析信号的频率成分，熵特征适合描述信号的复杂程度与变化情况。不同特征的结合使用可以更全面地了解 EEG 信号的特征和图像。

2.2 脑区域间特征

2.2.1 脑功能连接矩阵

2.1 中所述的疲劳驾驶特征仅仅是从单个电极局部脑区域计算的，并没有考虑到脑区之间的相互关联。虽然大脑有不同的区域，每个区域都具有不同的功能，但没有任何一个区域可以独立完成工作，而是通过所有大脑区域的相互作用和协调来完成的。时域特征、频域特征和熵等 EEG 特征仅仅是从单个脑区提取的。它们不能有效地揭示大脑各区域之间的信息交流方式，也不能完全反映大脑的实际时间变化^[71]。然而，近年来的许多研究表明，脑功能连通性可以很好地表征认知过程中不同脑区之间的相互作用^[72-74]。功能连接指的是电极或脑区之间的关联程度，它是衡量不同神经组织活动之间相互关系的指标。目前存在的基于 EEG 数据构建脑功能网络的方法通常以电极测量的大脑区域作为网络节点，并通过信号之间的相互依赖关系来衡量节点之间的连接强度。

目前，用于构建脑功能连接矩阵以实现疲劳驾驶检测的 EEG 特征主要包括相位滞后指数（phase lag index, PLI）^[75]、部分定向相干（partial directed coherence, PDC）^[76]、直接定向相干（direct transfer function, DTF）^[77]、互信息（mutual information, MIN）^[78]、调制指数（modulation index, MI）^[79]、皮尔逊相关（Pearson correlation, PC）^[80]、锁相值（phase-locked value, PLV）^[81]和同步似然（synchronization likelihood, SL）^[17]等方法。

锁相值衡量了特定频率下 EEG 信号之间的相位同步程度。通过计算给定频率下 EEG 信号的平均相位差的幅度，能够表征不同电极之间的同步性。相位滞后指数用于衡量 EEG 信号之间的相位延迟。它在给定频率下计算了 EEG 信号的相位差的平均方向，即相位延迟的统计指标。

部分定向相干是一种频域因果分析方法，用于描述多通道信号之间的定向关系。它基于向量自回归模型和频域因果模型，计算信号在不同频率上的因果传递程度。直接定向相干是一种基于频域的分

析方法, 用于研究信号在不同频率上的传递方向。通过时间-频率分析, DTF 计算信号之间的频率传递关系, 并估计信号的传递方向。它能够展示信号在频域上的转换和传递路径, 有助于揭示相关的脑活动。

互信息是一种统计指标, 用于度量两个随机变量之间的相关性和依赖程度。调制指数方法直观地通过衡量相位-幅值图中幅值分布与均匀分布的偏差, 来评估相位-幅值耦合 (phase amplitude coupling, PAC) [25]。皮尔逊相关用于衡量两个信号之间的线性相关程度。同步似然是一种评估信号同步性的方法, 通过计算不同频带上信号的相位同步情况来估算信号之间的相互作用程度。使用这些 EEG 特征进行疲劳驾驶检测时, 可以获得不同方面的信息来揭示 EEG 信号之间的关联、相位耦合和同步性。通过综合分析这些特征, 可以更全面地评估疲劳驾驶的风险并提供有效的预警机制。

之前的内容介绍了当前用于构建脑功能连接矩阵方法的原理。接下来, 将重点介绍其中一些特征提取方法的计算公式。

a. 皮尔逊相关

任意两 EEG 通道信号 X 和 Y 之间的皮尔逊相关计算公式为:

$$\rho_{x,y} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = \frac{E[(x - \mu_x)(y - \mu_y)]}{\sigma_x \sigma_y} \quad (1)$$

式中 σ_{xy} 为 x 和 y 的协方差, σ_x 为 x 的标准差, σ_y 为 y 的标准差, μ_x 为 x 的均值, μ_y 为 y 的均值。皮尔逊相关系数取值范围为 $[-1, 1]$, 正值表示正相关, 负值表示负相关, 绝对值越大表示线性相关性越高。

b. 锁相值

任意两 EEG 通道信号 X 和 Y 之间锁相值计算公式为:

$$PLV = |\exp(j\{\Phi_x(t) - \Phi_y(t)\})| \quad (2)$$

其中, $\Phi_x(t)$ 和 $\Phi_y(t)$ 分别为通道 X 和 Y 的瞬时相位。锁相值的取值范围为 $[0, 1]$, 0 表示两通道之间不同步, 1 表示两通道之间完全同步。

c. 相位滞后指数

相位滞后指数是两个 EEG 信号之间的瞬时相位差分布不对称的度量, 其计算公式为:

$$PLI = \left| \left\langle \text{sign}[\sin(\Delta\varphi(t_k))] \right\rangle \right| \quad (3)$$

式中 $\Delta\varphi(t_k)$ 为两 EEG 信号瞬时相位差, $k=1, 2, \dots, N$ 。相位滞后指数的取值范围为 $[0, 1]$, 0 表示两通道之间无耦合, 1 表示两通道之间完全耦合。

Kong 等 [82] 研究了基于 EEG 信号中区域内和区域间相位同步评估驾驶疲劳的方法。研究者发现, 驾驶疲劳状态下的相位同步特征与非疲劳状态存在显著差异, 并建立了一个评估模型用于驾驶员疲劳水平的识别和量化。同时发现了一个简单而重要的空间频率电极对, 即 δ 波段的 Fz-Oz, 可用于评估驾驶员疲劳。此外, 在 NASA-TLX 和 KSS 共同验证下, 作者还发现驾驶疲劳导致额枕叶和后枕叶 EEG 信号 δ 和 α 波段的同步性显著增加。Wang 等 [83] 使用了功能连接值作为特征, 记录驾驶者的 EEG 信号并计算功能连接的强度或相关性值, 揭示了疲劳状态对脑网络功能连接的影响。研究结果表明, 疲劳状态下功能连接值发生显著变化, 这对于识别和理解驾驶疲劳具有重要意义。

还有一些研究利用功能连接矩阵实现疲劳驾驶检测, 比如, Dimitrakopoulos 等 [77] 进行了一项模拟驾驶实验。采用 PDC、DTF 和 PLI 3 种不同方法构建 α 波段的脑功能网络。并以功能连接值作为特征, 对警觉性和疲劳状态进行特征选择和分类。他们将实验前和最后阶段分别定义为警觉状态和疲劳状态。通过 PDC 网络的 22 个判别连接, 取得了最高的检测精度 (84.7%)。Sun 等 [84] 探讨了利用脑功能连接模式进行心理疲劳分类的判别分析方法。研究者通过分析 EEG 信号中的 PDC 功能连接值构建脑功能连接矩阵, 并应用特征选择和分类器模型, 成功区分了心理疲劳和非疲劳状态, 为心理疲劳的识别和分类提供了有潜力的方法。研究中使用留一交叉验证算法证明了疲劳分类的总体准确率为 81.5% ($P < 0.0001$)。Chen 等 [75] 提出了一种基于 PLI 的方法, 将多通道 EEG 转换成功能脑网络连接矩阵, 并将其作为特征输入到多种 CNN 模型中。实验结果显示分类准确率最高为 (95.4±2.0)%, 灵敏度最高为 (93.9±3.1)%, 精度最高为 (95.5±2.4)%, $F1_{\text{score}}$ 最高为 (94.7±2.0)%。作者使用 KSS 作为主观评价指标。这些研究结果表明, 基于功能连接矩阵的 EEG 信号分析方法在疲劳驾驶检测中具有较高的准确性和潜力。

Harvy 等 [85] 通过将功率谱和功能连接值在特征层级和决策层级融合, 成功提升了驾驶疲劳识别的性能。研究结果表明, 融合方法的平均准确率高

于单个特征类别的准确率（特征级融合 84.70%，决策级融合 87.13%，功率特征 80.82%，连通性特征 79.36%）。与上述研究不同，本研究融合了功能连接值和功率谱密度，能够更全面地描述脑网络在驾驶疲劳中的特征变化。作者将模拟驾驶实验中前 15 min 和后 15 min EEG 分别标记为警觉和疲劳样本。

需要注意的是，上述文献都是在单一频段上构建的功能连接网络，而现在有研究应用不同频段间的耦合，即跨频率耦合构建功能连接网络，但这方面的研究还有待深入。杨硕等^[18]的研究设计了脑疲劳诱发实验，通过计算 delta-gamma 波段的相位振幅耦合分析脑网络的特征变化。研究者发现，脑疲劳后前额叶、顶叶和枕叶区域的耦合效应显著降低，而额叶区域的耦合效应显著增强。这一发现为驾驶认知负荷评估和驾驶疲劳检测提供了新的参考和改善方法。Gonzalez-Trejo 等^[79]探讨了感知需求不同情况下模拟驾驶过程中的 EEG theta-gamma 相位-振幅耦合，并发现驾驶过程中存在 EEG 相位-振幅耦合，且其模式和强度随感知需求的变化而变化。这一发现有望进一步提高驾驶疲劳识别的性能，并为驾驶认知负荷评估提供更全面的视角。总之，这些研究结果表明，在功能连接矩阵的应用中，跨频率的耦合分析方法具有提高驾驶疲劳识别性能的潜力。构建脑功能连接矩阵的特征如表 2 所示。

Table 2 Features used in the functional connection matrix construction

表2 用于构建功能连接矩阵的特征	
特征	文献
部分定向相干	[76]
皮尔逊相关	[80]
相位滞后指数	[75]
锁相值	[81]
调制指数	[79]
直接定向相干	[77]
互信息	[78, 86]
幅值锁定位	[87]
同步似然	[17]
平均相位相干性	[82]

文献 [78] 中采用互信息构建功能连接进行疲劳驾驶研究，但文中并没有给出互信息计算公式。文献 [86] 给出了互信息的计算公式，但其研究的是帕金森病患者 EEG 信号。

2.2.2 脑网络空间拓扑特征

2.2.1 中的研究表明，随着 EEG 极节点数量的增加，构建功能连接矩阵所包含的特征量呈指数增长。这可能导致检测速度较慢，并且可能有冗余特征。为了在应用中实现快速且准确的疲劳状态检测，我们可以考虑进行特征挑选或降维，以减少存储与计算成本。此外，为了更有效地检测驾驶中的疲劳状态，越来越多的研究开始利用图论方法从脑功能网络中提取各种拓扑特征。

值得注意的是，在这种方法中，构建功能连接矩阵是一个中间过程，用于从特征中提取更多信息。具体而言，可以计算出由 EEG 极节点构成的脑网络中不同部分之间的连接强度，从而建立功能连接矩阵。然后，可以使用该矩阵来提取不同的拓扑特征，例如节点度、聚集系数、特征路径长度、全局效率与偏心率，这些特征被用作识别疲劳的分类指标^[88-90]。这一方法与前文不同之处在于，前文是直接从 EEG 信号中提取特征。使用网络拓扑特征的方法，除了计算简单，检测速度快之外，还能够提高疲劳状态检测的准确性。

a. 节点度

节点度可以作为衡量节点在网络中的重要性的指标。节点的重要性随着节点度的增加而增加。节点 i 的节点度计算公式为：

$$D(i) = \sum_{i,j \in V, i \neq j} a_{ij} \quad (4)$$

式中 V 是节点集， a_{ij} 指在网络拓扑结构中由节点 j 指向节点 i 。

b. 聚集系数

在图论中，聚集系数衡量相邻顶点聚类的紧密程度。具体来说，就是一个点的相邻点之间的连接强度。节点 i 的聚集系数计算公式为：

$$C(i) = \frac{2E_i}{K_i(K_i - 1)} \quad (5)$$

与节点 i 连接的节点称为节点 i 的邻居节点， E_i 表示节点 i 的邻居节点之间彼此相连的个数， K_i 表示与节点 i 相连接的邻居节点个数。

c. 特征路径长度

特征路径长度是指节点 i 与其他节点之间的平均距离，是衡量网络信息传输有效性的重要指标。节点 i 和 j 之间的最短路径是它们之间传输信息最快的路径，该路径的长度 l_{ij} 是该路径包含的边数。节点 i 的特征路径长度计算公式为：

$$L(i) = \frac{\sum_{ij \in V, i \neq j} l_{ij}}{M-1} \quad (6)$$

式中 M 为网络节点总数。

d. 全局效率

全局效率可用于评估网络的整体性能和运行效率。节点 i 的全局效率计算公式为:

$$G(i) = \frac{1}{M-1} \sum_{ij \in V, i \neq j} \frac{1}{l_{ij}} \quad (7)$$

e. 偏心率

偏心率是指网络中从一个节点到其他节点的最短路径的最大值, 计算公式如下:

$$ECC(i) = \max \{l_{ij} | j \in V\} \quad (8)$$

相对于提取功能连接矩阵特征, 提取拓扑特征更直观且容易理解, 因此, 许多研究选择利用拓扑特征进行相关分析, 以更好地理解 EEG 信号与疲劳之间的关系。例如, Kar 等^[17] 研究睡眠剥夺对 EEG 通道功能连接性的影响。他们发现, 睡眠剥夺会导致 EEG 通道之间连接强度减弱和数量减少, 并改变连接模式, 可能导致注意力、认知和情绪调节方面的问题。Han 等^[91] 总结了基于 EEG 信号的模拟驾驶疲劳时大脑复杂网络特征的分析。研究结果显示, 疲劳状态下大脑的复杂网络特征发生显著变化, 包括小世界性和模块化程度的降低, 以及节点的度中心性和层次性改变。这些特征变化随着疲劳程度的增加而越来越明显。这些研究结果对于理解疲劳对认知和驾驶行为的影响有重要意义。Han 等的研究中根据驾驶时间的增加, 将驾驶状态分为了 T0 阶段、T1 阶段、T2 阶段和 T3 阶段。Li 等^[78] 设计了一个脑疲劳实验。他们使用互信息构建了邻接矩阵, 并将矩阵的最大特征值作为反映相应网络特征的指标。实验结果表明, 在任务状态下, 最大特征值仅在 alpha1 (8~10 Hz) 波段存在显著的统计学差异。随着心理疲劳程度的增加, 最大特征值也增加, 说明最大特征值可以作为考虑脑功能变化的心理疲劳估计指标。进一步研究表明, 即使仅使用少量 EEG 极通道也是可行的。这些研究结果在飞行、交通和工业人类安全等多个领域具有潜在的应用前景。尽管上述研究主要关注了拓扑特征对疲劳驾驶影响的研究, 而没有实现具体的疲劳检测功能, 但是通过进一步探索其他生理或行为特征的结合, 如眼动数据、行为表现等, 与 EEG 信号的拓扑特征相结合, 以提高疲劳检测的准确性和实用性。

提取 EEG 功能连接网络的拓扑特征实现疲劳

驾驶检测已成为近年来的研究热点。Cynthia 等^[81] 的研究应用 PLV 方法构建了睡眠数据中的功能连接矩阵, 提取了关键的拓扑特征。通过使用人工神经网络 (artificial neural network, ANN) 分类器, 他们实现了最高 87.5% 的疲劳驾驶检测精度。Wang 等^[76] 使用部分定向相干性来测量 delta 节律的功能连接强度。并提取了节点度、聚类系数、局部效率和特征路径长度等 4 个拓扑属性。他们使用 SVM 分类器实现了疲劳驾驶的识别, 并达到了 87.16% 的准确率。该研究中他们在驾驶过程开始 30 min 时, 将最后 15 min 的 EEG 记录标记为清醒状态。当连续驾驶过程持续 60~150 min, 直到受试者的面部反应和 EEG 信号显示受试者疲劳时, 将最近记录的 15 min EEG 标记为疲劳。之后, 在此基础上利用专家知识, 进一步利用同步采集的 EEG、眼电和面部视频, 主观上判断被试是否存在精神疲劳。Zheng 等^[87] 提出了一种基于幅值锁定值 (amplitude locking value, ALV) 的方法用于量化信道间的相关性。该方法结合了信号的相位信息和幅度信息, 并利用计算得到的 alpha 波段的 ALV 构建功能连接性网络。他们提取了节点度、最短路径长度和聚集系数等拓扑属性, 并使用 XGBoost 分类器达到了 82.84% 的准确率。研究中使用的数据集是公共数据集 DEED-VIG。Zhou 等^[80] 进行了一项模拟驾驶实验, 使用皮尔逊相关系数计算 EEG 信号通道之间的相关性, 并构建脑功能网络。他们提取并组合了聚类系数、节点度、偏心率、局部效率和特征路径长度等 5 个脑功能网络特征, 并利用 8 种机器学习算法作为分类器, 进行疲劳检测。结果显示, 节点度、局部效率和特征路径长度的特征组合在逻辑回归算法中达到了最佳分类准确率 92.92%。作者在实验开始前采集 5 min 静息 EEG 数据作为清醒状态, 并使用疲劳量表 FS-14 评估被试是否处于疲劳状态。

在疲劳驾驶检测研究中, 一些研究仅使用了拓扑特征进行分类, 而其他研究则综合考虑了功能连接值和拓扑特征。例如, Wang 等^[92] 的研究针对模拟驾驶实验, 应用相位滞后指数构建了功能连接矩阵, 并提取了空间特征。实验结果表明, 通过融合网络拓扑特征和关键连接, 疲劳检测的精度得到了提高, 最高的检测精度达到了 96.76%。该研究中, 根据行为表现, 将前 5 min 和后 5 min 定义为警觉状态和疲劳状态。另外, Liu 等^[93] 的实验结果表明, 在疲劳状态下, 跨频耦合增加, 特别是在

额叶、额叶和顶叶区域的 beta-gamma 耦合。基于这一发现,研究者构建了一种图神经网络 (graph neural network, GNN) 来检测疲劳,分类准确率达到了 96.23%。作者将 EEG 数据最初和最后的 5 min 数据分别标为最警惕和最疲劳状态。这种方法利用了跨频耦合扩散的频内子网络的特征。需要注意的是,以上两个研究综合考虑了功能连接值和拓扑特征,在疲劳驾驶检测中取得了较高的分类精度。通过融合不同类型的特征,可以更全面地捕捉到疲劳状态下 EEG 信号的变化,提高疲劳检测的准确性和可靠性。

综上所述,一些研究仅使用拓扑特征进行分类,而其他研究则综合考虑了功能连接值和拓扑特征。综合考虑不同的特征类型可以提高疲劳驾驶检测的准确性,并为进一步研究提供了有价值的思路。

3 疲劳驾驶检测模型性能评估和评价指标

3.1 模型性能评估

现在模型性能评估的主要方法有被试评估^[94]、被试间评估^[94]和合并被试评估^[69]。通过这些评估方法,可以对模型在不同数据集上的表现进行分析,评估其泛化能力,并检验其对未见过的数据的效果。此外,这些评估方法还有助于比较不同模型或算法在相同任务上的性能,从而帮助选择最佳的模型或优化算法。

a. 被试评估

被试评估是指针对每个被试个体的数据进行独立的模型训练和测试。在每个被试中,其数据被分为训练集和测试集,其检测结果是相应被试个体的分类结果。

b. 被试间评估

被试间评估就是每次训练模型时每个被试的数据只能作为训练集或者测试集。假设有 N 个被试,取其中 $N-1$ 被试的数据作为训练集,剩下一个被试的数据作为测试集。重复这一过程直到每一个被试的数据都被用作测试集去获得测试精度。

c. 合并被试评估

合并被试评估就是将所有被试数据合并去成一个数据集,采用 k 折交叉验证去评估模型。 k 取值一般为 5 或者 10。

图 2 给出了被试评估、被试间评估和合并被试评估 3 种模型评估方法的流程图。

被试评估是指为每个个体建立独立模型,对其

数据进行独立建模和分类。个体化模型在 EEG 分类中有着重要的意义。首先,EEG 信号往往在个体之间存在较大的差异,包括 EEG 波形的形状、频率特征、时空属性等。通过个体化模型,可以更好地捕捉和利用这些个体差异,提高分类准确度和个预测性能。其次,个体化模型可以辅助差异分析和个性化诊断。通过建立个体模型,可以定量化和分析每个个体的 EEG 特征,揭示其在特定任务或疾病状态下的个体特征,为个性化诊断和治疗提供准确依据。最后,个体化模型可以为脑机接口等应用提供定制化的解决方案。通过建立基于个体的模型,可以实现更准确、可靠的脑机接口操作,提高脑控设备的实时性、稳定性和个性化适应性。

合并被试评估就是建立一个集成模型,将多个个体的数据整合在一起进行分类和预测。在 EEG 分类中,整合模型具有重要意义。首先,通过整合多个个体的数据,可以增加样本量并获得更多 EEG 信息,从而提高分类的准确度和稳定性。此外,整合模型可以利用个体之间的差异和特征改善分类器的鲁棒性和泛化能力。其次,EEG 信号在不同个体间存在较大的差异,可能导致某些个体的分类性能较差。通过整合模型,可以混合和整合多个个体的数据,消除个体差异,使分类器能够更好地适应不同个体的特征。最后,整合模型可以从多个个体的数据中抽取一般化规律和共性特征。有助于理解 EEG 信号的一般特征和脑机制,为脑机接口、神经科学研究等领域提供有意义的科学发现。综上所述,个体化模型和整合模型是两个相互关联的概念。个体化模型旨在寻找每个个体的差异,为每个被试量身定制一个模型,以提高检测精度。但是随着人数的增加,个体化模型的数量也会相应增加,增加了模型的复杂性和开销。整合模型旨在消除个体差异,建立一个一般化模型,通过训练丰富的数据提高模型精度。人数越多,个体差异的影响越少,从而提高模型的鲁棒性。

被试间评估和被试评估都是常用的个体化模型评估方法,在个体化建模方面有着不同的特点。被试间评估采用“留一法”,将每个个体数据依次作为测试集,验证模型的泛化能力。通过将不同个体作为测试集来测试模型,可以评估模型对未见过的个体的分类或预测能力。然而,被试间评估存在一些不稳定性,因为建立的个体化模型是通过拟合其他个体的数据来进行预测的。相比之下,被试评估与被试间评估的建模方式有所不同。被试评估建立




Fig. 2 Three model evaluation methods are depicted in a flow chart: subject, inter-subject, and combined subject evaluation

图2 被试评估、被试间评估和合并被试评估3种模型评估方法的流程图

的个体化模型只拟合自身个体的数据, 不使用其他个体的数据。因此, 在建立被试评估的个体化模型时, 结果会相对稳定一些。被试评估可以更加专注于个体自身的特征和规律, 而不受其他个体数据的影响。综上所述, 被试间评估和被试评估是两种常用的个体化模型评估方法。被试间评估可以验证模型的泛化能力, 但结果可能较为不稳定。被试评估则更关注建立个体自身的个体化模型, 结果相对较为稳定。在选择评估方法时, 需要根据具体情况来决定使用哪种方法。

通过前述内容可知, 被试评估和被试间评估方法都是用于建立个体化模型, 每个被试都有一个检测结果。相比之下, 合并被试评估方法旨在建立一个一般化模型, 只有一个检测结果。研究者收集了23名被试在模拟驾驶中的EEG数据, 并使用了被试评估和被试间评估方法建立个体化模型^[94]。结

果显示, 采用被试间评估方法建立的个体化模型的检测精度中位数为74%, 而采用被试评估方法建立的个体化模型的检测精度中位数为81%。然而, 作者并未说明如何标记EEG状态。在文献[19]中, 研究者采用了被试评估、被试间评估和合并被试评估3种评估方法。他们将被试评估和被试间评估建立的个体化模型的检测结果取均值, 作为相应评估方法的最终结果。实验结果显示, 在这3种评估方法中, 被试间评估的检测精度最差, 而被试评估和合并被试评估的检测精度相近, 它们均优于被试间评估。类似的结果也在其他研究^[95]中得到了验证。综上所述, 被试评估方法利用个体差异进行建模, 合并被试评估方法则消除个体差异, 而被试间评估方法是利用已经训练好的模型对新数据进行评估, 个体差异可能导致检测结果不佳。因此, 在疲劳驾驶检测或其他EEG分类任务中, 如果模型在

被试间评估中表现良好, 可以说明该模型具有良好的泛化能力。

3.2 模型评价指标

混淆矩阵 (confusion matrix) 是用于评估分类模型性能的一种表格形式。它对模型的预测结果与实际标签之间的关系进行了可视化呈现。混淆矩阵通常用于二分类问题, 但也可以扩展到多类分类问题。图3为二分类时混淆矩阵的可视化图。图3a表示, 上半部分样本实际为正样本, 下半部分样本实际为负样本; 图3b表示, 模型将左半部分样本预测为正样本, 将右半部分样本预测为负样本; 图3c表示生成了混淆矩阵, 其中左上角和右上角表示预测正确的样本, 而右上角和左下角则表示错误预测的样本。其每一部分的具体解释如下:

真阳性 (true positive, TP): 当EEG是疲劳状态时, 分类器正确地预测它是疲劳的。

真阴性 (true negative, TN): 当EEG是清醒状态时, 分类器正确地预测它是清醒的。

假阳性 (false positive, FP): 当EEG是清醒状态时, 分类器错误地预测它是疲劳的。

假阴性 (false negative, FN): 当EEG是疲劳状态时, 分类器错误地预测它是清醒的。

模型评估指标主要有准确率、错误率、灵敏度、精确度和 $F1_{score}$ 。它们都是根据混淆矩阵演化出来的。

a. 准确率 (accuracy, Acc): 被正确预测的样本个数。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

b. 错误率 (error rate, Err): 被错误分类的样本个数, 与Acc互补。

$$Err = \frac{FP + FN}{TP + TN + FP + FN} \quad (10)$$

c. 灵敏度 (sensitivity, Sen): 表示正样本被识别出的能力, 也就是疲劳EEG被检测出来的比例。

$$Sen = \frac{TP}{TP + FN} \quad (11)$$

d. 精确度 (precision, Pre): 模型预测为疲劳状态样本中, 真实状态也为疲劳状态的样本比例。

$$Pre = \frac{TP}{TP + FP} \quad (12)$$

e. $F1_{score}$: 它结合了灵敏度和精确度的结果, 以平衡正确的预测率疲劳和清醒状态。

$$F1_{score} = \frac{2 \times Sen \times Pre}{Sen + Pre} \quad (13)$$




Fig. 3 Confusion matrix visualization
图3 混淆矩阵可视化

这些评估指标的作用是全面了解模型的性能并进行比较。研究者^[31]计算了模型的准确率、灵敏度、精确度和F1分数, 并分别得到了90.42%、89%、86.51%和88%的结果。高精度度表明该模型在困倦警报方面具有很好的能力。此外, 作者还将他们的方法与现有方法进行了比较, 其结果明显好于现有方法。需要注意的是, 具体实验设计和标签标记方法在文献中并未详细说明。研究者^[66]比较了AdaBoost分类器和其他3种分类器的错误率、灵敏度、精确度等分类指标。结果显示, AdaBoost在总体性能上表现最好。研究者^[19]使用了两个数据集以及3种模型性能评估方法来验证他们提出的模型的可靠性。他们发现, 在PSED数据集上, 指数能量特征在3种评估方法中都取得了最好的准确率, 而在SVDD数据集上, 指数能量特征仅在被试评估和合并被试评估中表现最好, 而对数能量特征在被试间评估中表现最好。因此, 他们比较了这两个特征在这两个数据集上使用3种评估方法得到的详细性能 (包括准确率、灵敏度、精确度和 $F1_{score}$)。结果表明, 在大多数评价指标中, 指数能量特征优于对数能量特征, 因此作者选择了指数能

量特征进行分类。综上所述, 这些评估指标不仅可以全面评估模型的性能, 而且可以指导分类器和特征的选择。

4 EEG信号分类方法

目前常用的EEG分类方法有传统机器学习和深度学习两种方法。在前面的章节已经介绍了一些分类器的应用。本节只是简要概述这些方法的应用现状及其常用分类模型的原理。

4.1 传统机器学习分类方法

现在疲劳驾驶检测研究中采用的分类方法主要是传统机器学习, 包括支持向量机、K近邻算法、AdaBoost、极限学习机(extreme learning machine, ELM)、决策树和随机森林(random forest, RF)等。

支持向量机是一种常用的监督学习算法, 可用于二分类和多分类问题。其目标是在特征空间中找到一个最优的超平面, 将不同类别的样本分开。K近邻算法是另一种常用的监督学习算法, 用于解决分类和回归问题。其原理非常直观和简单, 通过计算新样本与训练集中的样本之间的距离, 并选择距离最近的 K 个样本, 根据这 K 个样本的类别进行投票或计算平均值来进行预测。ELM属于单层前馈神经网络的一种形式。ELM的核心思想是将随机生成的权重和偏差应用于输入层和隐藏层之间的连接, 并利用激活函数将输入信号映射到高维空间。然后通过求解线性方程组的方式计算输出层的权重。ELM在训练过程中的计算时间较短, 在解决分类和回归问题时具有较好的性能, 并且在处理大规模数据集时有优势。决策树用于解决分类和回归问题。它通过对输入数据进行一系列的二分判断, 构建出一棵树状的决策模型。在分类问题中, 决策树根据特征的取值将输入样本划分到不同的类别中。每个决策树节点代表一个特征及其对应的判断规则, 而分支代表具体的特征取值。决策树的叶节点表示最终的分类结果。在回归问题中, 决策树的思想类似, 但是每个叶节点上存储的是一个数值, 代表对输入样本的回归预测结果。

随机森林是一种集成学习算法, 由多个决策树组成, 用于解决分类和回归问题。它的核心思想是通过多个决策树的投票或平均预测结果来进行最终的分类或回归。每个决策树在采样训练数据及特征的随机子集上进行训练, 每个树基于不同的特征子集和数据子集来做决策, 然后综合所有树的预测结

果来做出最终的决策。AdaBoost是另一种流行的集成学习方法, 用于提升弱分类器的预测性能。它通过迭代训练一系列弱分类器, 并根据每个分类器的准确性动态调整样本的权重, 从而得到一个性能较好的集成模型。在迭代过程中, 每个弱分类器的训练被重点关注于先前错误分类的样本上, 以最大程度地减少错误, 最终得到一个能够更好地进行分类的强分类器。

在疲劳驾驶检测中, KNN(K-nearest neighbors)分类器被广泛应用。研究者^[96]收集了驾驶员在不同疲劳和清醒状态下的EEG信号, 并通过离散小波变换对信号进行分解和重构。他们提取了小波系数作为特征, 并利用K近邻分类器对疲劳和清醒状态进行分类。实验结果表明, 当将 K 值设置为5时, 可以得到最佳的疲劳和清醒状态区分效果。研究中将参与者清醒时收集的EEG信号标记为正常状态, 而睡觉时的数据被标记为疲劳状态。此外, 有研究采用Emotiv EPOC+EEG设备进行驾驶员疲劳状态的分类^[97]。研究者采集了驾驶员在不同疲劳状态下的EEG数据, 并利用多种信号处理和特征提取方法, 如快速傅里叶变换、频谱分析和时域统计特征, 提取了相关特征。通过支持向量机和K近邻分类器对提取的特征进行分类, 结果显示, KNN分类方法的平均准确率为90%~100%, 而使用SVM分类方法的平均准确率为60%~90%。作者使用改进后的KSS进行主观评价。胡剑锋等^[98]提出了基于EEG信号模糊熵的驾驶疲劳检测分析方法。该方法选择模糊熵作为特征来衡量EEG信号的复杂度和不确定性, 进而采用随机森林、支持向量机、决策树和K近邻等四种分类器进行EEG信号的分类。实验结果表明, 这四种分类器均表现出良好的疲劳检测能力, 其中K近邻方法的平均准确率达到了97.4%的高水平。研究者首先让被试自由驾驶20 min, 并将最后5 min的EEG数据标记为正常状态组。然后, 被试进行单调驾驶30~120 min, 直到综合检测为疲劳状态, 并将最后5 min的EEG数据标记为疲劳状态组。

研究者^[99]设计了一个模拟驾驶实验, 通过计算前额叶EEG信号的多种熵作为输入特征, 并构建了一个快速有效的混合模型来检测驾驶员疲劳。该混合模型包含逻辑回归(logistic regression, LR)、极限学习机和光梯度增强机(light gradient boosting machine, LightGBM)。实验结果表明, 在多种熵指标中, 小波对数能量熵(wavelet

log-energy entropy, WLE) 表现出更好的识别率和计算效率, 最高检测精度达到了94.2%。三种方法被采用来衡量疲劳的发生: a. 面部表情监控视频; b. 使用驾驶模拟教学软件中的练习分数, 根据驾驶成绩下降自动扣分(初始分数为100分); c. 一份自我报告的疲劳问卷, 参照Chalder疲劳量表和Li's主观疲劳量表使用。Luo等^[100]提出了一种新的驾驶疲劳EEG检测的特征选择方法和改进的机器学习算法。研究者通过集成经验模态分解(ensemble empirical mode decomposition, EEMD)和PSD的新方法, 将其与排列熵、样本熵和模糊熵等6个特征进行比较。实验结果显示, 基于内禀模态函数(intrinsic mode function, IMF)分量的特征在实验分类精度和重叠率方面优于其他特征。通过通道优化和准确率比较, 研究者发现基于改进的分层极限学习机算法和基于粒子群优化的层次极限学习机(particle swarm optimization, PSO-H-ELM)分类器的特征选择方法具有更好的性能, 其平均准确率最高, 达到了94.58%。该研究的模拟实验是在晚上进行, 持续0.5 h, 作者并未介绍EEG样本标记标准。综上所述, 对于进一步提高驾驶疲劳检测的层次性改进, 可以在特征选择优化、模型集成优化等方面进行探索。

4.2 深度学习分类方法

深度学习是一种机器学习方法, 其核心思想是通过多层次的神经网络模型来学习和表示复杂的模式和关系。借鉴人脑神经网络结构, 深度学习使用多个神经元层次和权重调整进行信息处理和学习。其中包括深度信念网络(deep belief network, DBN)、卷积神经网络和循环神经网络(recurrent neural network, RNN)等。DBN是一种深度神经网络模型。它由多个叠加的限制玻尔兹曼机(restricted Boltzmann machine, RBM)组成, 通过逐层的预训练和微调, DBN能够自动学习输入数据的高级特征表示。CNN是一种特殊类型的深度学习神经网络, 主要用于处理具有网格结构的数据, 如图像。它通过多层次的卷积、池化和全连接层来提取和学习图像中的关键特征, 具有良好的特征提取和模式识别能力。在疲劳驾驶检测中, CNN已经被广泛用于处理驾驶员脸部表情图像。长短时记忆网络(long short-term memory network,

LSTM)是一种常用的循环神经网络结构, 用于处理序列数据和时序问题。相比于传统的RNN, LSTM能够更好地捕捉和记忆长期的依赖关系, 对于疲劳驾驶检测中的时间序列数据, 如EEG信号, LSTM有较好的效果。

为了提高EEG疲劳检测的准确性和自动化程度, 目前的研究主要集中于采用不同的方法对原始EEG数据进行分类。其中, 使用CNN是一种常用的方法, 该方法达到了90.42%和94%的检测准确率^[31, 95]。另外, Gao等^[101]提出了一种基于递归网络的卷积神经网络(recurrence network-based convolutional neural network, RN-CNN)方法, 通过多重递归网络对原始EEG信号进行降维和信息整合, 再利用CNN对提取的网络矩阵信息进行融合, 实现92.95%的准确率。Jiao等^[14]使用LSTM网络将EEG分为放松清醒和睡眠开始两类, 分类准确率达到98%, 依靠 α 波阻塞现象和 α 波衰减消失现象为真值标签。此外, Li等^[102]提出了基于DBN和单通道EEG的心理疲劳检测方法, 使用多个特征作为DBN输入, 实现了98.86%的检测精度。作者将主观评价(KSS)和实际行为(面部状态)这两种重要且常用的心理驾驶疲劳生理指标结合起来监测被试的状态。除了CNN以外, 一些研究采用生成对抗网络、递归网络和深度置信网络等方法关注驾驶员睡意检测和心理疲劳检测, 旨在提高检测的准确性。总的来说, 这些研究为发展高效准确的EEG疲劳检测技术提供了重要的理论基础和实践方法。

相对于深度学习算法而言, 传统机器学习算法往往更容易解释和理解, 可以提供对模型内部逻辑的解释和推断。然而, 在处理大规模数据和复杂任务时, 传统机器学习算法的性能可能受到限制, 因为它们可能不够高效。相比之下, 深度学习算法在处理大规模数据和复杂任务时通常表现出色, 因为它们能够发掘更多的信息和模式。综上所述, 传统机器学习和深度学习各自在不同领域和任务中都有其适用性和局限性。在决定使用哪种学习方法时, 应该考虑问题的复杂性、可用数据和计算资源以及对结果解释性的需求。这样就可以做出更加明智的决策, 选择最适合的学习方法来解决当前任务。对疲劳驾驶检测文献的总结如表3所示。

Table 3 Summary of application status of fatigue driving detection
表3 疲劳驾驶检测的应用现状总结

特征	分类器	电极	Acc	文献
时域特征、频域特征	长短时记忆网络	6电极	98.00%	[14]
时域特征、熵	正则贪心森林	Oz	两个数据集分别为92.80%和82.00%	[19]
时域特征	极端随机树	Fpz-Cz和T7	两个数据集分别为94.45%和85.36%	[34]
原始脑电	卷积神经网络	14电极	90.42%	[31]
频域特征	阈值	64电极	ROC 0.78	[36]
时域特征、频域特征	BP神经网络	Fp1、Fp2、Fz	97.00%	[40]
频域特征	K近邻	32电极	99.99%	[51]
拓扑特征	逻辑回归	32电极	92.92%	[80]
频域特征、熵	卷积神经网络	17电极	91.31%	[61]
熵	AdaBoost	32电极	97.50%	[66]
熵	梯度增强决策树	32电极	94.00%	[67]
熵	支持向量机	32电极	85.00%	[68]
频域特征、熵、功能连接矩阵	BP_Adaboost	24电极	92.70%	[70]
功能连接矩阵	卷积神经网络	14电极	95.40%	[75]
拓扑特征	支持向量机	36电极	87.16%	[76]
功能连接矩阵	支持向量机	62电极	84.70%	[77]
频域特性、功能连接矩阵	支持向量机	24电极	87.13%	[85]
拓扑特征	XGBoost	17电极	82.84%	[87]
拓扑特征	支持向量机	30电极	99.17%	[90]
拓扑特征	人工神经网络	16电极	87.50%	[81]
功能连接矩阵、拓扑特征	支持向量机	24电极	96.76%	[92]
功能连接矩阵、拓扑特征	图神经网络	24电极	96.23%	[93]
原始脑电	卷积神经网络	1电极	94.00%	[95]
频域特征	K近邻	14电极	96.00%	[97]
熵	K近邻	32电极	97.40%	[98]
熵	逻辑回归、极限学习机、光梯度增强机	40电极	94.20%	[99]
频域特征	分层极限学习机	32电极	94.58%	[100]
原始脑电	递归网络的卷积神经网络	40电极	92.95%	[101]
熵、频域特征	深度信念网络	1电极	98.86%	[102]

ROC: 接受者操作特性曲线 (receiver operating characteristic curve)。疲劳驾驶检测中常用的评价指标是Acc, 表格中最后一列Acc表示实验结果, 除文献 [36] 的结果用ROC表示, 其他研究都是使用最佳Acc表示研究结果。

5 基于EEG信号的疲劳驾驶检测研究面临的问题

进行疲劳驾驶检测时, 目前的实验通常采用模拟驾驶而非真实驾驶的方法, 然而, 这种选择可能会对检测结果产生一定影响。首先, 在模拟驾驶实验中, 驾驶环境和真实道路条件可能存在一定的差异, 如道路宽度、交通流量、气象条件等, 这可能影响驾驶员的疲劳程度和行为。其次, 虚拟现实或驾驶模拟器在模拟驾驶实验中的使用可能限制了驾驶员对真实情境的感知和对外界信息的反应。最后, 缺乏真实环境的压力和紧张感可能导致驾驶员

的EEG信号与真实驾驶时的信号有所不同, 从而影响疲劳检测的结果。尽管模拟驾驶实验是从安全和伦理的考量出发, 提供一些实验数据和研究成果, 帮助理解驾驶疲劳的机理和检测方法, 但与真实驾驶相比, 仍存在一定差异。目前, 越来越多的研究开始关注在真实驾驶环境中进行疲劳检测。例如, Fu等 [8] 描述了在真实的公交路线上让被试驾驶3.5 h的实验, 还有研究选择在低压缺氧高原环境下进行实验 [38], 以模拟特定环境条件下的真实驾驶情境。这些研究结果表明, 在真实驾驶环境中进行疲劳驾驶检测的实验是可行的。然而, 在进行这样的实验之前, 需要与被试进行详细的沟通, 并

对危险发生概率进行全面评估,同时准备好详细的应对措施。尽可能在真实驾驶环境中进行疲劳检测实验是理想的选择,因为它更贴近真实驾驶情境,相较于虚拟驾驶具有明显差异。然而,由于实验成本高或者存在较高的危险性,模拟驾驶仍是一个合适的替代方案。总的来说,根据研究目的和条件,可以权衡利弊,选择最适合的实验方法。在进行真实驾驶实验时,与被试的充分沟通和全面风险评估对实验的安全性和有效性至关重要。而模拟驾驶可以提供初步的数据和结果,有助于理解疲劳驾驶的机理和检测方法。为了增加检测方法在现实驾驶环境中应用的可能性,建议研究者在真实的驾驶环境中开展相关实验。

相比传统机器学习模型,深度学习对大量训练数据的需求更高,越来越多的研究使用深度学习模型来检测疲劳^[14, 32, 95]。由于深度神经网络通常具有众多参数,因此需要充足的数据来准确优化这些参数。如果可用的数据量不足,可能会影响深度学习模型的性能和泛化能力。为了解决这个问题,研究者通常采用数据增强(data augmentation, DA)^[32]的方法来扩充数据集,从而显著提升网络性能。然而,数据增强也存在潜在的问题和限制。首先,生成的数据可能无法完全涵盖真实数据集中的所有情况和变化,这可能导致模型在真实场景时的性能下降。其次,生成的数据可能存在一定的偏差或噪声,对模型训练带来负面影响。此外,数据生成过程还可能增加训练的计算复杂性和时间成本,需要额外的计算资源和时间。为了解决数据不足的问题,可以增加参与实验的被试数量,并确保每次实验的时长足够长。这样可以增加数据量,从而解决数据增强所带来的问题。然而,增加被试数量也可能会增加额外的成本。

进行疲劳驾驶检测研究需要大量的标注数据,即将EEG信号与实际疲劳水平进行对应标记。然而,目前存在一些不合理的标注方法,例如有的研究^[66]将实验中前几分钟和最后几分钟的EEG数据分别标记为清醒和疲劳状态。这样的标注方法与实际驾驶环境存在偏差,严重影响了数据的准确性。有时会让被试填写量表^[48]、记录反应时间和错误率^[84]然后通过对比差异来侧面证明被试警戒状态发生了变化。然而,受试者的主观评估和任务的主动参与可能会影响结果的准确性,而仅依靠反应时间来标识疲劳可能存在结果解释困难。目前,许多研究将主观的自我评价作为标签依据,其中最常用

的是KSS。KSS分为9个等级,前4个等级描述警觉性,第5个等级是中性,后4个等级描述嗜睡。然而,警觉性和困倦的4个级别有相似之处,很难判断相邻等级之间的距离是否相同。由于KSS是一种主观量表,相邻水平之间的差异很小,可能导致主观性偏差和基本真理标签的不一致^[103]。另一些研究尝试通过专家知识^[76, 104]进行标注。然而标注过程可能存在主观性、一致性和错误。为了解决数据标注问题,可以综合多种评估方法,例如面部录像、驾驶时车辆性能以及驾驶人员的行为表现。此外,需要对标注人员进行专业的培训与指导,并且进行交叉评估,以确保评估的稳定性和一致性。统一的数据标注标准对于提高数据质量、确保可比性、提高数据可信度、优化数据利用效果等方面具有重要意义。它可以减少标注人员之间的主观差异,降低标注错误和误导性的标注结果,从而提高数据的质量和可靠性。同时,制定统一的标注标准可以使不同标注人员对相同数据进行一致的标注,确保数据的可比性。这样可以更准确地比较不同数据样本之间的差异和共性,在后续的数据分析和模型训练中得到更精确的结果。因此,为了确保数据的一致性和准确性,标注人员需要接受专业的培训与指导,并进行交叉评估。此外,制定统一的标注标准可以提高数据的可信度,让数据使用者更加放心地进行决策和应用。统一标准能够提高数据的可靠性和可信度,增强数据的应用价值,并减少数据分析过程中产生解释上的困惑和额外成本。

当前,存在技术泛化问题的挑战,许多研究方法仅适用于特定的实验条件和受试者群体。在一些研究中,方法在研究者设计的实验中表现良好,但在更换数据集之后表现较差。这一问题已经在文献中得到了验证^[76, 87]。原因包括标注标准的不统一、实验环境的差异以及被试的年龄、性别和驾驶经验等因素的影响。同时,之前也提到过采用“留一法”时,实验的准确度普遍较低,这是由于个体差异导致的。为了解决这一问题,我们需要考虑以下几个方面:首先,需要确保对数据的标注标准进行统一。其次,为了消除被试者因素的影响,需要足够数量的被试参与实验(至少100人)。此外,实验应该在多种环境中设计和收集数据,至少包括真实驾驶中80%的驾驶情境(比如高速公路、城市道路、雨天、雪天、乡村道路等)。最后,现在很多研究中使用的数据是私人的,如果能够共享这些数据,那么我们就可以使用我们自己的检测方法在

这些不同数据集中进行验证,从而检验疲劳检测方法泛化能力。如果按照这些原则进行研究,所提出的方法在泛化性能上将得到提升。

在基于EEG信号的疲劳驾驶检测中,实时性是一个关键问题。由于EEG信号的采集和分析通常需要较长的时间和复杂的计算过程,如何实时地进行疲劳状态的检测是一个具有挑战性的任务。为了提高实时性,可以采取以下措施。首先,优化信号预处理和特征提取方法,以减少处理时间。可以采用实时的滤波技术和快速的特征提取算法,加速信号处理过程。其次,选择适合实时应用的分类算法和模型。可以考虑使用轻量级模型或采用深度学习算法进行加速,以在较短时间内进行疲劳状态的分类和预测。然后,结合硬件与软件的优化,提高系统的实时性能。例如,采用高速采样率的硬件设备或优化算法的编程实现,以加速信号采集和分析过程。然而,在追求实时性的同时,也必须保持疲劳状态检测的准确性。需要权衡实时性和准确性之间的平衡,根据应用的实际需求进行调整和优化。在系统设计和算法选择时,需要评估实时性和准确性之间的权衡,确保疲劳状态的判定结果既能及时准确,又能满足实时应用的要求。综上所述,通过优化信号处理和特征提取、选择高效的分类模型、硬件与软件优化,并综合考虑实时性和准确性的权衡,可以解决基于EEG信号疲劳驾驶检测的实时性问题,并提供及时的警示和决策支持。这些措施将有助于提高疲劳驾驶检测系统的实用性和有效性。

针对未来的研究,我们建议采取以下措施。首先,制定一个统一标准的数据标注准则,以减少主观偏差的影响。确保标注的一致性和可靠性,减少误差来源。其次,实验应尽可能在真实驾驶环境中进行,因为模拟环境和真实环境存在差异。通过模拟真实驾驶情境,使得研究成果具有更好的现实适用性和泛化能力。此外,被试样本的数量应足够多,以确保数据的代表性和可靠性。通过增加被试样本的数量,可以更好地反映不同人群和驾驶情境下的疲劳驾驶特征,提高检测模型的可靠性和泛化能力。同时,应该在多种驾驶环境下进行实验,以确保所提出的疲劳驾驶检测技术具有良好的泛化能力。例如,将实验设计包括高速公路、城市道路、恶劣天气等不同驾驶环境,以更全面地评估检测技术的效果和应用范围。最后,在实现检测的实时性方面,应优化数据采集、特征提取和分类模型。采用高效的数据采集设备和算法,加速处理过程,提

高实时性。在特征提取和分类模型的选择上,需要在实时性和准确性之间寻找合适的平衡点,确保实时性的同时不牺牲准确度。综上所述,通过制定统一标准的数据标注准则,进行真实驾驶环境的实验,增加样本数量,考虑不同驾驶环境下的评估和优化实时性,可以推动疲劳驾驶检测技术的发展,并提高其应用的实用性和有效性。这些措施将为未来的研究提供指导,并促进疲劳驾驶检测技术的进一步改进和应用。

6 总结与展望

本文通过对疲劳驾驶检测领域的综述,从5个方面对基于EEG的疲劳驾驶检测进行了总结。首先介绍了EEG信号疲劳驾驶检测基本框架。其次,探讨了当前基于EEG信号的特征提取方法。然后,介绍了疲劳驾驶检测中常用的性能评估和评价指标。接着,介绍了目前常用的检测模型。最后,总结了当前研究中存在的问题,并提出了解决方法。值得注意的是,当前基于EEG信号的疲劳驾驶检测方法常需要使用专业设备进行信号采集,这限制了其在实际驾驶环境中的应用。因此,未来的研究需要探索更便携式的EEG信号采集装置,以降低采集成本并提高实用性。除此之外,疲劳驾驶检测涉及的个体差异性需要被充分考虑。每个人的疲劳表现和EEG信号特征可能存在差异。因此,未来的研究可以探索建立个性化的模型,根据个体特点和模式实现更准确的个性化疲劳驾驶检测。另外,疲劳驾驶检测不仅需要考虑单一的EEG生理信号,还应综合考虑其他生理信号,如心率和眼动信号等,以提高检测的准确性和可靠性。融合多种生理信号的检测方法将是未来的一个研究方向。未来的发展趋势将是融合多个特征进行疲劳驾驶检测,如EEG信号的时域特征、频域特征、熵和空间特征等。相较于仅使用单一特征,多特征融合可以更全面地描述驾驶员的状态,并提高模型的检测精度。这样做可以充分挖掘不同特征之间的相关性和互补性,更准确地反映驾驶员的疲劳状态。

综上所述,基于EEG信号的疲劳驾驶检测方法为识别和防止疲劳驾驶带来的安全隐患提供了潜在的解决方案。未来的研究应以提高检测准确性、降低设备成本、优化特征提取和分类方法为目标,并将研究成果应用于实际的驾驶场景中,以改善道路交通安全,保护驾驶员和其他道路使用者的生命和财产安全。

参 考 文 献

- [1] 裴玉龙, 金英群, 陈贺飞. 基于脑电信号分析的不同年龄驾驶人疲劳特性. 中国公路学报, 2018, **31**(4): 59-65, 77
Pei Y L, Jin Y Q, Chen H F. China Journal of Highway and Transport, 2018, **31**(4): 59-65, 77
- [2] 欧阳晋. 疲劳驾驶“驶”不得--吉林省松原市“10·4”重大道路交通事故回顾. 广东安全生产, 2021(6): 64-65
Ou Y J. Guangdong Production Safety, 2021(6): 64-65
- [3] World Health Organization. Global status report on road safety 2018. Geneva: WHO, 2019: 4-7
- [4] Sagaspe P, Taillard J, Akerstedt T, *et al.* Extended driving impairs nocturnal driving performances. PLoS One, 2008, **3**(10): e3493
- [5] 江跃龙, 张铭智. 基于PERCLOS的列车司机疲劳检测设计与实现. 计算机时代, **2023**(4): 112-115
Jiang Y L, Zhang M Z. Computer Times, **2023**(4): 112-115
- [6] Trutschel U, Sirois B, Sommer D, *et al.* PERCLOS: an alertness measure of the past//Boyle L, Carney C, Lee J D, *et al.* Driving Assessment Conference. Iowa state: University of Iowa, 2011: 172-179
- [7] 蔡素贤, 杜超坎, 周思毅, 等. 基于车辆运行数据的疲劳驾驶状态检测. 交通运输系统工程与信息, 2020, **20**(4): 77-82
Cai S X, Du C K, Zhou S Y, *et al.* Journal of Transportation Systems Engineering & Information Technology, 2020, **20**(4): 77-82
- [8] Fu R R, Wang H, Zhao W B. Dynamic driver fatigue detection using hidden Markov model in real driving condition. Expert Syst Appl, 2016, **63**: 397-411
- [9] Wang H, Dragomir A, Abbasi N I, *et al.* A novel real-time driving fatigue detection system based on wireless dry EEG. Cogn Neurodyn, 2018, **12**(4): 365-376
- [10] 刘东华, 刘庆华, 李杨, 等. 基于PERCLOS的疲劳驾驶检测研究. 计算机与数字工程, 2022, **50**(7): 1583-1586, 1608
Liu D H, Liu Q H, Li Y, *et al.* Computer & Digital Engineering, 2022, **50**(7): 1583-1586, 1608
- [11] Bergasa L M, Nuevo J, Sotelo M A, *et al.* Real-time system for monitoring driver vigilance. IEEE T Intell Transp, 2006, **7**(1): 63-77
- [12] Shen J, Liu D, Shen J, *et al.* A novel sensors-based and multiple warning early fatigue detection system architecture//Chao H C, Leung V, Park J J. 2015 First International Conference on Computational Intelligence Theory, Systems and Applications (CCITSA). Iian, Taiwan, China: IEEE, 2015: 193-196
- [13] Zheng W L, Lu B L. A multimodal approach to estimating vigilance using EEG and forehead EOG. J Neural Eng, 2017, **14**(2): 026017
- [14] Jiao Y Y, Deng Y N, Luo Y, *et al.* Driver sleepiness detection from EEG and EOG signals using GAN and LSTM networks. Neurocomputing, 2020, **408**: 100-111
- [15] Hasan M M, Watling C N, Larue G S. Physiological signal-based drowsiness detection using machine learning: singular and hybrid signal approaches. J Safety Res, 2022, **80**: 215-225
- [16] Gwak J, Hirao A, Shino M. An investigation of early detection of driver drowsiness using ensemble machine learning based on hybrid sensing. Appl Sci, 2020, **10**(8): 2890
- [17] Kar S, Routray A. Effect of sleep deprivation on functional connectivity of EEG channels. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2013, **43**(3): 666-672
- [18] 杨硕, 冀亚坤, 王磊, 等. 基于脑疲劳的Delta-Gamma相位幅值耦合研究. 中国生物医学工程学报, 2018, **37**(4): 445-450
Yang S, Ji Y K, Wang L, *et al.* Chinese Journal of Biomedical Engineering, 2018, **37**(4): 445-450
- [19] Balam V P, Chinara S. Development of single-channel electroencephalography signal analysis model for real-time drowsiness detection: SEEGDD. Phys Eng Sci Med, 2021, **44**(3): 713-726
- [20] 王忠民, 郑翰林, 赵玉鹏, 等. 基于脑电信号的疲劳驾驶检测研究综述. 西安邮电大学学报, 2022, **27**(6): 52-66
Wang Z M, Zheng R L, Zhao Y P, *et al.* Journal of Xi'an University of Posts and Telecommunications, 2022, **27**(6): 52-66
- [21] 王洪涛, 殷浩钧, 陈创泉, 等. 基于脑电信号的驾驶疲劳检测综述. 华中科技大学学报, 2022, **50**(11): 54-65
Wang H T, Yin H J, Chen C Q, *et al.* Journal of Huazhong University of Science and Technology (Natural Science Edition), 2022, **50**(11): 54-65
- [22] Stancin I, Cifrek M, Jovic A. A review of EEG signal features and their application in driver drowsiness detection systems. Sensors (Basel), 2021, **21**(11): 3786
- [23] Balandong R P, Ahmad R F, Saad M N M, *et al.* A review on EEG-based automatic sleepiness detection systems for driver. IEEE Access, 2018, **6**: 22908-22919
- [24] Cohen M X, Elger C E, Fell J. Oscillatory activity and phase-amplitude coupling in the human medial frontal cortex during decision making. J Cogn Neurosci, 2009, **21**(2): 390-402
- [25] Tort A B, Komorowski R W, Manns J R, *et al.* Theta-gamma coupling increases during the learning of item-context associations. Proc Natl Acad Sci USA, 2009, **106**(49): 20942-20947
- [26] Reinhart R M G, Nguyen J A. Working memory revived in older adults by synchronizing rhythmic brain circuits. Nat Neurosci, 2019, **22**(5): 820-827
- [27] Salimpour Y, Anderson W S. Cross-frequency coupling based neuromodulation for treating neurological disorders. Front Neurosci, 2019, **13**: 125
- [28] De Hemptinne C, Swann N C, Ostrem J L, *et al.* Therapeutic deep brain stimulation reduces cortical phase-amplitude coupling in Parkinson's disease. Nat Neurosci, 2015, **18**(5): 779-786
- [29] Amiri M, Frauscher B, Gotman J. Phase-amplitude coupling is elevated in deep sleep and in the onset zone of focal epileptic seizures. Front Hum Neurosci, 2016, **10**(59): 387
- [30] Hinrichs H, Scholz M, Baum A K, *et al.* Comparison between a wireless dry electrode EEG system with a conventional wired wet electrode EEG system for clinical applications. Sci Rep, 2020, **10**(1): 5218
- [31] Chaabene S, Bouaziz B, Boudaya A, *et al.* Convolutional neural

- network for drowsiness detection using EEG signals. *Sensors* (Basel), 2021, **21**(5): 1734
- [32] Zhang Y, Guo H, Zhou Y, *et al.* Recognising drivers' mental fatigue based on EEG multi-dimensional feature selection and fusion. *Biomedical Signal Processing Control*, 2023, **79**: 104237
- [33] Cao Z H, Chuang C H, King J K, *et al.* Multi-channel EEG recordings during a sustained-attention driving task. *Sci Data*, 2019, **6**(1): 19
- [34] Venkata P B, Chinara S. Automatic classification methods for detecting drowsiness using wavelet packet transform extracted time-domain features from single-channel EEG signal. *J Neurosci Methods*, 2021, **347**: 108927
- [35] Venkata P B, Chinara S. Time domain parameters as a feature for single-channel EEG-based drowsiness detection method//Kapri D, Sharma V, Jain A, *et al.* 2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS). Bhopal, India: IEEE, 2020: 1-5
- [36] Zhang Y, Ma J, Zhang C, *et al.* Electrophysiological frequency domain analysis of driver passive fatigue under automated driving conditions. *Sci Rep*, 2021, **11**(1): 20348
- [37] Rifai C, Smith M R, Nguyen T N, *et al.* Comparing features extractors in EEG-based cognitive fatigue detection of demanding computer tasks//Jung R, Wheeler B, Otto K, *et al.* 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Milan, Italy: IEEE, 2015: 7594-7597
- [38] Jing D, Liu D, Zhang S, *et al.* Fatigue driving detection method based on EEG analysis in low-voltage and hypoxia plateau environment. *Int J Transp Sci Technol*, 2020, **9**(4): 366-376
- [39] Wu E Q, Cao Z, Xiong P, *et al.* Brain-computer interface using brain power map and cognition detection network during flight. *IEEE ASME Transactions on Mechatronics*, 2022, **27**(5): 3942-3952
- [40] Wang Y, Liu X, Zhang Y, *et al.* Driving fatigue detection based on EEG signal//Zhou Y, Li F, Zheng F C, *et al.* 2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC). Qinhuaingdao, China: IEEE, 2016: 715-718
- [41] Wang R F, Wang J, Yu H T, *et al.* Power spectral density and coherence analysis of Alzheimer's EEG. *Cogn Neurodynamics*, 2015, **9**(3): 291-304
- [42] Akin M, Kiymik M K. Application of periodogram and AR spectral analysis to EEG signals. *J Med Syst*, 2000, **24**(4): 247-256
- [43] Ameera A, Saidatul A, Ibrahim Z. Analysis of EEG spectrum bands using power spectral density for pleasure and displeasure state//Razlan Z M. IOP conference Series: Materials Science and Engineering. Indonesia: IOP Publishing, 2019: 012030
- [44] Kiymik M K, Subasi A, Ozcalik H R. Neural networks with periodogram and autoregressive spectral analysis methods in detection of epileptic seizure. *J Med Syst*, 2004, **28**(6): 511-522
- [45] Al Ghayab H R, Li Y, Siuly S, *et al.* Epileptic EEG signal classification using optimum allocation based power spectral density estimation. *IET Signal Process*, 2018, **12**(6): 738-747
- [46] Noshadi S, Abootalebi V, Sadeghi M T, *et al.* Selection of an efficient feature space for EEG-based mental task discrimination. *Biocybern Biomed Eng*, 2014, **34**(3): 159-168
- [47] Wu E Q, Hu D, Deng P Y, *et al.* Nonparametric bayesian prior inducing deep network for automatic detection of cognitive status. *IEEE Trans Cybern*, 2021, **51**(11): 5483-5496
- [48] Gharagozlou F, Nasl Saraji G, Mazloumi A, *et al.* Detecting driver mental fatigue based on EEG alpha power changes during simulated driving. *Iran J Public Health*, 2015, **44**(12): 1693-1700
- [49] Awais M, Badruddin N, Drieberg M. Driver drowsiness detection using EEG power spectrum analysis//Ismail M, Noor N M, Ramli N. 2014 IEEE Region 10 symposium. Kuala Lumpur, Malaysia: IEEE, 2014: 244-247
- [50] Arefnezhad S, Hamet J, Eichberger A, *et al.* Driver drowsiness estimation using EEG signals with a dynamical encoder-decoder modeling framework. *Sci Rep*, 2022, **12**(1): 2650
- [51] Rashid M, Mustafa M, Sulaiman N, *et al.* Random subspace K-NN based ensemble classifier for driver fatigue detection utilizing selected EEG channels. *Trait Signal*, 2021, **38**(5): 1259-1270
- [52] Min J, Wang P, Hu J. The original EEG data for driver fatigue detection. London: Digital Science, 2017. <https://doi.org/10.6084/m9.figshare.5202739.v1>
- [53] Huang K C, Huang T Y, Chuang C H, *et al.* An EEG-based fatigue detection and mitigation system. *Int J Neural Syst*, 2016, **26**(4): 1650018
- [54] Shannon C E. A mathematical theory of communication. *Bell System Technical Journal*, 1948, **27**(3): 379-423
- [55] Richman J S, Moorman J R. Physiological time-series analysis using approximate entropy and sample entropy. *Am J Physiol Heart Circ Physiol*, 2000, **278**(6): H2039-H2049
- [56] Chen W, Wang Z, Xie H, *et al.* Characterization of surface EMG signal based on fuzzy entropy. *IEEE Trans Neural Syst Rehabil Eng*, 2007, **15**(2): 266-272
- [57] Bandt C, Pompe B. Permutation entropy: a natural complexity measure for time series. *Phys Rev Lett*, 2002, **88**(17): 174102
- [58] Renner R, Wolf S. Smooth Renyi entropy and applications//Costello D J, Hajek B J. International Symposium on Information Theory, 2004. ISIT 2004. Proceedings. Chicago, IL, USA: IEEE, 2004: 233
- [59] Tsallis C, Mendes R, Plastino A R. The role of constraints within generalized nonextensive statistics. *Phys A Stat*, 1998, **261**(3-4): 534-554
- [60] Kannathal N, Choo M L, Acharya U R, *et al.* Entropies for detection of epilepsy in EEG. *Comput Methods Programs Biomed*, 2005, **80**(3): 187-194
- [61] Li G F, Zhang L, Zou Y, *et al.* Driver vigilance detection based on limited EEG signals. *IEEE Sens J*, 2023, **23**(12): 13387-13398
- [62] Sriraam N, Padma Shri T K, Maheshwari U. Recognition of wake-sleep stage 1 multichannel eeg patterns using spectral entropy features for drowsiness detection. *Australas Phys Eng Sci Med*, 2016, **39**(3): 797-806

- [63] Wang P, Min J, Hu J. Ensemble classifier for driver's fatigue detection based on a single EEG channel. *IET Intell Transp Syst*, 2018, **12**(10): 1322-1328
- [64] Borowska M. Entropy-based algorithms in the analysis of biomedical signals. *Studies in Logic, Grammar and Rhetoric*, 2015, **43**(1): 21-32
- [65] Luo H W, Qiu T R, Liu C, *et al.* Research on fatigue driving detection using forehead EEG based on adaptive multi-scale entropy. *Biomed Signal Proces*, 2019, **51**: 50-58
- [66] Hu J. Automated detection of driver fatigue based on AdaBoost classifier with EEG signals. *Front Comput Neurosci*, 2017, **11**: 72
- [67] Hu J, Min J. Automated detection of driver fatigue based on EEG signals using gradient boosting decision tree model. *Cogn Neurodyn*, 2018, **12**(4): 431-440
- [68] Mu Z D, Hu J F, Yin J H. Driving fatigue detecting based on EEG signals of forehead area. *Int J Pattern Recogn*, 2017, **31**(5): 1750011
- [69] Wang P, Min J L, Hu J F. Ensemble classifier for driver's fatigue detection based on a single EEG channel. *IET Intell Transp Syst*, 2018, **12**(10): 1322-1328
- [70] Liu X, Li G, Wang S, *et al.* Toward practical driving fatigue detection using three frontal EEG channels: a proof-of-concept study. *Physiol Meas*, 2021, **42**(4): 044003
- [71] Zhang C, Cong F, Wang H. Driver fatigue analysis based on binary brain networks//Busra. 2017 Seventh International Conference on Information Science and Technology (ICIST). Da Nang, Vietnam: IEEE, 2017: 485-489
- [72] Park H J, Friston K. Structural and functional brain networks: from connections to cognition. *Science*, 2013, **342**(6158): 1238411
- [73] Sporns O. Contributions and challenges for network models in cognitive neuroscience. *Nat Neurosci*, 2014, **17**(5): 652-660
- [74] Wang F, Zhang X, Fu R, *et al.* EEG characteristic analysis of coach bus drivers based on brain connectivity as revealed *via* a graph theoretical network. *RSC Adv*, 2018, **8**(52): 29745-29755
- [75] Chen J, Wang S, He E, *et al.* Two-dimensional phase lag index image representation of electroencephalography for automated recognition of driver fatigue using convolutional neural network. *Expert Syst Appl*, 2022, **191**: 116339
- [76] Wang F, Wu S C, Ping J Y, *et al.* EEG driving fatigue detection with PDC-based brain functional network. *IEEE Sens J*, 2021, **21**(9): 10811-10823
- [77] Dimitrakopoulos G N, Kakkos I, Vrahatis A G, *et al.* Driving mental fatigue classification based on brain functional connectivity//Boracchi G, Iliadis L, C Jayne C, *et al.* Engineering Applications of Neural Networks: 18th International Conference. Athens, Greece: Springer International Publishing, 2017: 465-474
- [78] Li G, Li B, Wang G S, *et al.* A new method for human mental fatigue detection with several EEG channels. *J Med Biol Eng*, 2017, **37**(2): 240-247
- [79] Gonzalez-Trejo E, Mogeles H, Pfleger N, *et al.* Electroencephalographic phase - amplitude coupling in simulated driving with varying modality-specific attentional demand. *IEEE T Hum Mach Syst*, 2019, **49**(6): 589-598
- [80] Zhou Y, Zeng C, Mu Z. Optimal feature-algorithm combination research for EEG fatigue driving detection based on functional brain network. *IET Biometrics*, 2023, **12**(2): 65-76
- [81] Cynthia A, Patricia G, Nisrine J, *et al.* A new system for detecting fatigue and sleepiness using brain connectivity: EEG based estimation of fatigue, vigilance and sleepiness for drivers//Khalil M. 2017 Fourth International Conference on Advances in Biomedical Engineering (ICABME). Beirut, Lebanon: IEEE, 2017: 1-4
- [82] Kong W Z, Zhou Z P, Jiang B, *et al.* Assessment of driving fatigue based on intra/inter-region phase synchronization. *Neurocomputing*, 2017, **219**: 474-482
- [83] Wang H, Liu X, Hu H, *et al.* Dynamic reorganization of functional connectivity unmasks fatigue related performance declines in simulated driving. *IEEE Trans Neural Syst Rehabil Eng*, 2020, **28**(8): 1790-1799
- [84] Sun Y, Lim J, Meng J, *et al.* Discriminative analysis of brain functional connectivity patterns for mental fatigue classification. *Ann Biomed Eng*, 2014, **42**(10): 2084-2094
- [85] Harvy J, Sigalas E, Thakor N, *et al.* Performance improvement of driving fatigue identification based on power spectra and connectivity using feature level and decision level fusions//Weiland J, Khine M, Suaning G, *et al.* 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Honolulu, HI, USA: IEEE, 2018: 102-105
- [86] 湛慧苗, 曾宣威, 吕浩铨, 等. 基于互信息的帕金森病脑皮层功能连接. *科学技术与工程*, 2022, **22**(33): 14652-14658
- Zhan H M, Zeng X W, Lv H A, *et al.* *Science Technology and Engineering*, 2022, **22**(33): 14652-14658
- [87] Zheng R, Wang Z, He Y, *et al.* EEG-based brain functional connectivity representation using amplitude locking value for fatigue-driving recognition. *Cogn Neurodyn*, 2022, **16**(2): 325-336
- [88] Chen J, Wang H, Wang Q, *et al.* Exploring the fatigue affecting electroencephalography based functional brain networks during real driving in young males. *Neuropsychologia*, 2019, **129**: 200-211
- [89] Zhao C, Zhao M, Yang Y, *et al.* The reorganization of human brain networks modulated by driving mental fatigue. *IEEE J Biomed Health Inform*, 2017, **21**(3): 743-755
- [90] Zou S L, Qiu T R, Huang P F, *et al.* The functional brain network based on the combination of shortest path tree and its application in fatigue driving state recognition and analysis of the neural mechanism of fatigue driving. *Biomed Signal Proces*, 2020, **62**: 102129
- [91] Han C, Sun X, Yang Y, *et al.* Brain complex network characteristic analysis of fatigue during simulated driving based on electroencephalogram signals. *Entropy (Basel)*, 2019, **21**(4): 353
- [92] Wang H, Liu X, Li J, *et al.* Driving fatigue recognition with functional connectivity based on phase synchronization. *IEEE T*

- Cogn Dev Syst, 2021, **13**(3): 668-678
- [93] Liu S, Wong C M, Liu X, *et al.* Driving fatigue effects on cross-frequency phase synchrony embedding in multilayer brain network. IEEE T Instrum Meas, 2023, **72**: 1-14
- [94] Rohit F, Kulathumani V, Kavi R, *et al.* Real-time drowsiness detection using wearable, lightweight brain sensing headbands. IET Intell Transp Syst, 2017, **11**(5): 255-263
- [95] Balam V P, Sameer V U, Chinara S. Automated classification system for drowsiness detection using convolutional neural network and electroencephalogram. IET Intell Transp Syst, 2021, **15**(4): 514-524
- [96] Ekaputri C, Fu'adah Y N, Pratiwi N K C, *et al.* Drowsiness detection based on EEG signal using discrete wavelet transform (DWT) and K-Nearest Neighbors (K-NN) methods//Triwiyanto, Nugroho H A, Rizal A, *et al.* Proceedings of the 1st International Conference on Electronics, Biomedical Engineering, and Health Informatics. Surabaya, Indonesia: Springer Singapore, 2021: 487-498
- [97] Nugraha B T, Sarno R, Asfani D A, *et al.* Classification of driver fatigue state based on EEG using Emotiv EPOC+. J Theor Appl Inf Technol, 2016, **86**(3): 347-359
- [98] 胡剑锋, 王涛涛. 基于脑电信号模糊熵的驾驶疲劳检测分析. 中国安全科学学报, 2018, **28**(4): 13-18
- Hu J F, Wang T T. China Safety Science Journal, 2018, **28**(4): 13-18
- [99] Min J L, Xiong C, Zhang Y G, *et al.* Driver fatigue detection based on prefrontal EEG using multi-entropy measures and hybrid model. Biomed Signal Proces, 2021, **69**(3): 102857
- [100] Luo Z, Zheng Y, Ma Y, *et al.* A new feature selection method for driving fatigue detection using EEG signals//Liu Q, Liu X, Chen B, *et al.* Proceedings of the 11th International Conference on Computer Engineering and Networks. Hechi, China: Springer Singapore, 2022: 535-542
- [101] Gao Z K, Li Y L, Yang Y X, *et al.* A recurrence network-based convolutional neural network for fatigue driving detection from EEG. Chaos, 2019, **29**(11): 113126
- [102] Li P, Jiang W, Su F. Single-channel EEG-based mental fatigue detection based on deep belief network//Schonle P, Michoud F, Brun N, *et al.* 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Orlando, FL, USA: IEEE, 2016: 367-370
- [103] Brown J G, Wieroney M, Blair L, *et al.* Measuring subjective sleepiness at work in hospital nurses: validation of a modified delivery format of the Karolinska Sleepiness Scale. Sleep Breath, 2014, **18**: 731-739
- [104] Ma Y, Chen B, Li R, *et al.* Driving fatigue detection from EEG using a modified PCANet method. Comput Intell Neurosci, 2019, **2019**: 4721863

Application and Challenges of EEG Signals in Fatigue Driving Detection^{*}

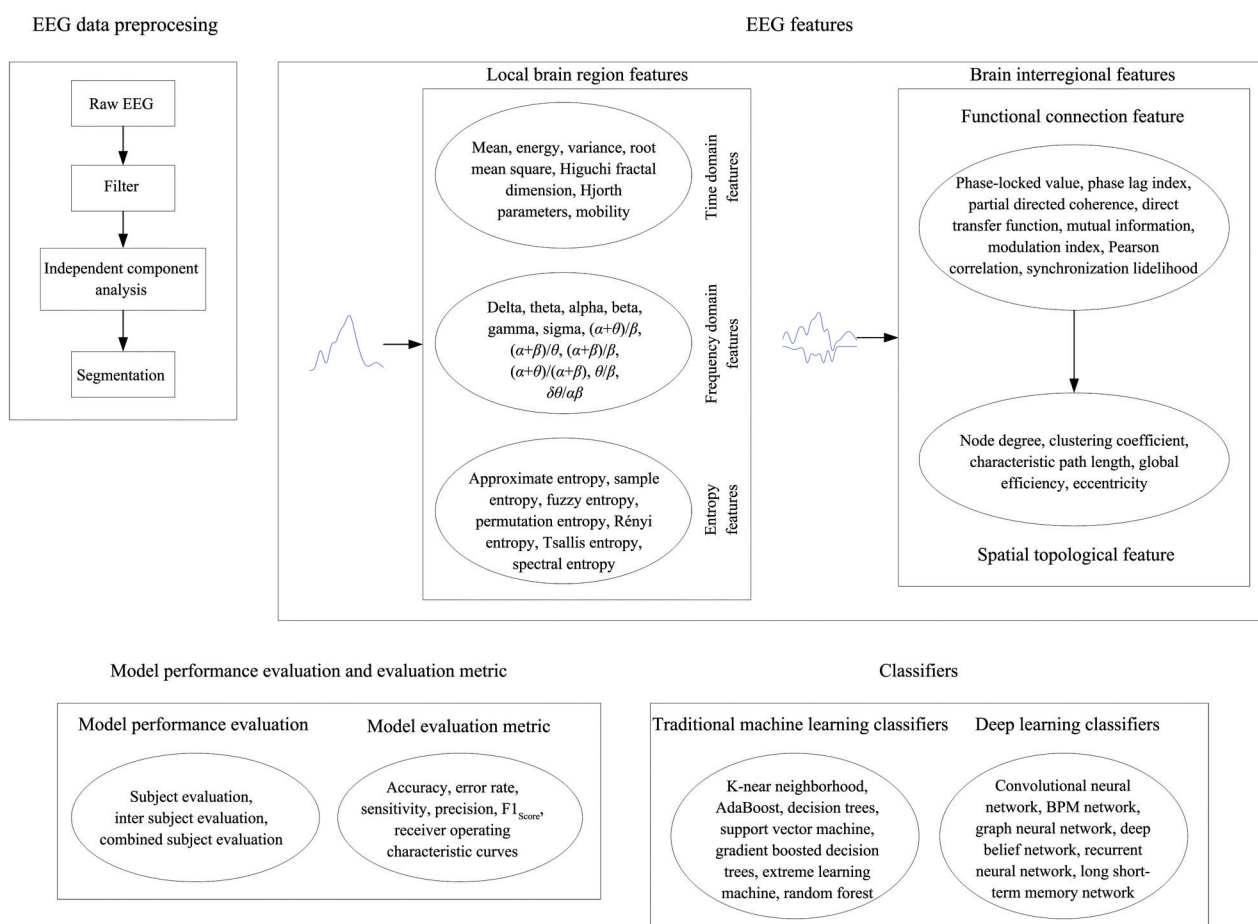
ZONG Shao-Jie¹⁾, DONG Fang^{1)**}, CHENG Yong-Xin^{1)**}, YU Da-Hua¹⁾, YUAN Kai^{1,2)},
WANG Juan¹⁾, MA Yu-Xin¹⁾, ZHANG Fei¹⁾

¹⁾Inner Mongolia Key Laboratory of Pattern Recognition and Intelligent Image Processing, School of Digital and Intelligence Industry,

Inner Mongolia University of Science and Technology, Baotou 014010, China;

²⁾School of Life Science and Technology, Xidian University, Xi'an 710071, China)

Graphical abstract



^{*} This work was supported by grants from Chinese National Programs for Brain Science and Brain-like Intelligence Technology (2022ZD0214500), The National Natural Science Foundation of China (82260359, 82371500, U22A20303, 61971451), and Natural Science Foundation of Inner Mongolia (2021MS08014, 2023QN08007).

^{**} Corresponding author.

DONG Fang. Tel: 86-18648481891, E-mail: dongfang@imust.edu.cn

CHENG Yong-Xin. Tel: 86-15047219886, E-mail: chengyongxin@imust.edu.cn

Received: October 17, 2023 Accepted: January 9, 2024

Abstract People frequently struggle to juggle their work, family, and social life in today's fast-paced environment, which can leave them exhausted and worn out. The development of technologies for detecting fatigue while driving is an important field of research since driving when fatigued poses concerns to road safety. In order to throw light on the most recent advancements in this field of research, this paper provides an extensive review of fatigue driving detection approaches based on electroencephalography (EEG) data. The process of fatigue driving detection based on EEG signals encompasses signal acquisition, preprocessing, feature extraction, and classification. Each step plays a crucial role in accurately identifying driver fatigue. In this review, we delve into the signal acquisition techniques, including the use of portable EEG devices worn on the scalp that capture brain signals in real-time. Preprocessing techniques, such as artifact removal, filtering, and segmentation, are explored to ensure that the extracted EEG signals are of high quality and suitable for subsequent analysis. A crucial stage in the fatigue driving detection process is feature extraction, which entails taking pertinent data out of the EEG signals and using it to distinguish between tired and non-fatigued states. We give a thorough rundown of several feature extraction techniques, such as topology features, frequency-domain analysis, and time-domain analysis. Techniques for frequency-domain analysis, such as wavelet transform and power spectral density, allow the identification of particular frequency bands linked to weariness. Temporal patterns in the EEG signals are captured by time-domain features such as autoregressive modeling and statistical moments. Furthermore, topological characteristics like brain area connection and synchronization provide light on how the brain's functional network alters with weariness. Furthermore, the review includes an analysis of different classifiers used in fatigue driving detection, such as support vector machine (SVM), artificial neural network (ANN), and Bayesian classifier. We discuss the advantages and limitations of each classifier, along with their applications in EEG-based fatigue driving detection. Evaluation metrics and performance assessment are crucial aspects of any detection system. We discuss the commonly used evaluation criteria, including accuracy, sensitivity, specificity, and receiver operating characteristic (ROC) curves. Comparative analyses of existing models are conducted, highlighting their strengths and weaknesses. Additionally, we emphasize the need for a standardized data marking protocol and an increased number of test subjects to enhance the robustness and generalizability of fatigue driving detection models. The review also discusses the challenges and potential solutions in EEG-based fatigue driving detection. These challenges include variability in EEG signals across individuals, environmental factors, and the influence of different driving scenarios. To address these challenges, we propose solutions such as personalized models, multi-modal data fusion, and real-time implementation strategies. In conclusion, this comprehensive review provides an extensive overview of the current state of fatigue driving detection based on EEG signals. It covers various aspects, including signal acquisition, preprocessing, feature extraction, classification, performance evaluation, and challenges. The review aims to serve as a valuable resource for researchers, engineers, and practitioners in the field of driving safety, facilitating further advancements in fatigue detection technologies and ultimately enhancing road safety.

Key words electroencephalogram signals, fatigue driving detection, brain functional connectivity, traditional machine learning, deep learning

DOI: 10.16476/j.pibb.2023.0399