

小波变换与注意力双路融合的虚拟现实晕动症脑电检测模型

陈玥池^① 化成城^{*①②} 戴志安^① 付景琦^① 朱敏^①
汪秋宇^① 严颖^{①②} 刘佳^{①②}

^①(南京信息工程大学江苏省智能气象探测机器人工程研究中心 南京 210044)

^②(南京信息工程大学江苏省大气环境与装备技术协同创新中心 南京 210044)

摘要: 虚拟现实晕动症(VRMS)指在虚拟现实(VR)环境中用户因前庭-视觉信息失调引发的严重眩晕, 该症状阻碍沉浸式VR技术应用和推广。该文提出一种小波变换与注意力机制协同的双路融合模型(WTATNet), 通过解耦VR运动刺激暴露后的休息态脑电(EEG)的时空特征, 为VRMS的客观检测提供新方法。该模型分为两条支路, 支路1对EEG时间维和导联维进行二维离散小波变换计算出小波系数, 再将小波系数送入卷积层进行特征提取。支路2则是EEG经过一维卷积层滤波后, 依次利用通道注意力模块和导联注意力模块强化通道维与导联维的关键特征。最后将两支路的特征融合并进行分类。该文使用VR游戏《超级滑翔翼2》诱发受试者的VRMS并记录他们在任务前后的休息态EEG评估WTATNet模型的性能, 最终实现对受试者休息态下眩晕脑电与非眩晕脑电的分类。该模型对VRMS的识别准确率、F1-score、精确率和召回率(10折交叉验证的平均值)分别为98.39%, 98.39%, 98.38%和98.40%, 优于目前的先进的EEG识别模型。结果表明所提方法可对VRMS进行检测, 并用于进一步研究VRMS的产生因素和治理方法, 对优化VR系统具有一定的指导意义。

关键词: 虚拟现实晕动症; 脑电; 离散小波变换; 卷积神经网络; 注意力机制

中图分类号: TN911.7; TP391

文献标识码: A

文章编号: 1009-5896(2026)03-0001-11

DOI: 10.11999/JEIT251233

CSTR: 32379.14.JEIT251233

1 引言

虚拟现实(Virtual Reality, VR)技术虽然带来了沉浸式体验, 但其广泛应用正受到虚拟现实晕动症(Virtual Reality Motion Sickness, VRMS)的严重制约——该症状源于用户视觉与前庭觉输入的冲突^[1,2]。这导致部分用户出现恶心、眩晕、头痛等不适^[3,4], 显著降低了用户体验、限制了内容设计并阻碍了VR普及以及在关键领域的应用^[5,6]。因此, 开发客观、实时的VRMS检测技术至关重要, 它不仅能用于监测用户舒适度和耐受时间, 为个性化体验优化提供依据, 是突破当前技术壁垒的关键基础^[7]。

目前评估VRMS的主流方法为主观评测(如问卷调查、口头汇报), 这些方法易受个体主观判断影响准确性, 更关键的是难以在用户沉浸体验过程中实施, 需要中断或干扰体验, 因而几乎无法用于研究VRMS的实时演变^[8-10]。而脑电信号(Electro-

EncephaloGraph, EEG)作为一种无创的生理测量手段, 具备毫秒级时间分辨率, 能持续捕捉大脑认知功能状态变化。其采集过程不打断、干扰用户体验, 且结果不易受个体主观偏差影响。因此, EEG有望成为一种客观、实时的VRMS检测指标, 为研究VRMS的动态变化特征及相关因素的即时作用机制提供支撑^[11-13]。例如, Liao等人^[14]利用深度学习模型, 通过学习用户在晕动症初发时的EEG模式, 提前预测症状。该模型在过山车场景中表现优异, 准确率达82.83%, 超越传统模型, 且在其他数据集上也表现良好。Feng等人^[10]通过分析EEG在时间域、频率域、空间域和黎曼空间的特征, 并使用传统机器学习进行分类。结果显示, 受试者内部分类准确率达92%, 跨受试者达68%, 全频段谱熵和谱偏度分别在VRMS诱发前后和任务阶段表现最佳。这两个研究说明EEG可用于VRMS的检测, 同时代表了EEG解码研究中的两个路径: 深度学习和手工特征。

在EEG分析中, 手工特征提取具有可解释性强、计算效率高、适合小样本和领域知识融合的优势, 便于理解生理机制并应用于实时处理; 但其劣势在于可能丢失复杂信息、依赖专家经验且对高阶模式(如动态网络)捕捉不足^[15,16]。而深度学习能自动学习EEG中的深层与非线性特征, 在处理大规模数据时展现出更优性能, 但其“黑箱”特性导致

收稿日期: 2025-11-24; 改回日期: 2026-01-10; 网络出版: 2026-01-24

*通信作者: 化成城 huachengcheng@nuist.edu.cn

基金项目: 国家自然科学基金(62206130), 江苏省自然科学基金(BK20200821), 南京信息工程大学人才启动经费(2020r075)

Foundation Items: The National Natural Science Foundation of China (62206130), The Natural Science Foundation of Jiangsu Province (BK20200821), The Startup Foundation for Introducing Talent of NUIST (2020r075)

可解释性差,且依赖高质量标注数据^[17]。两者结合则能取长补短^[18,19]。Chen等人^[20]提出了一种新颖的基于EEG的脑网络与卷积神经网络(Convolutional Neural Network, CNN)结合的深度学习框架用于注意力缺陷/多动障碍识别,通过重组EEG通道顺序,构建了适配CNN的脑网络邻接矩阵。该框架在测试中达到了94.67%的高准确率。Wang等人^[21]提出一种新颖的基于EEG的情绪识别方法,通过构建微分熵特征矩阵结合二维卷积长短期记忆模型解决传统方法忽略导联间空间相关性的问题。王春丽等人^[22]提出了一个基于时频空多维特征短时窗口的脑电模型,该模型采用并行双分支结构,分别以脑电信号和微分熵特征作为输入,实现了在0.1 s决策窗口下听觉注意力解码精度91.8%。Dhongade等人^[23]提出了一种基于小波变换和深度学习的EEG分析方法,用于高精度检测精神分裂症,在公开数据集上分别取得99.61%和99.12%的分类准确率,性能优于现有技术。以上将手工特征与深度学习相结合的优势在于兼顾了性能与可解释性,使脑电数据的后验分布和先验知识形成互补,已成为EEG分析领域的关键路径之一。

鉴于上述优势,本文提出一种创新方法:将小波变换提取的物理意义明确的时空特征,与注意力机制自适应的关键特征相结合。离散小波变换具有时频分辨能力,适合表征非平稳信号的瞬态特征。Minhas等人^[24]使用离散小波变换,结合7种阈值技术,评估EEG 6个单通道的45种特征组合。通过优化通道选择,降低可穿戴设备的计算需求。Shen等人^[25]提出一种基于EEG的实时癫痫发作检测方法,其核心是利用离散小波变换提取关键多频带特征并输入级联分类器。在公开数据集UB和CHB-MIT上实现了优异的性能,证明了小波变换对提取区分性时频特征的有效支撑作用。Dhongade等人^[23]提出一种基于小波变换与深度学习的精神分裂症EEG检测方法。核心通过离散小波变换分解EEG并提取多频带特征,显著增强特征的判别性。Wen等人^[26]提出一种基于小波包变换-奇异值分解-Logistic映射的隐写算法。在隐写算法中,小波包变换通过将EEG分解为多个子带信号,为隐藏私人信息提供了更大容量,同时保持信号的感知保真度。先前这些研究多将一维小波变换应用于EEG时序,专注时频分析但难以捕获空间关联性。为更好地建模EEG的时空耦合特性,本文采用二维小波变换,直接作用于依据导联位置排列的二维EEG。它同时进行空间邻域(导联拓扑)与时间动态的分解,能同时刻画多导联在特定频带和空间尺度

下的振荡模式,为后续处理提供蕴含时空上下文的基础特征表示。

在EEG分析中,通过时间卷积层对EEG进行滤波,不同通道对应不同卷积核,提取多通道的时频特征,随后应用通道注意力机制优化这些特征在频域或时频域的权重分配,可有效增强关键神经振荡模式的表征能力。Qin等人^[27]提出了一种结合高效通道注意力和时间卷积网络的端到端网络,其中紧凑CNN和时间卷积网络提取时频特征,通道注意力模块增强通道信息,实现参数少、速度快的轻量级的运动想象EEG分类。Zhou等人^[28]提出了双分支注意力时序卷积模型,模型包含注意力双分支卷积模块和注意力时间融合卷积模块。注意力双分支卷积模块利用双分支卷积提取低级运动想象EEG特征,注意力机制优化时空特征权重分配。该模型在BCI-IV-2a数据集达到到被试依赖分类87.54%、跨被试分类71.34%,PhysioNet跨被试任务达87.33%(二分类)和69.58%(四分类)。现有研究在EEG处理中已证实空间注意力机制的有效性,特别是在建模电极间拓扑关系方面,如图注意力网络在运动想象分类中的成功应用^[29,30]。受此启发,本文在VRMS检测任务中引入双维度注意力融合框架:在保留通道注意力对特征重要性动态校准的基础上,引入导联注意力机制^[31]。该机制显式建模头皮电极的空间关联性,实现对EEG“频域-空间”双维度的协同增强。

本文提出一种创新的双路模型(Wavelet Transform ATtentional Network, WTATNet),专门用于基于EEG的VRMS检测。本文的主要贡献为:(1)提出一种基于EEG的VRMS检测方法。本方法结合了深度学习与人工特征,实现了98.39%的平均准确率,优于当前最先进方法;(2)引入二维小波变换用于EEG分析,同步解析EEG的时间时空特征;(3)提出双注意力机制,通道注意力处理频域特征,导联注意力处理空域特征,形成“频域-空间”联合优化。

2 实验与数据获取

2.1 实验设计和虚拟现实场景

如图1所示为实验流程和部分场景图片。为了诱发受试者的VRMS,实验使用由Bit Planet Games开发的一款名为《超级滑翔翼2》的VR游戏。VR设备为Pico4。任务中,玩家需操纵飞机飞过VR场景中不同位置和方向的7个目标。这个过程持续5 min,足以诱发VRMS,又不会太严重,以免对受试者造成潜在的危害。此外,为了使所有受试者

的暴露时长一致，若受试者提前完成任务，则重复任务至5 min。若受试者未在5 min内完成，则任务也将结束。实验为每个受试者收集任务前和后的5 min 静息状态EEG。在该过程，要求受试者保持放松并闭上眼睛以避免视觉刺激。受试者在完成任务前后都要填写虚拟现实晕眩问卷(Virtual Reality Sickness Questionnaire, VRSQ)，用来评估他们当时的VRMS水平。数据选自静息状态，可避免任务过程中刺激和动作的影响。任务前静息态被视为无VRMS状态，任务后静息态被视为VRMS状态，这一点可通过VRSQ结果证明。

2.2 数据获取及预处理

本研究共招募了22名受试者(16名男性和6名女性，年龄在19~28岁)。受试者均身体健康，无酗酒史或精神病史，对眩晕无特殊敏感性，视力正常或矫正视力正常。受试者需遵守实验要求：(1)充分休息，不喝提神饮料或药物；(2)保持头发清洁；(3)实验前1 h内不进食水。本实验中，EEG由Neuroscan Grael采集，采样率为1 024 Hz，脑电帽的30个电极按照10~20国际标准放置。

EEG振幅较弱，极易受到干扰，因此需要对原始EEG进行预处理，以获得纯净的EEG。本文的预处理步骤如下：(1)人工去除明显伪影；(2)使

用ICA及眼电参考电极去除眼电伪影；(4)设置50 Hz、100 Hz和150 Hz陷波滤波器消除工频干扰；(5)设置0.5~100 Hz的带通滤波器，滤除非EEG节律的成分。(6)下采样至200 Hz。最后将预处理后EEG无重叠地分割为长度1秒的片段作为样本，共得到6 344个任务前静息状态样本和6 589个任务后静息状态样本。

3 基于小波变换和导联注意力的双路模型

3.1 整体模型

如图2所示为WTATNet的结构，该模型由两条支路构成。支路1结合二维离散小波变换和CNN，用于提取EEG多尺度的时空特征。支路2为嵌入通道注意力和导联注意力模块的CNN网络。最后将两条支路所提取到的特征进行融合并送入两层全连接层进行分类，神经元个数分别为128,2。

3.2 小波变换

在支路1中，首先进行二维离散小波变换，通过外积构造4个滤波器核，并对输入信号进行卷积(步长为2)，将输入信号分解为4个子带：LL频带(低频分量)、LH频带(垂直低频-水平高频分量)、HL频带(垂直高频-水平低频分量)、HH频带(高频分量)。二维离散小波变换的计算公式见式(1)~(4)

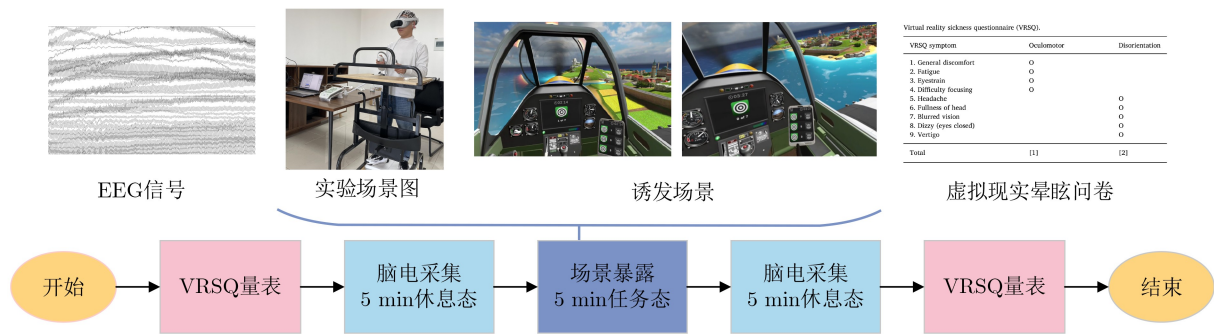


图1 实验流程

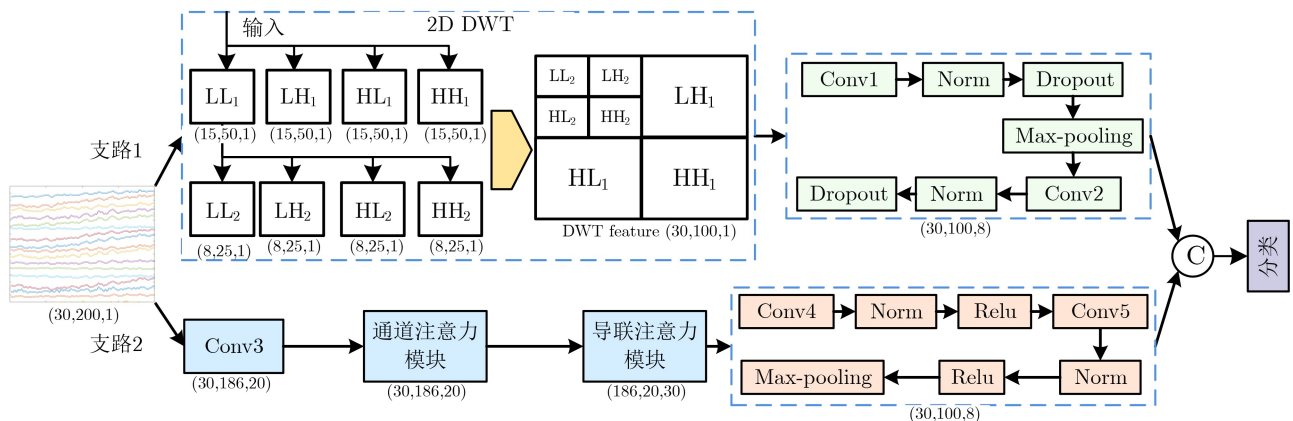


图2 基于小波变换和导联注意力的双路模型(WTATNet)

$$LL = (x * h) * h^T \quad (1)$$

$$LH = (x * h) * g^T \quad (2)$$

$$HL = (x * g) * h^T \quad (3)$$

$$HH = (x * g) * g^T \quad (4)$$

其中, h 是低通滤波器, g 是高通滤波器, $*$ 表示卷积操作(下采样步长为2)。为了获得更多的窄带成分, 可进行多一级的小波分解, 该分解是对低频子带LL进行的而保留高频子带(LH,HL,HH), 每级分解会将两个维度的长度减半, 并按Mallat布局重组, 用于捕获多尺度时间-空间特征。最后, 两级分解得到的小波系数根据图2所示拼接成与原数据尺寸相同的特征张量, 经过两层CNN进行特征提取。卷积核的大小都是(3,3), 卷积核的数量分别为16, 32。

需要注意的是, 二维小波不仅对EEG的时间维进行处理, 还涉及对其导联维的操作。但一维导联的线性排布无法反映导联在二维空间的位置关系。为了使二维小波能够提取部分有效的空间信

息, 本文根据电极空间位置, 按照横向和竖向进行两种不同的一维化处理, 如图3与表1所示。此外, 为了侧面验证二维小波变换的作用, 本文将导联做了3次随机排序, 如表1所示, 将其与横向和竖向两种排序进行对比。

3.3 通道注意力模块

在支路2中, EEG首先经过一个1D-CNN层, 该1D-CNN的卷积核尺寸为(1,15), 拥有20个输出通道。然后通道注意力模块是对特征通道进行加权来强化其表征能力(图4)。该模块首先对特征进行全局最大池化和全局平均池化, 然后将两个池化结果通过共享的多层感知机(MultiLayer Perceptron, MLP)层, 并将输出加在一起得到通道权值。最后将这个通道权值与输入特征相乘, 得出强化后特征。通道注意机制的主要思想是利用训练好的网络为各通道特征分配权重, 使后续网络聚焦在一些通道上, 忽视另一些通道。通道权值计算公式为

$$W_C = \sigma((MLP F_{avg}(X_C))) + \sigma((MLP F_{max}(X_C))) \quad (5)$$

其中, σ 是sigmoid激活函数, F_{avg}^c 和 F_{max}^c 分别表示全局平均池化和全局最大池化, X_C 是输入特征图。

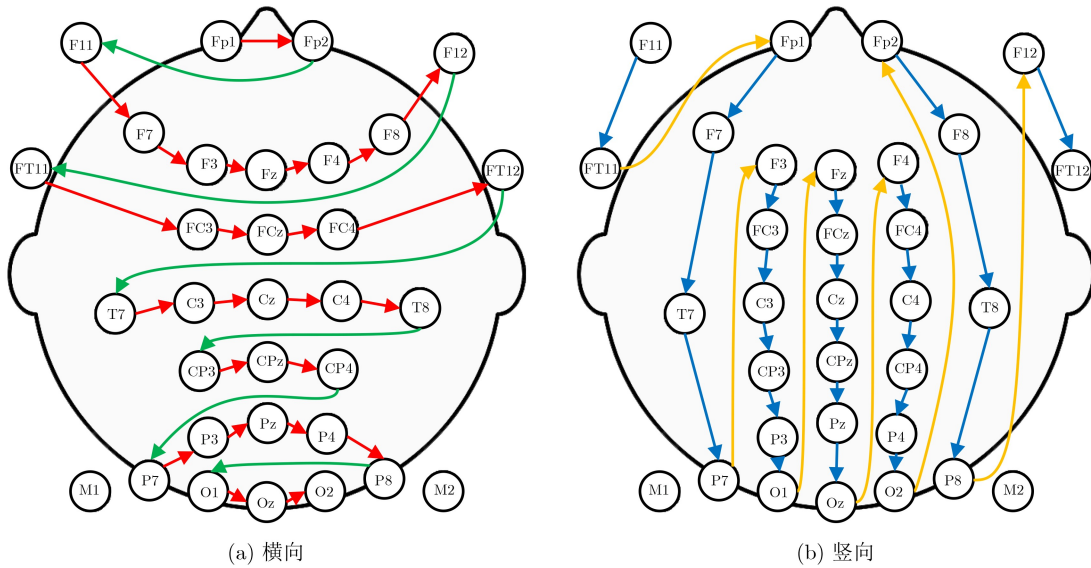


图3 两种导联排序方式示意图

表1 一维导联排序方法

方法	导联顺序
横向	[Fp1, Fp2, F11, F7, F3, Fz, F4, F8, F12, FT11, FC3, FCz, FC4, FT12, T7, C3, Cz, C4, T8, CP3, CPz, CP4, P7, P3, Pz, P4, P8, O1, Oz, O2]
竖向	[F11, FT11, Fp1, F7, T7, P7, F3, FC3, C3, CP3, P3, O1, Fz, FCz, Cz, CPz, Pz, Oz, F4, FC4, C4, CP4, P4, O2, Fp2, F8, T8, P8, F12, FT12]
随机1	[O1, C3, P3, C4, F12, FT11, Oz, Pz, FC4, Fp1, F3, Cz, Fz, FT12, FCz, P7, Fp2, F11, P4, F7, CP4, P8, T8, O2, CPz, F8, FC3, T7, CP3, F4]
随机2	[F8, O2, Fz, P8, F12, O1, FC4, CP4, FCz, P3, T8, F3, F7, Pz, Cz, T7, CPz, FT11, C3, P4, Fp1, Fp2, P7, FC3, CP3, C4, F4, Oz, F11, FT12]
随机3	[C4, FC4, P7, Fp2, F4, P8, Fp1, P3, FT11, Cz, F3, F11, T8, CP3, F7F12, O2, F8, Oz, CP4, FT12, CPz, Pz, T7, C3, FC3, P4, FCz, Fz, O1]

3.4 导联注意力模块

在多导联EEG处理中, 由于脑电帽佩戴误差和受试者头模型差异, EEG的空间信息易受影响。导联注意力机制通过对不同导联的特征进行非线性变换获取权重, 增强与任务相关的导联, 有望克服空间信息偏差。导联注意力模块首先借鉴ShallowConvNet^[32]的思路, 对每个元素进行平方, 以计算特征功率来放大其非线性表达。接着对平方后的EEG进行全局最大池化和全局平均池化。将两个池化的结果传递给共享的MLP层, 并将输出加在一起作为导联权重

$$W_L = \sigma(\text{MLP}(F_{\text{avg}}(\text{Square}(X_L)))) + \sigma(\text{MLP}(F_{\text{max}}(\text{Square}(X_L)))) \quad (6)$$

其中, σ 是sigmoid激活函数, X_L 是输入特征图。最后, 将双注意力模块提取到的信息再经过两层CNN进行特征提取, 卷积核的大小分别是(30,1), (1,15), 卷积核的数量分别是32,64。

3.5 模型验证

本文采用10折交叉验证来评估模型性能, 数据集被随机均匀地分成10份, 重复10次训练, 每次训练由1份数据作为测试集, 其余9份用于训练。本文中使用4个评价指标评价模型有效性: accuracy, precision, F1和recall。为防止过拟合, 本文设置了正则化及早停(early stopping)。在每一折训练中, 训练集被进一步划分为训练子集(80%)和验证子集(20%)。早停的耐心值设为10, 其判断与学习率自

适应调整(采用ReduceLRonPlateau策略, 当验证损失不再改善时学习率减半)均基于验证子集的损失进行。这样可有效提升训练效率、模型性能, 并防止过拟合。初始学习率设置为 1×10^{-4} , 优化器为Adam, 损失函数为交叉熵。最终, 模型在测试集上评估, 所报告的总体性能为10折结果的平均值。该模型基于Keras构建, 并在NVIDIA GeForce RTX4050 GPU上进行训练。

4 实验结果

4.1 对照实验

为了验证本文所提模型的性能, 引入8个脑电模型作为参照, 表2是这些模型分类结果。其中本文所提WTATNet实现了最好的分类性能, accuracy, precision, F1和recall分别为98.39%, 98.39%, 98.38%, 98.40%。就准确率而言, 比经典模型DeepConvNet, ShallowConvNet, EEGNet, EEGNet_old, EEGNet_SSVEP分别高30.9%, 2.84%, 25.99%, 30.61%, 19.14%, 比先进模型ConTraNet^[33], Conformer^[34], FBCNet^[35]分别高13.42%, 5.05%, 0.35%。

4.2 消融实验

为验证WTATNet中各个模块的效果, 本文设置了一系列消融实验。消融实验中的模型具体设置如下。模型1: 无小波变换模块。模型2: 无导联注意力模块。模型3: 无通道注意力模块。模型4: 仅完整的第1条支路。模型5: 仅完整的第2条支路。




图4 两个注意力模块结构图

表2 对照实验结果(平均值±标准差)(%)

模型/指标	accuracy	F1	precision	recall
WTATNet(本文)	98.39±0.56	98.39±0.53	98.38±0.53	98.40±0.52
DeepConvNet	67.49±6.03	64.00±8.13	68.12±5.88	78.98±2.73
ShallowConvNet	95.55±4.03	95.49±4.13	95.44±4.20	96.14±3.16
EEGNet	72.40±4.45	70.76±5.32	72.91±4.08	79.56±2.34
EEGNet_old	67.78±3.73	65.04±4.98	68.32±3.58	76.79±2.08
EEGNet_SSVEP	79.25±4.59	78.58±4.92	79.59±4.42	83.68±2.91
ConTraNet ^[33]	84.97±6.05	84.66±6.57	85.09±6.03	96.82±3.75
Conformer ^[34]	93.34±2.28	93.32±2.29	93.42±2.24	93.84±1.86
FBCNet ^[35]	98.04±0.92	98.03±0.93	98.02±0.95	98.08±0.82

模型6: 仅第2条支路且无通道注意力模块。模型7: 仅第2条支路且无导联注意力模块。模型8: 将WTATNet中的二维小波变换替换为一维小波变换, 仅对时间维进行小波分解。模型1~8的其余部分均与完整模型保持一致, 这些模型在导联横向排序和竖向排序下的结果如表3所示。在横向排序中, 模型1的准确率比完整模型低1.78%, 这表明小波变换在EEG特征提取中发挥了重要作用。模型2与模型3的准确率分别比完整模型低1.36%, 1.01%, 这表明在支路2中, 注意力模块有效捕捉了EEG的关键通道和导联, 提升了特征表达的精准性, 且导联注意力比通道注意力略重要。模型4与模型5的准确率分别比完整模型低1.66%, 1.82%, 表明双路模型通过融合多路径信息, 能获得更高的分类精度或特征区分度, 且支路1的作用相对支路2更重要一点。模型6与模型7的准确率分别比模型5高0.58%, 0.24%, 这表明在单路模型中, 通道注意力模块与导联注意力模块没有表现出明显作用。模型8的准确率比所提出的模型低1.78%, 表明二维小波变换在提取EEG特征时优于一维小波变换。这里的一维小波变换对一维时间序列进行多尺度分析。而二维小波变换通常是对二维图像进行多分辨率分解。它通过可分离的滤波器组, 同时在两个维度上(对于EEG, 即导联维和时间维)进行卷积和下采样操作。

此外, 可以看出电极横向排序略优于竖向排

序。竖向排序下模型1、模型2与模型3的准确率分别比所完整低1.85%, 1.06%, 3.43%, 表明在电极竖向排序时, 导联注意力模块的作用更大。模型3较高的标准差可能反映了其对参数初始化的敏感性增加以及正则化效果的减弱, 这进一步说明了通道注意力机制不仅提升性能, 还具有稳定训练的作用。此外, 模型4与模型5的准确率分别比完整模型低2.31%, 1.06%, 这再次表明双路模型效果更好, 且支路1作用更大。模型6、模型7的准确率分别比模型5高0.29%, 0.14%, 这表明通道注意力与导联注意力在单路也没有发挥出明显作用。这些结果与横向排序下结果基本一致。

此外, 本文还将EEG做了3次导联随机重排并放入所提出的模型中验证, 结果如表4所示。3次随机排列的模型准确率均低于电极横向排列与竖向排列的结果。

4.3 特征可视化分析

为了验证WTATNet的分类性能及各模块的效果, 本文利用T-SNE算法将本文所提模型、所有对照模型以及消融实验中的模型所学习到的高维特征映射到二维空间, 并将可视化结果在图5和图6中展示。如图5所示, EEGNet, EEGNet_old, EEGNet_SSVEP, ConTraNet以及DeepConvNet的两类数据点重叠较多, 没有学习到明显的特征。ShallowConvNet, FBCNet具有明显的边界, 分类

表3 电极横向排序下模型消融实验结果(平均值±标准差)(%)

模型/指标	横向排序				竖向排序			
	accuracy	F1	precision	recall	accuracy	F1	precision	recall
WTATNet	98.39±0.56	98.39±0.53	98.38±0.53	98.40±0.52	97.97±0.50	97.97±0.50	97.97±0.50	97.98±0.49
模型1	96.61±0.55	96.60±0.55	96.59±0.56	96.64±0.54	96.12±0.74	96.11±0.73	96.10±0.73	96.16±0.74
模型2	97.03±0.60	97.02±0.61	96.99±0.63	97.15±0.54	96.91±0.54	96.90±0.54	96.86±0.55	97.03±0.51
模型3	97.38±0.33	97.38±0.33	97.36±0.32	97.41±0.35	94.54±5.37	94.46±5.55	94.57±5.22	95.28±3.82
模型4	96.73±0.61	96.72±0.61	96.69±0.62	96.81±0.59	95.66±0.57	95.65±0.58	95.60±0.61	95.81±0.47
模型5	96.57±0.47	96.57±0.47	96.57±0.47	96.58±0.47	96.91±0.68	96.91±0.68	96.89±0.68	96.95±0.67
模型6	97.15±0.64	97.14±0.64	97.13±0.65	97.18±0.62	97.20±0.46	97.20±0.46	97.19±0.46	97.24±0.44
模型7	96.81±0.34	96.80±0.34	96.78±0.35	96.86±0.32	97.05±0.42	97.05±0.42	97.02±0.42	97.12±0.43
模型8	96.61±0.73	96.61±0.73	96.59±0.74	96.65±0.73	/	/	/	/

表4 不同导联重排方法下WTATNet结果(平均值±标准差)(%)

排序/指标	accuracy	F1	precision	recall
横向	98.39±0.56	98.39±0.53	98.38±0.53	98.40±0.52
竖向	97.97±0.50	97.97±0.50	97.97±0.50	97.98±0.49
随机1	96.30±0.68	96.29±0.69	96.29±0.66	96.36±0.73
随机2	97.09±0.39	97.08±0.39	97.07±0.38	97.13±0.39
随机3	96.95±0.64	96.94±0.64	96.92±0.63	96.99±0.65

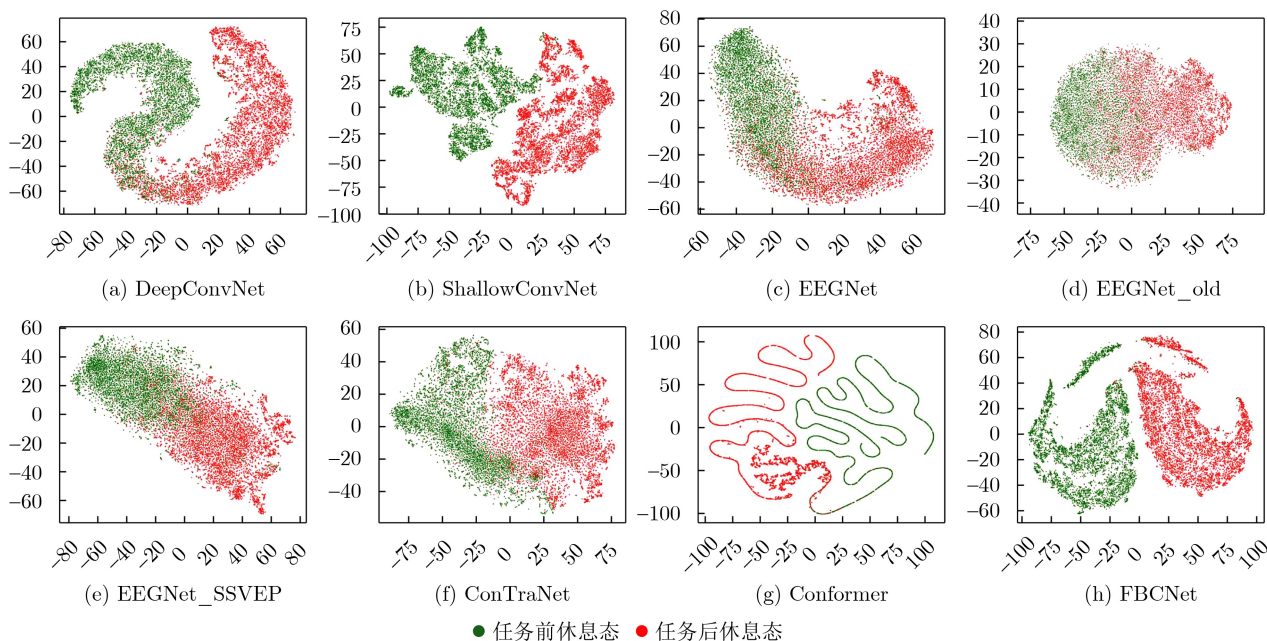


图5 对照实验特征可视化

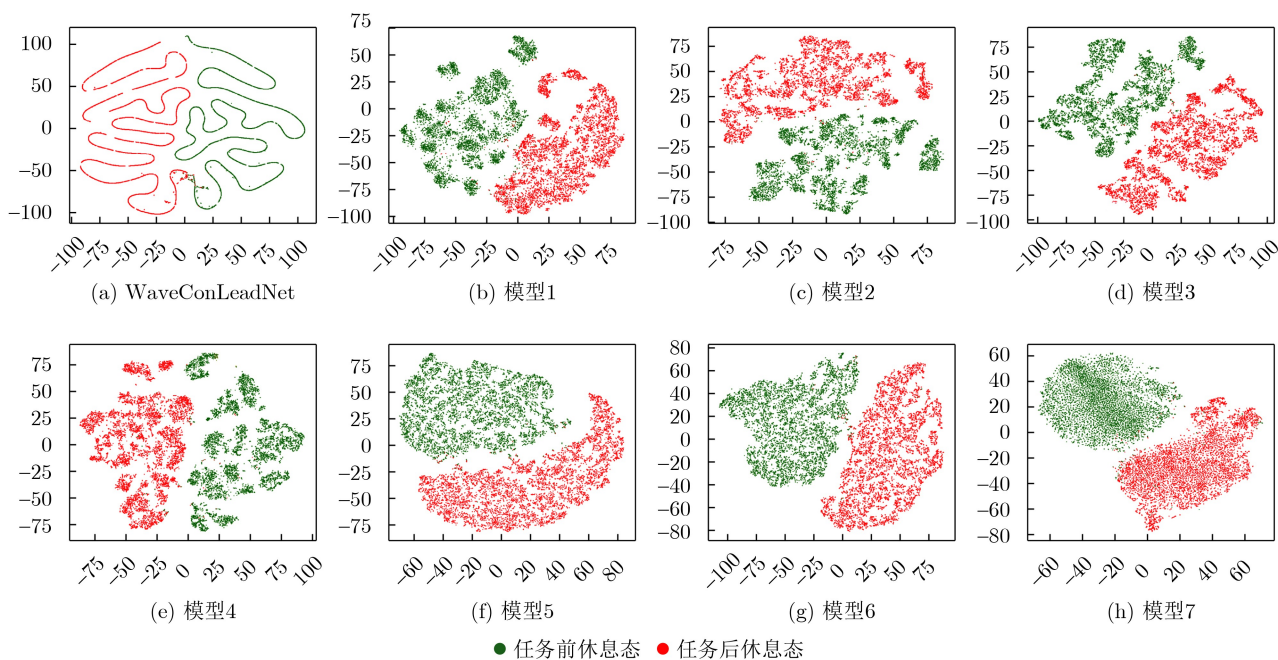


图6 消融实验特征可视化

效果较好，但是聚类效果较差。Conformer整体分类效果较好，但是有少部分点未能形成簇，分布显得杂乱无章。

如图6所示，所有模型的分离程度都比较好，存在清晰的边界，说明WTATNet的基本结构的性能相对稳定，但相对于完整模型，消融实验中其他模型所学特征的聚类效果较差。对比模型4和模型5,6,7，可以看出模型4学习的特征在类内聚集成不同的小簇。而模型1、模型2、模型3的特征可视化与模型4相似，也具有明显的簇。这说明整体上模

块使用越多，特征学习能力越强，但过拟合风险也随着提高。

5 讨论

本模型通过手工特征与深度学习相结合的机制实现VRMS高精度识别，其核心优势在于：(1)二维小波变换在时间维和导联维对信号进行分解，实现多尺度时空特征提取，适合处理多导联非平稳EEG；(2)通道注意力和导联注意力机制，强化模型对关键信息的聚焦能力，减少冗余信息的同时提

升对任务相关特征的敏感性；(3)两条支路分别从EEG不同角度提取特征，融合后能综合多维度信息以形成更全面的特征表示，有助于提高模型的泛化能力和分类性能。本文对比实验和消融实验的结果(表2、表3)验证了本文模型的优势。根据消融实验结果可发现：导联注意力模块和通道注意力模块在单路模型中效果不佳，但在结合小波变换+CNN的双路模型中表现优异。这可能因为支路2通过分层注意力机制虽然具有较强的表征能力，但其属于端到端模型反而强化了模型对噪声的敏感性。而小波变换+CNN支路所提取的手工特征相对于支路2引入了EEG的时频空信息提取的先验知识，对噪声有一定抗性，与支路2形成互补，增强了特征表达的全面性，抑制噪声。本文也做了一维小波变换，其效果远不如二维小波变换。这是因为一维小波变换仅聚焦于时间维的信号变化，忽略了EEG导联之间的空间信息。相比之下，二维小波变换同时对时间维和导联维进行分解，提取更加丰富的多尺度信息。表3的实验结果清晰表明，二维小波变换在分类精度优于一维小波变换。此外，本文不仅将导联进行了横竖两种重排，还进行了3次随机重排，重排后模型的效果均不好，如表4所示。这证明了空间信息的作用，以及小波变换提取到了该信息。随机排列导联破坏了这种空间结构，导致小波变换无法有效捕捉导联间的局部模式或相关性。

但是，本文仍存在一些限制，本研究旨在探索VRMS的EEG标记物，但任务后的EEG变化可能受到疲劳或注意力下降的混淆。尽管本研究采用短时VR暴露以降低疲劳影响，但在当前设计中，仍难以完全将这两种效应分离。未来的研究可通过多种方式进一步澄清这一问题：如设置视觉刺激相似但已知VRMS诱发程度不同的任务条件，或引入不易引发晕动症的非VR认知任务作为疲劳对照等^[36]。由于EEG的导联分布通常具有特定的空间拓扑结构，不连续的重排会破坏导联间的空间相关性和邻近性，使得二维小波变换无法捕捉完全的导联信息。这种空间信息的缺失可能削弱模型对复杂EEG的空间特征表达能力^[37]。未来研究可从多个方向突破：首先可探索图信号处理方法(如图小波变换或图卷积网络)，将电极拓扑关系显式建模为图结构，以更精细地刻画空间依赖关系。其次可尝试将EEG重构为时间×频率×空间的三维张量，并开发对应的三维小波变换算法，以同时提取更全面的时空-频谱特征。此外，可设计拓扑自适应模型，使空间结构能随输入信号调整，以适应个体与任务差异。这些方向有望弥补当前方法在时空信息整合上

的局限，推动EEG处理新范式的发展，为脑机接口与神经疾病诊断提供更强大的分析工具。

6 结论

本文提出了一种基于二维小波变换和导联注意力的双路混合模型WTATNet，本模型将手工特征和深度学习相结合，实现了对VRMS的有效识别。与经典模型与先进的模型相比，本模型实现了最佳性能。消融实验的结果验证了两个支路、小波变换模块、通道注意力模块、导联注意力模块的效果。总体而言，WTATNet的平均准确率、精确率、召回率和F1分别达到98.89%、98.38%、98.40%和98.39%，这表明它能有效检测VRMS，并具有良好的鲁棒性。所提模型不仅可应用于VRMS的检测，也为探索VRMS的成因机制及研发缓解方案提供数据支撑与技术路径。此外，本模型在EEG解码领域展现出泛化潜力，有望拓展应用于其他类型的EEG解析研究，为神经科学、临床医学等相关领域的EEG分析提供新思路。

参考文献

- [1] LIU Ran, XU Miao, ZHANG Yanzhen, *et al.* A pilot study on electroencephalogram-based evaluation of visually induced motion sickness[J]. *Journal of Imaging Science and Technology*, 2020, 64(2): 020501. doi: [10.2352/J.ImagingSci.Technol.2020.64.2.020501](https://doi.org/10.2352/J.ImagingSci.Technol.2020.64.2.020501).
- [2] LIANG Tie, HONG Lei, XIAO Jinzhuang, *et al.* Directed network analysis reveals changes in cortical and muscular connectivity caused by different standing balance tasks[J]. *Journal of Neural Engineering*, 2022, 19(4): 046021. doi: [10.1088/1741-2552/ac7d0c](https://doi.org/10.1088/1741-2552/ac7d0c).
- [3] KENNEDY R S, DREXLER J, and KENNEDY R C. Research in visually induced motion sickness[J]. *Applied Ergonomics*, 2010, 41(4): 494–503. doi: [10.1016/j.apergo.2009.11.006](https://doi.org/10.1016/j.apergo.2009.11.006).
- [4] 顾展滔, 丁玎, 陈亦婷, 等. 面向虚拟现实晕动症的评估与缓解方法[J]. *浙江大学学报: 理学版*, 2025, 52(1): 30–37. doi: [10.3785/j.issn.1008-9497.2025.01.004](https://doi.org/10.3785/j.issn.1008-9497.2025.01.004).
GU Zhantao, DING Ding, CHEN Yiting, *et al.* Evaluation and mitigation methods for virtual reality motion sickness[J]. *Journal of Zhejiang University: Science Edition*, 2025, 52(1): 30–37. doi: [10.3785/j.issn.1008-9497.2025.01.004](https://doi.org/10.3785/j.issn.1008-9497.2025.01.004).
- [5] GOLDING J F. Motion sickness susceptibility[J]. *Autonomic Neuroscience*, 2006, 129(1/2): 67–76. doi: [10.1016/j.autneu.2006.07.019](https://doi.org/10.1016/j.autneu.2006.07.019).
- [6] 蔡力, 翁冬冬, 张振亮, 等. 虚实运动一致性对虚拟现实晕动症的影响[J]. *系统仿真学报*, 2016, 28(9): 1950–1956. doi: [10.16182/j.cnki.joss.2016.09.004](https://doi.org/10.16182/j.cnki.joss.2016.09.004).

- CAI Li, WENG Dongdong, ZHANG Zhenliang, *et al.* Impact of consistency between visually perceived movement and real movement on cybersickness[J]. *Journal of System Simulation*, 2016, 28(9): 1950–1956. doi: [10.16182/j.cnki.joss.2016.09.004](https://doi.org/10.16182/j.cnki.joss.2016.09.004).
- [7] MITTELSTAEDT J M. Individual predictors of the susceptibility for motion-related sickness: A systematic review[J]. *Journal of Vestibular Research*, 2020, 30(3): 165–193. doi: [10.3233/ves-200702](https://doi.org/10.3233/ves-200702).
- [8] 徐子超, 张玲, 肖水凤, 等. 晕动症机制及防治技术研究进展与展望[J]. *海军军医大学学报*, 2024, 45(8): 923–928. doi: [10.16781/j.CN31-2187/R.20240056](https://doi.org/10.16781/j.CN31-2187/R.20240056).
XU Zichao, ZHANG Ling, XIAO Shuifeng, *et al.* Motion sickness mechanism and control techniques: Research progress and prospect[J]. *Academic Journal of Naval Medical University*, 2024, 45(8): 923–928. doi: [10.16781/j.CN31-2187/R.20240056](https://doi.org/10.16781/j.CN31-2187/R.20240056).
- [9] 蔡永青, 韩成, 权巍, 等. 基于注意力机制的视觉诱导晕动症评估模型[J]. *浙江大学学报: 工学版*, 2025, 59(6): 1110–1118. doi: [10.3785/j.issn.1008-973X.2025.06.002](https://doi.org/10.3785/j.issn.1008-973X.2025.06.002).
CAI Yongqing, HAN Cheng, QUAN Wei, *et al.* Visual induced motion sickness estimation model based on attention mechanism[J]. *Journal of Zhejiang University: Engineering Science*, 2025, 59(6): 1110–1118. doi: [10.3785/j.issn.1008-973X.2025.06.002](https://doi.org/10.3785/j.issn.1008-973X.2025.06.002).
- [10] FENG Naishi, ZHOU Bin, ZHANG Qianqian, *et al.* A comprehensive exploration of motion sickness process analysis from EEG signal and virtual reality[J]. *Computer Methods and Programs in Biomedicine*, 2025, 264: 108714. doi: [10.1016/j.cmpb.2025.108714](https://doi.org/10.1016/j.cmpb.2025.108714).
- [11] CAI Mengpu, CHEN Junxiang, HUA Chengcheng, *et al.* EEG emotion recognition using EEG-SWTNS neural network through EEG spectral image[J]. *Information Sciences*, 2024, 680: 121198. doi: [10.1016/j.ins.2024.121198](https://doi.org/10.1016/j.ins.2024.121198).
- [12] CHAUDARY E, KHAN S A, and MUMTAZ W. EEG-CNN-souping: Interpretable emotion recognition from EEG signals using EEG-CNN-souping model and explainable AI[J]. *Computers and Electrical Engineering*, 2025, 123: 110189. doi: [10.1016/j.compeleceng.2025.110189](https://doi.org/10.1016/j.compeleceng.2025.110189).
- [13] MEISER A, LENA KNOLL A, and BLEICHNER M G. High-density ear-EEG for understanding ear-centered EEG[J]. *Journal of Neural Engineering*, 2024, 21(1): 016001. doi: [10.1088/1741-2552/ad1783](https://doi.org/10.1088/1741-2552/ad1783).
- [14] LIAO C Y, TAI S K, CHEN R C, *et al.* Using EEG and deep learning to predict motion sickness under wearing a virtual reality device[J]. *IEEE Access*, 2020, 8: 126784–126796. doi: [10.1109/access.2020.3008165](https://doi.org/10.1109/access.2020.3008165).
- [15] 韩敏, 孙磊磊, 洪晓军. 基于回声状态网络的脑电信号特征提取[J]. *生物医学工程学杂志*, 2012, 29(2): 206–211.
HAN Min, SUN Leilei, and HONG Xiaojun. Extraction of the EEG signal feature based on echo state networks[J]. *Journal of Biomedical Engineering*, 2012, 29(2): 206–211.
- [16] 张成, 汤璇, 杨冬平, 等. 基于深度学习的脑电信号特征检测方法[J]. *电子设计工程*, 2024, 32(15): 156–160. doi: [10.14022/j.issn1674-6236.2024.15.033](https://doi.org/10.14022/j.issn1674-6236.2024.15.033).
ZHANG Cheng, TANG Xuan, YANG Dongping, *et al.* Method for EEG signal feature detection based on deep learning[J]. *Electronic Design Engineering*, 2024, 32(15): 156–160. doi: [10.14022/j.issn1674-6236.2024.15.033](https://doi.org/10.14022/j.issn1674-6236.2024.15.033).
- [17] DAS A, SINGH S, KIM J, *et al.* Enhanced EEG signal classification in brain computer interfaces using hybrid deep learning models[J]. *Scientific Reports*, 2025, 15(1): 27161. doi: [10.1038/s41598-025-07427-2](https://doi.org/10.1038/s41598-025-07427-2).
- [18] RAPARTHI M, MITTA N R, DUNKA V K, *et al.* Deep learning model for patient emotion recognition using EEG-tNIRS data[J]. *Neuroscience Informatics*, 2025, 5(3): 100219. doi: [10.1016/j.neuri.2025.100219](https://doi.org/10.1016/j.neuri.2025.100219).
- [19] GUO Xiang, LIANG Ruiqi, XU Shule, *et al.* An investigation of echo state network for EEG-based emotion recognition with deep neural networks[J]. *Biomedical Signal Processing and Control*, 2026, 111: 108342. doi: [10.1016/j.bspc.2025.108342](https://doi.org/10.1016/j.bspc.2025.108342).
- [20] CHEN He, SONG Yan, and LI Xiaoli. A deep learning framework for identifying children with ADHD using an EEG-based brain network[J]. *Neurocomputing*, 2019, 356: 83–96. doi: [10.1016/j.neucom.2019.04.058](https://doi.org/10.1016/j.neucom.2019.04.058).
- [21] WANG Teng, HUANG Xiaoqiao, XIAO Zenan, *et al.* EEG emotion recognition based on differential entropy feature matrix through 2D-CNN-LSTM network[J]. *EURASIP Journal on Advances in Signal Processing*, 2024, 2024(1): 49. doi: [10.1186/s13634-024-01146-y](https://doi.org/10.1186/s13634-024-01146-y).
- [22] 王春丽, 李金絮, 高玉鑫, 等. 一种基于时空频多维特征的短时段窗口脑电听觉注意解码网络[J]. *电子与信息学报*, 2025, 47(3): 814–824. doi: [10.11999/JEIT240867](https://doi.org/10.11999/JEIT240867).
WANG Chunli, LI Jinxu, GAO Yuxin, *et al.* A short-time window electroencephalogram auditory attention decoding network based on multi-dimensional characteristics of temporal-spatial-frequency[J]. *Journal of Electronics & Information Technology*, 2025, 47(3): 814–824. doi: [10.11999/JEIT240867](https://doi.org/10.11999/JEIT240867).
- [23] DHONGADE D, CAPTAIN K, and DAHIYA S. EEG-based schizophrenia detection: Integrating discrete wavelet transform and deep learning[J]. *Cognitive Neurodynamics*, 2025, 19(1): 62. doi: [10.1007/s11571-025-10248-8](https://doi.org/10.1007/s11571-025-10248-8).
- [24] MINHAS R, PEKER N Y, HAKKOZ M A, *et al.* Improved drowsiness detection in drivers through optimum pairing of EEG features using an optimal EEG channel comparable to a multichannel EEG system[J]. *Medical & Biological Engineering & Computing*, 2025, 63(10): 3019–3036. doi: [10.1007/s11517-025-03375-1](https://doi.org/10.1007/s11517-025-03375-1).
- [25] SHEN Mingkan, WEN Peng, SONG Bo, *et al.* An EEG based real-time epilepsy seizure detection approach using

- discrete wavelet transform and machine learning methods[J]. *Biomedical Signal Processing and Control*, 2022, 77: 103820. doi: [10.1016/j.bsp.2022.103820](https://doi.org/10.1016/j.bsp.2022.103820).
- [26] WEN Dong, JIAO Wenlong, LI Xiaoling, *et al.* The EEG signals steganography based on wavelet packet transform-singular value decomposition-logistic[J]. *Information Sciences*, 2024, 679: 121006. doi: [10.1016/j.ins.2024.121006](https://doi.org/10.1016/j.ins.2024.121006).
- [27] QIN Yuxin, LI Baojiang, WANG Wenlong, *et al.* ETCNet: An EEG-based motor imagery classification model combining efficient channel attention and temporal convolutional network[J]. *Brain Research*, 2024, 1823: 148673. doi: [10.1016/j.brainres.2023.148673](https://doi.org/10.1016/j.brainres.2023.148673).
- [28] ZHOU Kai, HAIMUDULA A, and TANG Wanying. Dual-branch convolution network with efficient channel attention for EEG-based motor imagery classification[J]. *IEEE Access*, 2024, 12: 74930–74943. doi: [10.1109/access.2024.3404634](https://doi.org/10.1109/access.2024.3404634).
- [29] KIEU H D. Graph attention network for motor imagery classification[C]. 2024 RIVF International Conference on Computing and Communication Technologies (RIVF), Danang, Vietnam, 2024: 255–260. doi: [10.1109/RIVF64335.2024.11009062](https://doi.org/10.1109/RIVF64335.2024.11009062).
- [30] LENG Jiancai, GAO Licai, JIANG Xiuquan, *et al.* A multi - feature fusion graph attention network for decoding motor imagery intention in spinal cord injury patients[J]. *Journal of Neural Engineering*, 2024, 21(6): 066044. doi: [10.1088/1741-2552/ad9403](https://doi.org/10.1088/1741-2552/ad9403).
- [31] 化成城, 周占峰, 陶建龙, 等. 导联注意力及脑连接驱动的现实晕动症识别模型研究[J]. 电子与信息学报, 2025, 47(4): 1161–1171. doi: [10.11999/JEIT240440](https://doi.org/10.11999/JEIT240440).
HUA Chengcheng, ZHOU Zhanfeng, TAO Jianlong, *et al.* Virtual reality motion sickness recognition model driven by lead-attention and brain connection[J]. *Journal of Electronics & Information Technology*, 2025, 47(4): 1161–1171. doi: [10.11999/JEIT240440](https://doi.org/10.11999/JEIT240440).
- [32] ALI O, SAIF-UR-REHMAN M, GLASMACHERS T, *et al.* ConTraNet: A hybrid network for improving the classification of EEG and EMG signals with limited training data[J]. *Computers in Biology and Medicine*, 2024, 168: 107649. doi: [10.1016/j.combiomed.2023.107649](https://doi.org/10.1016/j.combiomed.2023.107649).
- [33] SONG Yonghao, ZHENG Qingqing, LIU Bingchuan, *et al.* EEG conformer: Convolutional transformer for EEG decoding and visualization[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 710–719. doi: [10.1109/tnsre.2022.3230250](https://doi.org/10.1109/tnsre.2022.3230250).
- [34] MANE R, CHEW E, CHUA K, *et al.* FBCNet: A multi-view convolutional neural network for brain-computer interface[J]. arXiv preprint arXiv: 2104.01233, 2021. doi: [10.48550/arXiv.2104.01233](https://doi.org/10.48550/arXiv.2104.01233).
- [35] PAN Junting, SAYROL E, GIRO-I-NIETO X, *et al.* Shallow and deep convolutional networks for saliency prediction[C]. The IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 598–606. doi: [10.1109/CVPR.2016.71](https://doi.org/10.1109/CVPR.2016.71).
- [36] 林艳飞, 臧博宇, 郭嵘骁, 等. 基于相频特性的稳态视觉诱发电位深度学习分类模型[J]. 电子与信息学报, 2022, 44(2): 446–454. doi: [10.11999/JEIT210816](https://doi.org/10.11999/JEIT210816).
LIN Yanfei, ZANG Boyu, GUO Rongxiao, *et al.* A deep learning method for SSVEP classification based on phase and frequency characteristics[J]. *Journal of Electronics & Information Technology*, 2022, 44(2): 446–454. doi: [10.11999/JEIT210816](https://doi.org/10.11999/JEIT210816).
- [37] 熊鹏, 刘学朋, 杜海曼, 等. 基于平稳和连续小波变换融合算法的心电信号P, T波检测[J]. 电子与信息学报, 2021, 43(5): 1441–1447. doi: [10.11999/JEIT200049](https://doi.org/10.11999/JEIT200049).
XIONG Peng, LIU Xuepeng, DU Haiman, *et al.* Detection of ECG signal P and T wave based on stationary and continuous wavelet transform fusion[J]. *Journal of Electronics & Information Technology*, 2021, 43(5): 1441–1447. doi: [10.11999/JEIT200049](https://doi.org/10.11999/JEIT200049).
- 陈玥池: 女, 硕士生, 研究方向为脑电信号处理、虚拟现实晕动症。
化成城: 男, 副教授, 研究方向为脑电信号与脑机接口。
戴志安: 男, 硕士生, 研究方向为脑电迁移学习算法。
付景琦: 男, 硕士生, 研究方向为脑电跨被试算法、图神经网络。
朱敏: 女, 硕士生, 研究方向为脑电信号、少数导联检测虚拟现实晕动症。
汪秋宇: 硕士生, 研究方向为脑电信号、脑电信号特征提取、脑电信号的深度学习分析。
严颖: 男, 副教授, 研究方向为复杂系统的故障诊断与故障预测、脑机、机器学习、优化等。
刘佳: 女, 教授, 研究方向为多模态情感分析、计算机视觉与图像处理、虚拟/增强现实。

责任编辑: 余蓉

Wavelet Transform and Attentional Dual-Path EEG Model for Virtual Reality Motion Sickness Detection

CHEN Yuechi^① HUA Chengcheng^{①②} DAI Zhian^① FU Jingqi^① ZHU Min^①
WANG Qiuyu^① YAN Ying^{①②} LIU Jia^{①②}

^①(*Jiangsu Province Engineering Research Center of Intelligent Meteorological Exploration Robot, Nanjing University of Information Science and Technology, Nanjing 210044, China*)

^②(*Jiangsu Collaborative Innovation Center of Atmospheric Environment and Equipment Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China*)

Abstract:

Objective Virtual Reality Motion Sickness (VRMS) presents a barrier to the wider adoption of immersive Virtual Reality (VR). It is primarily caused by sensory conflict between the vestibular and visual systems. Existing assessments rely on subjective reports that disrupt immersion and do not provide real-time measurements. An objective detection method is therefore needed. This study proposes a dual-path fusion model, the Wavelet Transform ATtentional Network (WTATNet), which integrates wavelet transform and attention mechanisms. WTATNet is designed to classify resting-state ElectroencephaloGraph (EEG) signals collected before and after VR motion stimulus exposure to support VRMS detection and research on the mechanisms and mitigation strategies.

Methods WTATNet contains two parallel pathways for EEG feature extraction. The first applies a Two-Dimensional Discrete Wavelet Transform (2D-DWT) to both the time and electrode dimensions of the EEG, reshaping the signal into a two-dimensional matrix based on the spatial layout of the scalp electrodes in horizontal or vertical form. This decomposition captures multi-scale spatiotemporal features, which are then processed using Convolutional Neural Network (CNN) layers. The second pathway applies a one-dimensional CNN for initial filtering followed by a dual-attention structure consisting of a channel attention module and an electrode attention module. These modules recalibrate the importance of features across channels and electrodes to emphasize task-relevant information. Features from both pathways are fused and passed through fully connected layers to classify EEGs into pre-exposure (non-VRMS) and post-exposure (VRMS) states based on subjective questionnaire validation. EEG data were collected from 22 subjects exposed to VRMS using the game “Ultrawings2.” Ten-fold cross-validation was used for training and evaluation with accuracy, precision, recall, and F1-score as metrics.

Results and Discussions WTATNet achieved high VRMS-related EEG classification performance, with an average accuracy of 98.39%, F1-score of 98.39%, precision of 98.38%, and recall of 98.40%. It outperformed classical and state-of-the-art EEG models, including ShallowConvNet, EEGNet, Conformer, and FBCNet (Table 2). Ablation experiments (Tables 3 and 4) showed that removing the wavelet transform path, the electrode attention module, or the channel attention module reduced accuracy by 1.78%, 1.36%, and 1.01%, respectively. The 2D-DWT performed better than the one-dimensional DWT, supporting the value of joint spatiotemporal analysis. Experiments with randomized electrode ordering (Table 4) produced lower accuracy than spatially coherent layouts, indicating that 2D-DWT leverages inherent spatial correlations among electrodes. Feature visualizations using t-SNE (Figures 5 and 6) showed that WTATNet produced more discriminative features than baseline and ablated variants.

Conclusions The dual-path WTATNet model integrates wavelet transform and attention mechanisms to achieve accurate VRMS detection using resting-state EEG. Its design combines interpretable, multi-scale spatiotemporal features from 2D-DWT with adaptive channel-level and electrode-level weighting. The experimental results confirm state-of-the-art performance and show that WTATNet offers an objective, robust, and non-intrusive VRMS detection method. It provides a technical foundation for studies on VRMS neural mechanisms and countermeasure development. WTATNet also shows potential for generalization to other EEG decoding tasks in neuroscience and clinical research.

Key words: Virtual Reality Motion Sickness (VRMS); ElectroencephaloGraph (EEG); Discrete Wavelet Transform (DWT); Convolutional Neural Network (CNN); Attention mechanism