基于深度学习的驾驶员意图预测：实时脑车通信

Niloufar Alavi、Swati M. Shah、Rezvan Alamian 和 Stefan M. G¨otz

arXiv:2601.05084v1 [cs.HC] 8 Jan 2026

摘要—脑机接口（BCI）能够在无需言语或身体动作的情况下，实现大脑与电子设备之间的直接通信。这类接口在需要快速响应的应用中尤为有益，例如驾驶；车辆的高级驾驶辅助系统可以借此即时了解驾驶员的意图。本研究提出一种利用深度学习和脑电图（EEG）信号预测驾驶员转向意图的新方法。研究通过驾驶模拟器构建受控环境，让参与者在不同驾驶场景中想象操控车辆，包括左转和右转，以及直行。卷积神经网络（CNN）仅经过少量预处理，便对检测到的脑电数据进行了分类。模型区分三种转向意图的准确率达到83.7%，表明卷积神经网络能够有效处理原始脑电数据。右转片段的分类准确率最高，这表明脑活动可能存在空间偏向。本研究为构建更直观的脑车通信系统奠定了基础。

I. 引言

交流是我们生活中不可或缺的一部分。它是我们与外界建立联系和表达自我的方式。我们可以与人或机器进行交流。技术和科学的进步将智能设备和机器融入日常生活。我们可以使用语言、手势或其他交流方式向机器传递信息 [1]。脑机接口（BCI）通过大脑提供即时通信，并绕过以往通常涉及周围肌肉（包括言语在内）的交流方式 [2]。直接交流可以简化信息传递，并使重度残障人士也能够进行交流 [3]。脑机接口使用范围广泛的脑信号 [4]。侵入式微电极和硬膜外电极甚至可以检测到单个神经元层面的信号 [5]；而脑电图（EEG）中的非侵入式表面电极则测量许多神经元的电位总和 [6]。写入通道还可以进一步增加双向功能 [7]–[9]。尽管侵入式方法已取得良好效果，例如用于控制假肢[10], [11], ，但与脑外科手术相关的损伤和感染风险、伦理问题，以及所记录信号逐渐衰减的问题，仍然是其缺点 [12]。因此，非侵入式技术更为理想。

除了用于医学诊断，脑机接口也已成为一项重要应用 [13]。在执行某些任务的同时检测到的脑电信号，有助于识别相关性和模式 [14], [15]。这些相关性和模式可用作用户指令；运动μ波或特定事件相关电位或许能提供生理学依据，但深度学习方法甚至可以不依赖这些关联，只需足量的训练数据就能发现模式，并处理神经信号的高度可变性以及记录噪声 [4], [16]–[23]。先进机器学习技术的同步发展，能够从原始高维数据中识别细微的非线性关系，而无需进行降维或聚合 [24]–[27]。卷积神经网络（CNN）源自图像处理并经改造后，可处理预处理后的脑电数据；直到不久前，这还是标准做法 [28], [29], ，也可以直接处理原始脑电信号 [30]–[33]。

驾驶车辆是一个众所周知的认知挑战性任务示例，需要运用多种能力来操作车辆，同时管理交通与安全，并完成从 A 点到 B 点的实际行驶。因此，驾驶领域一直受到大量研究关注，研究旨在简化驾驶过程。尽管全自动驾驶曾被视为个人交通出行的近未来发展方向，但其复杂性使人们更加关注如何简化驾驶，并开发了大量基础或先进的驾驶辅助系统。然而，目前这些系统在做出决策时，都没有考虑驾驶员的心理状态或意图，也不具备快速判断情境的能力 [34]。相反，这些系统完全依赖传感器和传统用户 [35]。然而，众多研究人员认为，设计智能驾驶辅助系统的关键在于识别驾驶意图的能力 [36], [37]。

本研究旨在检测驾驶员或领航乘客的意图，使机器（即汽车）能够执行细节工作和低层控制。以往研究尝试结合多种传感器来估计驾驶员的转向意图，例如肌电图（EMG）数据、姿态跟踪和脑电图 [17], [38]。然而，额外配置传感器并不实用。仅利用脑电图检测转向意图的研究，主要聚焦于脑信号的特征检测与预处理 [39], [40]。典型方法对三种选择（左转、右转和直行）的准确率仅为二分之一至三分之二 [41]。与现有研究不同，本研究仅依据脑电数据进行分类，并在三种类别（右转、左转和直行）上实现了超过 80% 的准确率。此外，分类采用深度学习算法，无需预处理，这有助于未来项目实现实时脑机接口控制。

II. 研究方法

A. 研究设计

我们在 IPG CarMaker（IPGMovie 9.1.1）中设计了一条测试赛道。设计的道路场景由 92 个片段组成，



图1：驾驶模拟器的实验设置。



(a) (b)

图2：驾驶员视角下的（a）直行驾驶和（b）转弯。

其中包括左转、右转以及直行片段。转弯片段随机分布，其余片段均为直行。每个片段开始时，都会通过串口线向脑电图软件（ANT EEGo）发送触发信号。在模拟过程中，摄像机位置设置为近似驾驶员视角，以增强沉浸感。受试者坐在距离 42 英寸电视屏幕 1.5 米的位置（图 1）。为避免其他特征影响脑电信号，沿途景物保持相似。图 2 展示了该场景中的示例。参与者抵达转弯处前几秒，便能看到道路开始转弯。驾驶汽车完成一整圈约需 14 分钟，其中包括三次休息（每次一分钟）。我们为参与者重复呈现场景两至六次。本次实验中没有使用驾驶模拟器的方向盘和踏板，因为参与者只需想象自己正在转弯。图 3 展示了实验设计。

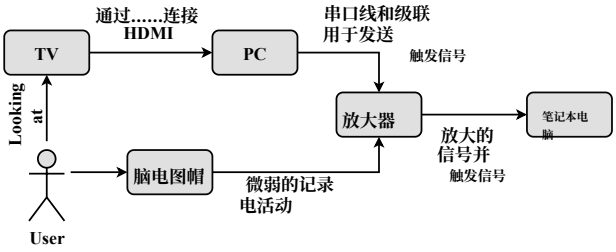

图3：实验设置中信号流的配置。

B. 参与者

参与者通过社交媒体群组中的广告招募，均为凯撒斯劳滕大学的学生（1名男性、9名女性；平均年龄为 $= 28.33 \pm 6.56$，范围为22–44岁）。实验说明以英语撰写，所有参与者均会说英语，但母语各不相同。他们均为右利手，视力正常或经矫正后正常，且无任何神经系统或心理疾病。参与者签署了书面知情同意书，并获得了相应的时间补偿。

C. 实验流程

参与者被要求关闭手机和电子设备，或将其设置为飞行模式。在签署知情同意书并填写人口统计信息表后，受试者阅读了详细说明并可提问。说明要求他们想象自己是驾驶员，并用意念控制汽车。任务并非移动模拟器上的方向盘，也不是对移动方向盘进行运动想象，而是控制屏幕上汽车的转向。当到达转弯点时，他们必须专注于向该方向转弯；转弯结束后，必须再次专注于驾驶直行 。

他们还被告知休息时间，并应尽量保持静止，在任务期间不要分心。随后，按照10–20系统将带有64个脑电通道的Waveguard凝胶脑电帽戴在他们头上。阻抗被确保低于20 kΩ。脑电数据以512 Hz的采样频率进行记录。

D. 分析

1）数据训练：使用 Python 3.9.1 和 TensorFlow 库（版本 2.8.0）处理并分析脑电数据文件。未进行滤波或更深入的预处理步骤，随后便开展分类。我们没有去除眨眼引起的眼部伪迹或肌肉伪迹，以便让深度学习算法忽略不重要的特征。从每个触发位置提取两个相互重叠的窗口：样本 700–1700（1.36–3.32 秒）和样本 750–1750（1.46–3.42 秒），使准确率提高了 3–4%。分段后，剔除了低于第 10 百分位数和高于第 90 百分位数的样本，以去除异常值。所得数据在输入一维卷积神经网络处理前，经过归一化，使其达到零均值和单位方差

（卷积神经网络）。将 64 个通道中所有缩放后的时间段展平为单个样本，并为其分配相应标签（直行 = 0,左转 = 1,右转 = 2），然后保存至数据库以生成模型。在训练和验证期间，加载、打乱数据样本及标签，并将其划分为训练集（70%）和验证集（30%）。该场景中自然包含更多直行 片段。因此，使用合成少数类过采样技术 [42] 平衡训练样本，确保每个类别的样本数量相同，随后再次打乱并输入神经网络。每个片段的样本张量维度为 (1, 500, 64)，训练输入张量总量为 (4278, 500, 64)。网络包含卷积、最大池化、卷积、平均池化、展平、丢弃和全连接层。通过反复试验进行超参数调优，以最大化准确率并最小化损失。值得注意的是，由于修正线性单元（ReLU）激活函数和零填充在某些情境下会导致分类准确率较低，我们没有采用它们 [43], [44]。我们使用 Adam优化器，学习率为 2×10^{-5}，并采用分类交叉熵计算损失，这适用于我们的整数输出类别（0 表示直行，1 表示 左转，2 表示 右转）。网络经过 80 次迭代训练，批量大小为 32。根据准确率峰值选出最佳模型，并使用该模型评估验证样本。模型未在由未见过的参与者/会话组成的留出测试集上进行测试。根据实际验证标签和预测验证标签生成混淆矩阵，其中包含四个基本要素——真阳性、真阴性、假阳性和假阴性。我们使用准确率表示正确预测数占所有预测数的比例，使用精确率衡量每个类别的真阳性预测数占所有阳性预测数的比例，使用召回率表示真阳性预测数占该类别所有样本数的比例，并使用 F1 分数表示准确率与全面性之间的调和均衡 [45], [46]。

2）可视化：此外，我们使用 Python 3.10 中的 MNE 库处理脑电数据，以便进行可视化。为聚焦于相关的脑活动，我们对脑电数据进行了 0.1–40 Hz 带通滤波以降低噪声，并采用平均参考重新参考，以减少共同噪声源的影响。在伪迹剔除步骤中，我们使用独立成分分析（ICA）分离脑活动与伪迹的混合来源，将其拆分为独立成分，从而去除眨眼、肌肉活动和电气干扰等伪迹。最后，我们对基线进行了校正，使刺激前基线时段（从 −200 ms 至触发时刻）的均值为零，以消除脑电信号随时间变化、即片段间残留的任何渐进性偏移。触发后 3 s 的数据片段被截取出来。这些处理后的数据构成了各类别地形图绘制的基础。此外，为补偿脑电数据的非平稳性 [47], [48]，我们还计算了 Welch估计的功率谱密度，即对连续数据块的周期图取平均。

III. 结果

有一名参与者未完成实验，因此其数据被排除。随后对其余参与者整体进行分类，构建群体模型；接着对三名随机选取的参与者分别进行个体分类，以确定个体差异的影响。表 I 展示了通用模型以及其中一个个体模型在验证数据集上的多类别混淆矩阵。通用模型的准确率为 83.7%。

表 I：**通用模型和个体模型的混淆矩阵**

		预测值		
		直行	**Left**	**右转**
所有受试者	直行	395	56	24
	Left	30	187	2
	右转	35	7	209
受试者 1	直行	52	13	8
	Left	6	23	0
	右转	5	2	29
受试者 2	直行	64	9	13
	Left	2	30	1
	右转	7	1	39
受试者 3	直行	71	13	7
	Left	3	21	3
	右转	5	1	41

表 II：**各类别的性能指标**

		精确率	**召回率**	**F1 分数**
类别	直行	0.858	0.832	0.845
	Left	0.748	0.854	0.797
	右转	0.889	0.833	0.860

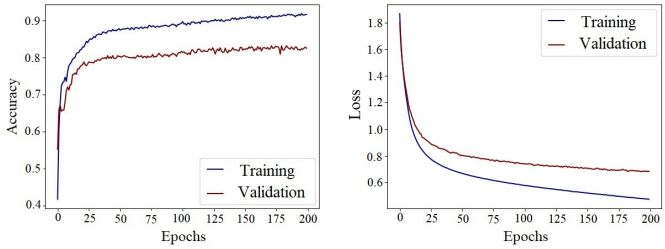

(a) (b)

图 4：通用模型的准确率和损失。

表 I 显示了哪些情形比其他情形更容易被误分类。直行 片段在 83% 的情况下被正确分类。误分类数据在另外两个类别之间的分布并不均匀，且更倾向于左转类别。被错误分类的左转和右转片段大多被识别为直行。表 II 中的性能指标表明，右转 类别的得分最高，其次是直行。

地形图区分了三种类别（图 5）。在向左转 和右转时，相应大脑半球的额叶比其他区域更加活跃。明显的侧向成分在很大程度上取决于方向。在直行 条件下，中央沟周围的部分额叶和顶叶显示出最高水平的激活。图 6 绘制了 AF7 和 AF8 通道中的诱发电位。诱发电位响应在左转 和右转 条件之间存在明显差异。极性变化与所选电极所在的一侧相对应。这种模式的

活动在直行 条件下不随极性变化，但在 AF7电极中略低。

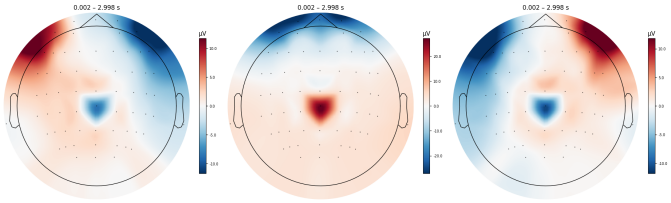

(a) (b) (c)

图 5：触发事件发生后最初 3 秒内平均脑活动的地形图，分别对应 (a)左转、(b) 直行和 (c)右转。

图 7 展示了三种条件下的功率谱。阿尔法频段（8–13 Hz）始终在约 10 Hz 处呈现明显峰值。贝塔频段（13–30 Hz）的功率因条件而异。超过贝塔频段范围后，功率谱逐渐下降。

IV. 讨论

A. 模型规模与变异性

本研究旨在利用原始数据，并将其输入卷积神经网络，将驾驶员的转向意图预测为三种类别之一：右转、左转和直行。我们针对实验中收集的合并数据训练模型，并分别针对三个独立数据集进行训练。参与者和片段数量充足，因此可以使用一个灵活的整体模型并达到较高的准确率。相应地，与以往采用个体模型的研究相比，我们使用了规模更大的模型，并进行了更多轮训练。我们预计，与个体建模相比，准确率会有所下降，因为网络无法再利用个体特征，但仍有可能超越以往研究 [49]，[50]。

一个需要考虑的重要因素是脑电数据随时间的变化。Brigham 和 Kumar 证明，随着记录会话之间的间隔增加，使用脑电数据进行受试者识别的准确率会降低

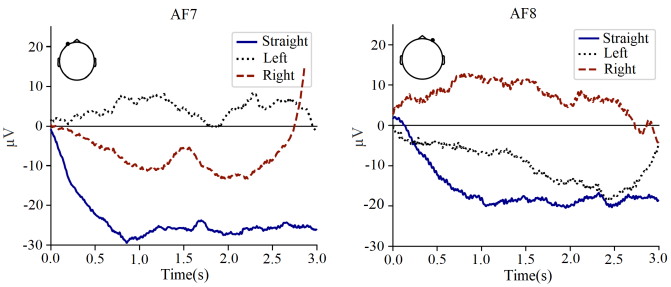

(a) (b)

图 6：诱发反应比较：图中展示了不同条件下通道（a）AF7 和（b）AF8 的不同诱发反应。

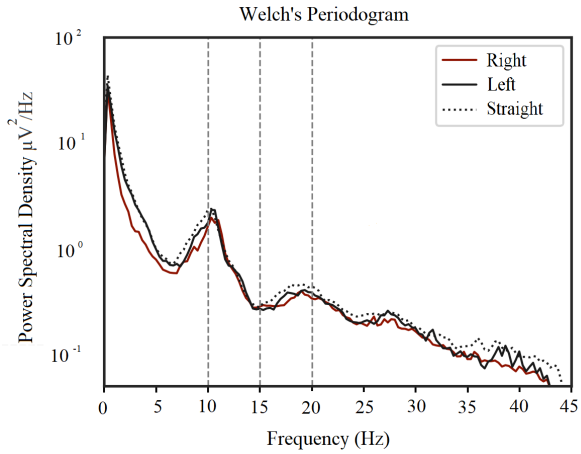

图 7：使用 Welch 方法，根据 C4 电极采集的数据计算得到的功率谱密度。

这表明，在受试者识别后，使用新数据更新训练数据库，或采用一些自适应分类方法，可能会有所帮助 [51]。尽管如此，Maiorana 等人 [52]证明，在训练阶段使用来自不同会话的数据可以获得更高的识别率，这与我们的实验做法一致。这一策略可以最大限度地减少训练阶段所用会话的特异性影响，并确认脑电特征 [52]的持续性。

B. 敏感区间与频谱特征

值得一提的是，为达到这一准确率，我们提取了触发点后 1.36 至 3.32 秒内的时间段。触发点后 0 至 2 秒内的时间段未取得良好结果。触发后即时阶段表现不佳是意料之中的，因为相关研究也采用了类似范围的时间段，例如六秒时间段（包括转向前后的时刻） [41], 2、事件前 0.5 秒和事件后 2.5 秒 [38]，，以及转向开始后四秒 [40]。

所有条件下的脑电数据 Welch 周期图都显示出约 0.5 Hz 处的高峰。该峰值可能与生理活动或伪迹有关，例如电极漂移或与呼吸相关的运动。随着频率从德尔塔波（0 Hz — 4 Hz）增加到西塔波（4 Hz — 8 Hz），我们观察到功率下降，这在脑电记录中很常见，也与 $1/f$ 脑信号的频谱行为 [53]一致。在所有不同条件下，都可以看到阿尔法波（8 Hz – 13 Hz）范围内的峰值，这表明每项任务期间的放松程度相似。不同条件之间的差异在贝塔频段（13 Hz — 30 Hz）中更为明显：与想象右转相比，想象左转 和直行直行 时的功率谱表现出略高的功率。不同条件之间的频谱差异表明，运动或认知过程的参与程度存在差异，其中左转 和直行 意象任务期间的皮层激活更强。在伽马波（30 Hz – 45 Hz）范围内，功率谱逐渐下降，该范围内没有显著峰值。三种条件下的功率谱

在所有频段中都呈现出相似的趋势，但它们之间最大的差异出现在贝塔频段内。

此外，地形图中呈现的模式可能并不仅仅反映与想象转向相关的脑活动。它们还可能捕捉到高度相关的眼球运动。额叶区域上方的强信号通常是眼睛移动时产生的活动 [54]。眼部活动很难分离出来，但另一方面，它也确实对信号有所贡献，并且是实现高层次车辆转向这一预期目标的一种手段。当参与者观看汽车向右转时，转弯的后续过程出现在他们的右侧视野中，他们也更频繁地看向右侧。左转时同样如此。这种注视行为与相关研究一致，即驾驶员在转向时往往会看向车辆的未来路径 [55], [56]。

C. 空间偏向

向右转的脑数据比其他数据分类得更准确（表 I 和表 II）。右–左偏差出乎意料，因为直行片段的样本数量几乎是其他片段的两倍。我们原本预期直行片段的准确率更高，而左转和右转的准确率大致相同。一种可能的解释是，空间注意并不会平均分配到两个大脑半球，且由注意引起的偏差更偏向右侧 [57]。其他研究也支持这一发现，但其结果仅适用于右利手人群，因为受试者均为右利手 [58]。因此，方向准确率偏差不太可能是由我们的实验设置造成的。空间偏向的形成可能会受到利手相关因素的影响[59]。因此，利手可能是右转片段准确率更高的原因；对于左利手人群，结果可能有所不同，其左转的准确率可能更高。不过，要得出这一结论还需要更多证据，未来还可以开展进一步研究。

另一个值得注意的现象是，未被正确分类的直行片段在大多数情况下被误判为左转片段。然而，转弯片段最常被误分类为直行。因此，该网络能够很好地区分左转和右转，但在区分转弯片段与直行片段方面，表现并不那么理想。一个可能的原因是，尽管指令明确要求参与者专注于转弯和直行，但其中一些人只专注于转弯，这意味着在直行片段期间，他们难以想象自己直行驾驶。

总而言之，本研究旨在预测驾驶员的转向意图，这一目标已成功实现。深度学习是一个前景广阔的领域，有望显著提高原始数据的分类准确率。

参考文献

[1] J. Jia、Y. He 和 H. Le，“多模态人机交互系统及其在智慧学习环境中的应用”，载于国际混合式学习会议。Springer，2020年，第 3–14 页。[2] J. R. Wolpaw、N. Birbaumer、D. J. McFarland、G. Pfurtscheller 和T. M. Vaughan，“脑机接口用于通信与控制”，《Clinical Neurophysiology》，第 113 卷，第 6 期，第 767–791 页，2002年。

[3] O. Attallah、J. Abougharbia、M. Tamazin 和 A. A. Nasser，“一种基于运动想象的脑机接口系统，用于帮助四肢运动功能障碍者”，《脑科学》，第10卷，第11期，第864页，2020年。[4] S.-P. Kim、J. D. Simeral、L. R. Hochberg、J. P. Donoghue、G. M. Friehs 和 M. J. Black，“四肢瘫痪者利用皮层内神经接口系统进行点选式光标控制”，《IEEE神经系统与康复工程汇刊》，第19卷，第2期，第193–203页，2011年。[5] G. Buzs´aki，“神经元集群的大规模记录”，《自然·神经科学》，第7卷，第5期，第446–451页，2004年。[6] M. Teplan 等，“脑电测量基础”，《测量科学评论》，第2卷，第2期，第1–11页，2002年。[7] J. T. Sombeck、J. Heye、K. Kumaravelu、S. M. Goetz、A. V. Peterchev、W. M. Grill、S. Bensmaia 和 L. E. Miller，“表征多电极阵列中皮层内微刺激引发的短潜伏期诱发反应”，《神经工程学杂志》，第19卷，第2期，第026044页，2022年。[8] J. C. Chen、P. Kan、Z. Yu、F. Alrashdan、R. Garcia、A. Singer、C. E. Lai、B. Avants、S. Crosby、Z. Li 等，“用于周围神经血管内刺激的无线毫米级磁电植入物”，《自然·生物医学工程》，第6卷，第6期，第706–716页，2022年。[9] C. Hughes、A. Herrera、R. Gaunt 和 J. Collinger，“双向脑机接口”，《临床神经病学手册》，第168卷，第163–181页，2020年。[10] M. Velliste、S. Perel、M. C. Spalding、A. S. Whitford 和 A. B. Schwartz，“用于自主进食的假肢手臂皮层控制”，《自然》，第453卷，第7198期，第1098–1101页，2008年。[11] R. Abiri、S. Borhani、E. W. Sellers、Y. Jiang 和 X. Zhao，“基于脑电的脑机接口范式综述”，《神经工程学杂志》，第16卷，第1期，第011001页，2019年。[12] L. F. Nicolas-Alonso 和 J. Gomez-Gil，“脑机接口综述”，《传感器》，第12卷，第2期，第1211–1279页，2012年。[13] M. Weinrich、B. Dobkin、E. Donchin、E. Wolpaw、J. Wolpaw、B. Allison、J. Pineda、L. Bianchi、F. Babiloni、F. Cincotti 等，“客座编者按：脑机接口技术——第二届国际会议综述”，2003年。[14] M. Heim、F. Heinrichs、M. Hueppe、F. Nunez、A. Szameitat、M. Reuter、S. M. Goetz 和 C. Weber，“利用功能神经网络实现自定步调运动想象与运动执行的实时脑电脑机接口”，IEEE Access，2025年。[15] D. J. McFarland、C. W. Anderson、K.-R. Muller、A. Schlogl 和 D. J. Krusienski，“2005年脑机接口会议——脑机接口信号处理研讨会：特征提取与转换”，《IEEE神经系统与康复工程汇刊》，第14卷，第2期，第135–138页，2006年。[16] K. Aggarwal、M. M. Mijwil、A.-H. Al-Mistarehi、S. Alomari、M. G¨ok、A. M. Z. Alaabdin、S. H. Abdulrhman 等，“未来已经到来了吗？人工智能、机器学习与深度学习的当前发展”，《伊拉克计算机科学与数学杂志》，第3卷，第1期，第115–123页，2022年。[17] P. Calder´o-Bardaj´ı、X. Longfei、S. Jaschke、J. Reermann、K. Mideska、G. Schmidt、G. Deuschl 和 M. Muthuraman，“基于样本熵和时频分析的脑电记录转向方向检测”，载于《2016年第38届IEEE医学与生物学工程学会年会国际会议（EMBC）》。IEEE，2016年，第833–836页。[18] F. Lotte、M. Congedo、A. L´ecuyer、F. Lamarche 和 B. Arnaldi，“基于脑电的脑机接口分类算法综述”，《神经工程学杂志》，第4卷，第2期，第R1页，2007年。[19] S. Saha 和 M. Baumert，“基于脑电的感觉运动脑机接口中受试者内及受试者间变异性综述”，《计算神经科学前沿》，第13卷，第87页，2020年。[20] S. M. Goetz、B. Luber、S. H. Lisanby 和 A. V. Peterchev，“一种纳入两种变异来源的运动诱发电位描述新模型”，《脑刺激》，第7卷，第4期，第541–552页，2014年。[21] Z. Li、A. V. Peterchev、J. C. Rothwell 和 S. M. Goetz，“噪声底以下运动诱发电位的检测：重新审视运动刺激阈值”，《神经工程学杂志》，第19卷，第5期，第056040页，2022年。[22] K. Ma、B. Wang、S. Liu 和 S. M. Goetz，“重新思考运动诱发电位中的噪声底表征”，《神经工程学杂志》，第22卷，第3期，第034002页，2025年。[23] S. M. Goetz、B. Howell、B. Wang、Z. Li、M. A. Sommer、A. V. Peterchev 和 W. M. Grill，“ 分离皮层下刺激的两种变异来源，以量化皮质脊髓束兴奋性的波动”，Clinical Neurophysiology，第138卷，第134–142页，2022年。[24] M. C.-T. Tai，“人工智能对人类社会与生物伦理学的影响”，《慈济医学杂志》，第32卷，第4期，第339页，2020年。

[25] X.-W. Chen 和 X. Lin，“大数据深度学习：挑战与展望”，IEEE Access，第2卷，第514–525页，2014年。[26] R. Shokri 和 V. Shmatikov，“隐私保护深度学习”，载于《第22届ACM SIGSAC计算机与通信安全会议论文集》，2015年，第1310–1321页。[27] T. Panch、P. Szolovits 和 R. Atun，“人工智能、机器学习与卫生系统”，《全球卫生杂志》，第8卷，第2期，2018年。[28] H. Dose、J. S. Møller、H. K. Iversen 和 S. Puthusserypady，“一种用于脑机接口运动想象脑电信号分类的端到端深度学习方法”，《专家系统与应用》，第114卷，第532–542页，2018年。[29] P. Bashivan、I. Rish、M. Yeasin 和 N. Codella，“利用深度循环卷积神经网络从脑电中学习表征”，arXiv预印本 arXiv:1511.06448，2015年。[30] E. Petoku 和 G. Capi，“利用卷积神经网络实现基于脑电脑机接口系统的物体运动运动想象”，载于《2021年第9届国际冬季脑机接口会议（BCI）》。IEEE，2021年，第1–5页。[31] X. Zhao、H. Zhang、G. Zhu、F. You、S. Kuang 和 L. Sun，“一种用于基于脑电的运动想象分类的多分支三维卷积神经网络”，《IEEE神经系统与康复工程汇刊》，第27卷，第10期，第2164–2177页，2019年。[32] R. T. Schirrmeister、J. T. Springenberg、L. D. J. Fiederer、M. Glasstetter、K. Eggensperger、M. Tangermann、F. Hutter、W. Burgard 和 T. Ball，“利用卷积神经网络进行脑电解码与可视化的深度学习”，《人脑图谱》，第38卷，第11期，第5391–5420页，2017年。[33] X. Tang、N. Zhang、J. Zhou 和 Q. Liu，“利用粒子群优化的隐藏层可见深度堆叠网络进行运动想象脑电识别”，《神经计算》，第234卷，第1–10页，2017年。[34] L. G. Hern´andez、O. M. Mozos、J. M. Ferr´andez 和 J. M. Antelis，“不同汽车驾驶条件下基于脑电的制动意图检测”，《神经信息学前沿》，第12卷，第29页，2018年。[35] W. Chang、W. Meng、G. Yan、B. Zhang、H. Luo、R. Gao 和 Z. Yang，“基于驾驶脑电的多层动态脑网络分析与转向过程研究”，《专家系统与应用》，第207卷，第118121页，2022年。[36] M. Haghani、M. C. Bliemer、B. Farooq、I. Kim、Z. Li、C. Oh、Z. Shah-hoseini 和 H. MacDougall，“脑成像方法在驾驶行为研究中的应用”，《事故分析与预防》，第154卷，第106093页，2021年。[37] Y. Xing、C. Lv、H. Wang、H. Wang、Y. Ai、D. Cao、E. Velenis 和 F.-Y. Wang，“面向智能车辆的驾驶员变道意图推断：框架、综述与挑战”，《IEEE车辆技术汇刊》，第68卷，第5期，第4377–4390页，2019年。[38] G. Vecchiato、M. Del Vecchio、J. Ambeck-Madsen、L. Ascari 和 P. Avanzini，“脑电–肌电耦合作为汽车驾驶场景中转向检测的混合方法”，《认知神经动力学》，第16卷，第5期，第987–1002页，2022年。[39] H. Lakany，“用意念操控轮椅”，载于《IEEE智能环境国际研讨会》。6月。IET，2005年，第199–202页。[40] L. Gheorghe、R. Chavarriaga 和 J. d. R. Mill´an，“驾驶模拟器任务中的转向时机预测”，载于《2013年第35届IEEE医学与生物学工程学会年会国际会议（EMBC）》。IEEE，2013年，第6913–6916页。[41] T. Ikenishi、T. Kamada 和 M. Nagai，“使用脑电图对驾驶员转向意图进行分类”，《系统设计与动力学杂志》，第2卷，第6期，第1274–1283页，2008年。[42] N. V. Chawla、K. W. Bowyer、L. O. Hall 和 W. P. Kegelmeyer，“SMOTE：合成少数类过采样技术”，《人工智能研究杂志》，第16卷，第321–357页，2002年。[43] Y. Jiang、J. Xie 和 D. Zhang，“用于卷积神经网络图像分类任务的自适应偏移激活函数”，《电子学》，第11卷，第22期，第3799页，2022年。[44] S. Iqbal、A. N. Qureshi、A. Ullah、J. Li 和 T. Mahmood，“通过自适应超参数调优提升生物医学卷积神经网络模型的鲁棒性与质量”，《应用科学》，第12卷，第22期，第11870页，2022年。[45] M. C. Guerrero、J. S. Parada 和 H. E. Espitia，“利用脑电信号的主成分分析识别癫痫患者”，《计算》，第9卷，第12期，第133页，2021年。[46] D. M. Powers，“评估：从精确率、召回率和F值到ROC曲线、知情度、标记度与相关性”，arXiv预印本 arXiv:2010.16061，2020年。[47] P. Von B¨unau、F. C. Meinecke、S. Scholler 和 K.-R. M¨uller，“在脑电数据中寻找稳定脑源”，载于《2010年年度国际会议》*IEEE* 医学与生物工程会议. IEEE，2010年，第 2810–2813 页。[48] P. Welch，“使用快速傅里叶变换估计功率谱：一种基于对短时修改周期图进行时间平均的方法”，*IEEE* 音频与电声学汇刊，第 15 卷，第 2 期，第 70–73 页，1967 年。[49] J. Li、P. Washington 等，“使用消费级可穿戴设备进行情绪识别的个性化方法与通用方法比较：一项机器学习研究”，*JMIR AI*，第 3 卷，52171，2024年 1，第 e 页。[50] H. Zhang、H. Ji、J. Yu、J. Li、L. Jin、L. Liu、Z. Bai 和 C. Ye，“基于混合神经网络的受试者独立脑电图分类”，《神经科学前沿》，第 17 卷，第 1124089 页，2023 年。[51] K. Brigham 和 B. V. Kumar，“想象言语期间基于脑电图（脑电图）信号的受试者识别”，载于*2010*年第四届 *IEEE* 生物识别：理论、应用与系统国际会议（*BTAS*）。IEEE，2010年，第 1–8 页。[52] E. Maiorana、D. La Rocca 和 P. Campisi，“脑电信号用于生物特征识别的持久性”，*IEEE* 信息取证与安全汇刊，第 11 卷，第 1 期，第 163–175 页，2015 年。[53] C. Demanuele、C. J. James 和 E. J. Sonuga-Barke，“区分电磁脑信号 1/f 谱特性中的低频振荡”，《行为与脑功能》，第 3 卷，第 1 期，第 62 页，2007年。[54] V. Ronca、R. Capotorto、G. Di Flumeri、A. Giorgi、A. Vozzi、D. Germano、V. D. Virgilio、G. Borghini、G. Cartocci、D. Rossi 等，“优化脑电信号完整性：眼动伪迹校正综合指南”，《生物工程》，第 11 卷，第 10 期，第 1018 页，2024 年。[55] M. F. Land 和 D. N. Lee，“转向时我们看向何处”，《自然》，第 369 卷，第 6483 期，第 742–744 页，1994 年。[56] S. Tuhkanen、J. Pekkanen、R. M. Wilkie 和 O. Lappi，“对未来路径的视觉预期：预测性注视与转向”，《视觉杂志》，第 21 卷，第 8 期，第 25–25 页，2021 年。[57] F. Takio、M. Koivisto 和 H. H¨am¨al¨ainen，“执行功能对空间偏向的影响随生命周期而变化”，《发展认知神经科学》，第 10 卷，第 170–180 页，2014年。[58] F. Takio、M. Koivisto、T. Tuominen、S. J. Laukka 和 H. H¨am¨al¨ainen，“视觉右向空间偏向随年龄而变化”，《侧化：身体、大脑与认知的不对称性》，第 18 卷，67，2013年 1，第 44no. pp. –。[59] C. A. Bareham、T. A. Bekinschtein、S. K. Scott 和 T. Manly，“左利手是否能抵御空间偏向？”，《科学报告》，第 5 卷，第 1 期，第 9162 页，2015 年。