

驾驶疲劳EEG检测中二分类与三分类的对比研究

林靖涵

应急管理大学, 应急通信与控制工程学院, 河北 廊坊

收稿日期: 2026年8月2日; 录用日期: 2026年9月1日; 发布日期: 2026年9月9日

摘要

针对驾驶疲劳检测中分类策略选择不明确的问题, 基于公开的多模态驾驶疲劳表型数据集MPD-DF, 采用EEGConformer模型对比二分类(清醒vs.疲劳)与三分类(清醒vs.轻度疲劳vs.中重度疲劳)策略。实验采用样本级分层划分, 经数据清洗、标签映射与被试内归一化后, 二分类纳入33名有效被试, 三分类纳入14名有效被试。结果表明, 三分类任务测试集准确率达92.41%, 精确率89.82%, 召回率93.62%, F1分数91.55%, 各项核心指标均优于二分类(准确率90.54%, F1 85.13%); 其中三分类对中重度疲劳的召回率高达97.88%, 临床预警价值突出。三分类策略通过保留疲劳程度的层级划分, 有效降低了误报率并实现了对疲劳渐进过程的分级刻画, 可为驾驶疲劳的分级预警与差异化干预提供可靠的识别依据。

关键词

驾驶疲劳, 脑电信号, 疲劳检测, 分类策略, 深度学习

Comparative Study of Binary and Ternary Classification in EEG-Based Driving Fatigue Detection

Jinghan Lin

School of Emergency Communication and Control Engineering, University of Emergency Management, Langfang Hebei

Received: August 2, 2026; accepted: September 1, 2026; published: September 9, 2026

Abstract

To address the ambiguity in classification strategy selection for driving fatigue detection, this study

文章引用: 林靖涵. 驾驶疲劳 EEG 检测中二分类与三分类的对比研究[J]. 计算机科学与应用, 2026, 16(9): 100-109.
DOI: 10.12677/csa.2026.169292

compares binary classification (wakefulness vs. fatigue) and ternary classification (wakefulness vs. light fatigue vs. moderate-severe fatigue) using the EEGConformer model on the public MPD-DF dataset. After data cleaning, label mapping, and subject-wise normalization, the binary task included 33 valid subjects and the ternary task included 14 valid subjects under stratified sample-level partitioning. Results show that the ternary task achieves a test accuracy of 92.41%, precision of 89.82%, recall of 93.62%, and F1-score of 91.55%, all superior to the binary task (accuracy 90.54%, F1 85.13%). Notably, the recall for moderate-severe fatigue in the ternary task reaches 97.88%, demonstrating prominent clinical early-warning value. By preserving the hierarchical division of fatigue levels, the ternary strategy effectively reduces false alarms and enables graded characterization of the fatigue progression process, providing a reliable basis for graded early warning and differentiated intervention in driving fatigue monitoring.

Keywords

Driving Fatigue, Electroencephalogram, Fatigue Detection, Classification Strategy, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 研究背景与意义

疲劳驾驶是引发道路交通事故的重要诱因之一。Chowdhury 等指出[1], 根据世界卫生组织统计, 疲劳驾驶是交通事故发生的主要原因之一。因此, 对驾驶疲劳状态进行准确、实时地监测与预警, 对于降低事故风险、保障道路交通安全具有重要的工程应用价值。

在各类生理信号中, 脑电信号(EEG)能够直接反映大脑皮层神经电活动, 具有时间分辨率高、对疲劳状态敏感等优势, 被视为驾驶疲劳评估的“金标准”[2]。现有检测系统主要基于视觉行为识别和生理信号检测两类技术。刘萱等[3]设计了基于 TGAM 脑电波传感器的嵌入式疲劳检测系统, 通过专注度与冥想度阈值实现实时预警; 陈小强等[4]则提出视觉-生理多模态融合策略, 结合改进 CNN 与 ECG、EEG、EMG 信号, 实现了较高精度的疲劳状态识别。然而, 上述研究大多将疲劳检测建模为二分类问题, 模型结构简单但粒度较粗, 难以刻画疲劳的渐进发展过程。

近年来, 深度学习方法在 EEG 疲劳识别中展现出显著优势。刘帅等[5]提出多维度注意力融合型 Inception 网络(MDAIN), 通过频带分离与跨频带卷积实现了较高的平均准确率; 但现有研究多为二分类框架, 将轻度疲劳与重度疲劳笼统归并, 可能导致预警时机滞后。而三分类策略虽能实现精细化分级, 却面临类别边界模糊、样本不均衡及决策复杂度提升等问题。目前, 二分类与三分类策略在统一模型与统一数据下的系统性对比仍较为匮乏。为此, 本文选用 EEGConformer 网络分别开展二分类与三分类任务, 通过样本级分层划分对比两类策略的性能差异, 为驾驶疲劳 EEG 检测的分类策略选择提供实验依据。

1.2. 相关工作

驾驶疲劳检测算法按输入信号类型可分为非生理信号法与生理信号法两大类。非生理信号法主要包括基于计算机视觉的面部特征检测和基于车辆动力学参数的行为模式识别, 部署成本低但易受光照、遮挡及驾驶风格差异影响。生理信号法中, 心电(ECG)、眼电(EOG)和脑电(EEG)等能够反映驾驶员内部生

理状态, 其中 EEG 因直接记录中枢神经元活动, 被广泛视为疲劳监测的可靠途径。

传统 EEG 疲劳检测方法通常先通过时频分析提取 δ 、 θ 、 α 、 β 等频带特征, 再采用 SVM、随机森林等浅层分类器进行识别[6]。这类方法依赖人工特征工程, 难以刻画 EEG 信号中复杂的非线性时空耦合关系。近年来, 深度学习方法在 EEG 信号自动特征学习中展现出显著优势。Lawhern 等[7]提出的 EEGNet 以紧凑的卷积结构实现了高效的 EEG 解码。但上述研究主要集中在二分类框架, 针对同一模型架构下二分类与三分类策略的系统性对比研究仍较为匮乏。

1.3. 模型结构概述

为便于理解两类分类策略在检测性能上的差异, 本节介绍 EEGConformer 模型的核心结构及二分类、三分类任务的设计思路。

EEGConformer 是面向 EEG 时序信号分类的深度学习模型, 其网络结构由时域卷积前端(Temporal Convolutional Frontend)与 Transformer 编码器两部分构成[8]。具体而言, 输入为 32 通道 $\times$ 500 采样点的原始 EEG 时序信号(对应 500 Hz 采样率、1 s 时长)。时域卷积前端首先通过一维卷积操作将各通道时序信号映射为 40 维特征嵌入向量(Embedding Size = 40), 同时压缩时间维度, 降低后续 Transformer 的计算开销; 随后叠加可学习的位置编码(Positional Encoding), 以保留样本内的时间先后信息。

经卷积前端处理后的特征序列输入 6 层 Transformer 编码器(depth = 6)。每层编码器由多头自注意力(Multi-Head Self-Attention)与前馈网络(Feed-Forward Network)组成: 其中多头自注意力采用 10 个注意力头(num_heads = 10), 通过并行计算多组查询-键-值映射, 捕获跨通道与跨时间的长期依赖关系; 前馈网络扩展倍数为 4(forward_expansion = 4), 隐层维度为 160, 增强非线性表达能力。为防止过拟合, 注意力层与前馈层均设置 dropout = 0.5(drop_p = 0.5, forward_drop_p = 0.5), 并辅以残差连接与层归一化(Layer Normalization)稳定训练。最终, 经全局平均池化(Global Average Pooling)将时序特征压缩为固定维度向量, 再通过全连接层映射为类别概率。

本文基于上述模型, 分别构建两类分类任务: 二分类任务将医师标注的 5 级疲劳状态映射为“清醒”(0)与“疲劳”(1), 原标签 0 映射为清醒类, 原标签 1~4 统一合并为疲劳类; 三分类任务映射为“清醒”(0)、“轻度疲劳”(1)与“中重度疲劳”(2), 原标签 0 映射为清醒, 原标签 1 映射为轻度疲劳, 原标签 2~4 合并为中重度疲劳。两类任务共享相同的 EEGConformer 主干网络, 仅在输出层维度与损失计算方式上根据类别数进行适配。

2. 实验设计

2.1. 数据集构建

本次实验采用公开的多模态驾驶疲劳表型数据集 MPD-DF (Multimodal Phenotyping Dataset of Driving Fatigue) [9]作为基础数据源。该数据集由复旦大学人类表型组研究院采集并发布, 包含 50 名健康被试(35 名女性, 15 名男性, 年龄 23~59 岁)在标准化 2 小时模拟驾驶任务中的多模态生理数据, 其中 32 通道脑电(EEG)信号按照国际 10-10 电极排布系统安放, 以 500 Hz 采样率连续采集, 并附有专业睡眠医师基于 EEG 信号逐秒标注的 5 级疲劳标签: Wakefulness(清醒)、Fatigue1(轻度疲劳)、Fatigue2(困倦)、Fatigue3(N1 期睡眠)、Fatigue4(N2 期睡眠)。

由于原始数据中存在信号异常与严重运动伪影等噪声干扰, 且 5 级标签在有限样本下存在类别极度不平衡问题, 本文对原始数据集进行了系统性的数据清洗与任务重构。首先, 原始标注中包含标签 8 (Signal Abnormality, 信号异常)和标签 9 (Severe Artifacts, 严重伪影), 对应电极位移、大幅体动等导致的不可判读片段, 本文剔除所有含异常标签的数据段, 确保输入模型的信号质量可靠。其次, 为兼顾疲劳检

测的临床意义与模型训练的可行性, 将医师标注的 5 级疲劳状态映射为 3 级: 0 级(清醒, Wakefulness, 对应原标签 0)、1 级(轻度疲劳, Light Fatigue, 对应原标签 1)、2 级(中重度疲劳, Moderate-Severe Fatigue, 由原标签 2、3、4 合并), 并在此基础上构建两类对比任务: 二分类任务将清醒(0)与疲劳(1 级与 2 级合并为 1)进行区分, 三分类任务则保持清醒(0)、轻度疲劳(1)与中重度疲劳(2)的独立类别。随后, 以 1 秒为时间窗对清洗后的 EEG 信号进行切片, 每段样本包含 32 通道 $\times$ 500 采样点(500 Hz 采样率, 时长 1 s)。

为保证模型训练的稳定性与类别均衡性, 设定以下筛选准则: 有效 trial 数需在 5000~10,000 之间, 清醒状态占比需在 5%~95%之间以剔除全程清醒或全程疲劳的极端被试, 三分类任务额外要求中重度疲劳(2 级)样本占比不低于 5%且必须存在该类别; 经筛选, 二分类任务最终纳入 33 名有效被试, 三分类任务纳入 14 名有效被试。在数据划分方面, 本文将所有有效被试的 EEG 数据按被试顺序拼接为统一数据集, 并对每个被试单独进行被试内 Z-score 归一化以消除个体间基线差异; 进而采用样本级分层划分策略, 其中训练集、验证集与测试集分别约占 64%、16%、20%。该划分通过分层抽样保证各集合类别比例与总体分布一致, 以评估模型在该数据子集上的识别性能。

2.2. 实验环境与配置

实验硬件配置为: CPU AMD Ryzen 7 9700X (8 核 16 线程), GPU NVIDIA GeForce RTX 5080 (16 GB 显存), 内存 48 GB, 存储 512 GB NVMe SSD。软件环境方面, 操作系统为 Ubuntu 24.04.4 LTS (WSL2), 深度学习框架为 PyTorch 2.11.0 (CUDA 13.0, cuDNN 91900), Python 版本 3.11.15, 辅助库包括 NumPy 2.4.3、SciPy 1.17.1、scikit-learn 1.8.0、MNE-Python 1.12.1、Matplotlib 3.10.9、Pandas 2.3.3 等。

本文核心模型采用面向 EEG 时序信号分类的 EEGConformer 网络。该模型由卷积前端与 Transformer 编码器两部分构成: 卷积前端通过深度可分离卷积将原始 32 通道 EEG 时序信号映射为深层时频表示; Transformer 编码器采用多头自注意力机制捕获跨通道与跨时间的长期依赖关系, 经多层编码后通过全局平均池化与全连接层输出疲劳类别概率。二分类与三分类任务共享相同的 EEGConformer 主干网络结构, 仅输出层维度根据任务类别数进行适配。为保证实验公平性与可比性, 二分类与三分类任务均在完全相同的硬件环境、相同的数据预处理流程、相同的 EEGConformer 网络结构(除输出头外)及相同的优化策略下开展训练, 且均采用样本级分层划分。两类任务核心训练参数配置如表 1 所示。

Table 1. Model parameter configuration

表 1. 模型参数配置

配置参数	二分类任务	三分类任务
训练轮次	最多 300 轮	最多 300 轮
优化器	Adam	Adam
初始学习率	2e-04	2e-04
训练策略	验证损失平台衰减	验证损失平台衰减
Batch Size	64	64
损失函数	CrossEntropyLoss	CrossEntropyLoss

2.3. 评价指标

采用模式识别领域常用评价指标对模型性能进行全面评估, 包括准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 分数(F1-Score)以及混淆矩阵(Confusion Matrix)。其中 F1 分数为精确率与召回率的调和平均数。针对三分类任务, 各类别的精确率、召回率与 F1 分数先按类别单独计算, 再取宏平均(Macro-Average)作为综合评估指标, 以避免类别不平衡对总体指标的掩盖。

3. 实验结果与分析

3.1. 总体性能对比

为系统评估不同分类策略在驾驶疲劳 EEG 检测中的适用性，本文在完全相同的 EEGConformer 网络结构、相同数据预处理流程及相同训练配置下，分别开展二分类与三分类任务，实验结果如表 2 所示。

Table 2. Overall performance comparison between binary and ternary

表 2. 二分类与三分类总体性能对比

评价指标	二分类任务	三分类任务	性能差异
准确率	90.54%	92.41%	+1.87%
精确率	79.65%	89.82%	+10.17%
召回率	91.43%	93.62%	+2.19%
F1 分数	85.13%	91.55%	+6.42%

结果表明，三分类任务在各项核心指标上均优于二分类任务。三分类准确率达 92.41%，较二分类提升 1.87%；精确率提升尤为显著，提升 10.17%，说明三分类策略有效降低了将清醒状态误判为疲劳的误报率；召回率与 F1 分数分别提升 2.19%和 6.42%，表明模型在保持高检出的同时，综合判别性能更为均衡。

二分类任务将医师标注的轻度疲劳(Fatigue1)与中重度疲劳(Fatigue2~4)统一合并为“疲劳”类，导致该类别内部 EEG 特征异质性较大，清醒与疲劳的决策边界模糊，模型易将部分清醒样本误判为疲劳，故精确率相对较低(79.65%)。三分类任务保留了医师对疲劳程度的层级划分，使模型能够分别学习清醒、轻度疲劳与中重度疲劳的渐进式特征差异，从而在降低误报的同时维持了对疲劳状态的高灵敏度检出。

综上，在基于 MPD-DF 数据集与 EEGConformer 模型的实验条件下，三分类策略的检测精度与综合性能优于二分类，能够为驾驶疲劳的分级预警提供更为可靠的识别依据。

3.2. 各类别分类性能对比

为深入分析不同分类策略对各类别疲劳状态的识别差异，本文分别统计了二分类与三分类任务中各类别的精确率、召回率与 F1 分数，结果如表 3、表 4 所示。

Table 3. Performance metrics for each class in the binary classification task

表 3. 二分类任务各类别性能指标

类别	精确率	召回率	F1 分数
清醒(Wakefulness)	96.16%	90.33%	93.15%
疲劳(Fatigue)	79.92%	91.43%	85.29%

Table 4. Performance metrics for each class in the ternary classification task

表 4. 三分类任务各类别性能指标

类别	精确率	召回率	F1 分数
清醒(Wakefulness)	96.45%	91.88%	94.56%
轻度疲劳(Light Fatigue)	86.42%	90.18%	88.89%
中重度疲劳(Moderate-Severe)	86.10%	97.88%	91.21%
Macro 平均	89.82%	93.62%	91.55%

结合表 3 与表 4，两类任务的类别级性能差异可归纳为以下三点：

(1) 针对“清醒”类别：二分类与三分类的精确率均保持在 96% 以上，召回率分别为 90.33% 和 91.88%，差异较小(见表 3、表 4)。说明 EEGConformer 模型对清醒状态的 EEG 特征(以高频 β 节律为主)学习充分，分类策略的改变对该类别的识别稳定性影响有限。

(2) 针对“疲劳”相关类别：二分类任务将轻度与中重度疲劳合并为单一“疲劳”类，该类别的精确率仅为 79.92% (表 3)，存在较明显的将清醒样本误判为疲劳的情况；三分类任务将疲劳拆分为“轻度”与“中重度”两个独立类别后，轻度疲劳的精确率提升至 86.42%，中重度疲劳的召回率高达 97.88% (表 4)。这表明拆分疲劳等级后，模型能够更精准地刻画不同疲劳程度的 EEG 特征差异，有效降低了低警觉状态与清醒状态之间的误判。

(3) 针对相邻疲劳等级的边界模糊性：三分类任务中，“轻度疲劳”的精确率(86.42%)在三类中最低(表 4)，说明清醒与轻度疲劳的 EEG 特征边界最为模糊，存在一定量的相互误判；而“中重度疲劳”的召回率(97.88%)显著高于其他类别，表明该阶段的 EEG 特征(以 θ 波增强、 α 波扩散为标志)与清醒状态区分度大，模型对其检出灵敏度极高，具有突出的临床预警价值。

综上，三分类策略不仅提升了总体检测精度，更关键的是实现了对疲劳渐进过程的分级刻画：清醒状态识别稳定，轻度疲劳边界有待进一步细化，中重度疲劳检出灵敏，可为差异化预警策略(如轻度疲劳提示休息、中重度疲劳强制停车)提供可靠的分类依据。

3.3. 训练过程分析

为直观展示两类任务的模型收敛行为，本文绘制了二分类与三分类任务的训练/验证损失曲线及验证指标曲线，分别如图 1、图 2、图 3、图 4 所示。

由图 1、图 2 可知，二分类任务在前 50 轮内收敛迅速，训练损失由初始 0.48 降至 0.25，验证损失同步下降；50~150 轮期间损失曲线平稳下降，验证准确率由 0.80 提升至 0.89，Macro F1 由 0.78 提升至 0.88；150 轮后模型趋于饱和，训练损失稳定在 0.20~0.22 区间，验证指标在 0.89~0.90 小幅波动。训练损失与验证损失始终保持合理差距，未出现明显分离，表明模型在有限样本条件下具有良好的稳定性与泛化能力。




Figure 1. Training and validation loss curves for the binary classification task

图 1. 二分类任务训练与验证损失曲线




Figure 2. Validation accuracy and Macro F1 curves for the binary classification task
图 2. 二分类任务验证准确率与 Macro F1 曲线




Figure 3. Training and validation loss curves for the ternary classification task
图 3. 三分类任务训练与验证损失曲线




Figure 4. Validation accuracy and Macro F1 curves for the ternary classification task
图 4. 三分类任务验证准确率与 Macro F1 曲线

由图 3、图 4 可知，三分类任务因类别数增加、决策边界更为复杂，收敛速度略慢于二分类。前 50 轮训练损失由 0.70 快速降至 0.35，验证损失同步下降；50~200 轮期间损失持续平稳下降，验证准确率由 0.78 提升至 0.90，Macro F1 由 0.74 提升至 0.90；200 轮后模型趋于收敛，训练损失稳定在 0.17~0.19 区间，验证指标维持在 0.90~0.91。值得注意的是，三分类任务的最终验证 F1 (0.91) 与准确率 (0.91) 均高于二分类，说明尽管三分类的优化难度更大，但 EEGConformer 模型通过 Transformer 的全局依赖建模能力，有效学习了三个疲劳等级的渐进式特征差异，最终实现了更优的泛化性能。

对比两类任务的训练曲线，三分类任务的总训练轮次更长 (300 轮 vs 250 轮)，但两者均未触发早停机制 (patience = 30)，表明模型在预设轮次内持续优化，未出现严重过拟合。三分类任务后期损失的波动幅度略大于二分类，这与三分类中“轻度疲劳”样本边界模糊、类别间特征重叠较大有关，但整体收敛趋势稳定可控。

3.4. 混淆矩阵分析

为深入分析模型在不同疲劳等级上的具体误分模式，本文绘制了二分类与三分类任务的归一化混淆矩阵，如图 5、图 6 所示。




Figure 5. Confusion matrix for the binary classification task
图 5. 二分类任务混淆矩阵




Figure 6. Confusion matrix for the ternary classification task
图 6. 三分类任务混淆矩阵

由图 5 可知,二分类任务中“清醒”样本的正确分类率为 90.17%,误判为“疲劳”的比例为 9.83%;“疲劳”样本的正确分类率为 91.43%,误判为“清醒”的比例为 8.57%。两类误分比例接近,说明二分类的决策边界在清醒与疲劳之间存在双向模糊区域,这与二分类将医师标注的轻度疲劳(Fatigue1)与中重度疲劳(Fatigue2~4)强行合并为单一“疲劳”类有关——该类别内部 EEG 特征异质性较大,导致模型难以建立清晰的判别界面。

由图 6 可知,三分类任务的误分模式呈现明显的层级特征:“清醒”类别的正确分类率为 92.22%,其中误判为“轻度疲劳”的比例为 6.75%,而误判为“中重度疲劳”仅 1.03%,说明清醒状态与轻度疲劳存在一定特征重叠,但与中重度疲劳的区分度极高;“轻度疲劳”类别的正确分类率为 90.88%,误判为“清醒”的比例为 5.24%,误判为“中重度疲劳”为 3.88%,这是三分类中误分最复杂的类别,清醒与轻度疲劳、轻度与中重度疲劳之间均存在双向误判,反映了疲劳渐进过程中相邻等级边界的天然模糊性;“中重度疲劳”类别的正确分类率高达 97.77%,误判为“清醒”仅 0.71%,误判为“轻度疲劳”仅 1.52%,该类别几乎不存在漏检风险,中重度疲劳的 EEG 特征(以 θ 波增强、 α 波扩散为标志)与清醒状态差异显著,模型对其检出灵敏度极高,具有突出的临床预警价值。综上,三分类任务通过保留医师对疲劳程度的层级划分,使模型能够分别学习不同疲劳阶段的 EEG 特征差异,不仅提升了总体检测精度,更关键的是实现了对中重度疲劳的精准锁定(召回率 97.77%),可为差异化预警策略(如轻度疲劳提示休息、中重度疲劳强制干预)提供可靠的分类依据。

3.5. 结果讨论

本次实验在统一条件下对比了二分类与三分类策略。三分类全面优于二分类,原因主要有三方面:其一,二分类将异质性较大的轻度与中重度疲劳强行合并,导致决策边界模糊(疲劳类精确率仅 79.92%),而三分类保留了层级划分,使模型能分别学习各等级的渐进式特征差异;其二,EEGConformer 的 Transformer 编码器通过多头注意力机制,可针对不同疲劳等级($\beta/\alpha/\theta$ 节律)分别建模,三分类任务更充分地利用了该全局解耦能力;其三,三分类对中重度疲劳召回率达 97.88%,说明模型对少数类学习充分,但轻度疲劳精确率(86.42%)在三类中最低,反映清醒与轻度疲劳的边界仍存在模糊性,这与医师相邻等级的主观标注不确定性有关。

此外,针对三分类任务中“轻度疲劳”类别精确率相对较低(86.42%)、混淆矩阵呈现双向误判(误判为清醒 5.24%,误判为中重度疲劳 3.88%)的现象,有必要从神经生理层面理解其成因。轻度疲劳作为清醒向中重度疲劳演化的过渡态,其 EEG 特征表现为 α 波由枕叶向顶叶的初步扩散及额叶 θ 波的早期增强,这种介于两类之间的混合性特征是导致分类边界模糊的根本原因。

值得指出的是,尽管 Transformer 的自注意力机制为可解释性分析提供了可能,但在 EEG 信号解码中,attention weights 的神经生理意义目前尚不明确。与自然语言处理中 attention 反映 token 间语义依赖不同,EEG 通道间的 attention 权重可能同时受到空间耦合、频带能量分布及个体基线差异的多重影响,单纯的可视化热力图难以建立与经典神经生理指标(如频带功率、相干指数)的可靠对应关系,易产生误导性解释。因此,本研究未将 attention map 作为主要分析工具。未来工作将结合频带特异性归因分析(如逐频带 SHAP 值)与神经生理学先验(α/θ 功率比、额-枕相干等),在更具生理可解释性的特征空间中解析模型决策依据,而非直接解读原始 attention 权重。

从部署角度看,三分类与二分类计算开销基本持平,但标注成本更高。此外,本文采用样本级分层划分,跨被试泛化性能有待进一步验证。综上,三分类在 MPD-DF 数据集上具有明确的精度与分级预警优势,但轻度疲劳的精准识别仍是后续需突破的难点。

4. 结论与建议

本文基于公开的多模态驾驶疲劳数据集 MPD-DF, 选用 EEGConformer 网络作为基准模型, 在统一的实验条件下分别开展“清醒 vs. 疲劳”二分类任务与“清醒 vs. 轻度疲劳 vs. 中重度疲劳”三分类任务, 通过样本级分层划分与固定训练配置对比了两类策略的检测性能。实验结果表明, 三分类任务在测试集上的准确率达 92.41%, Macro F1 达 91.55%, 较二分类分别提升 1.87% 和 6.42%; 其中中重度疲劳类别的召回率高达 97.88%, 几乎无漏检风险, 可为重度疲劳的强制干预提供可靠依据。

基于上述结果, 本文给出以下工程建议: (1) 在驾驶疲劳实时监测系统的分类策略选择上, 推荐优先采用三分类框架, 以实现疲劳程度的精细化分级预警; (2) 若受限于标注成本或硬件资源, 可采用二分类作为简化方案, 但需注意其较高的误报率(精确率 79.65%)可能影响用户体验; (3) 针对三分类中“轻度疲劳”类别边界模糊的问题, 建议在数据扩充阶段增加轻度疲劳样本的采集与标注, 或引入代价敏感学习、类别重加权等策略进一步提升该类别的精确率。

此外, 为验证分类策略的普适性并分离模型架构与策略优化各自的贡献, 本文补充开展了 EEGNet v4 基线实验, 严格遵循其原始文献推荐配置($F1 = 8$, $D = 2$, $F2 = 16$, $\text{kernel_length} = 64$, $\text{dropout} = 0.5$)。然而, 在 MPD-DF 数据集 500 Hz 采样率条件下, EEGNet 默认 $\text{kernel_length} = 64$ 的感受野仅 0.128 s, 难以捕捉驾驶疲劳相关的秒级节律动态(如 α 波扩散与 θ 波增强过程), 且学习率偏大、缺乏权重衰减, 导致模型严重过拟合、未能有效收敛(验证 Macro F1 约 0.30, 训练损失 0.40 与验证损失 1.70 严重分离)。该结果从侧面说明, 通用轻量级架构直接迁移至高采样率疲劳检测任务时存在适配性问题, 也印证了本文选用具备全局依赖建模能力的 EEGConformer 的合理性。未来将在优化基线配置(如降采样至 128 Hz、扩大卷积核长度至 250、调整学习率与正则化策略)的基础上, 开展更系统的架构对比研究。

后续研究方向包括: (1) 扩大被试规模, 探索被试独立划分(Leave-One-Subject-Out)下的模型泛化性能, 验证跨个体疲劳检测的稳定性; (2) 结合 EOG、ECG 等多模态生理信号, 构建多模态融合模型, 利用模态互补性缓解单一 EEG 信号的类别边界模糊问题; (3) 开展不同时间窗长度(如 2 s、5 s)的消融实验, 优化实时检测的时间分辨率与模型响应延迟之间的平衡。

参考文献

- [1] Chowdhury, A., Shankaran, R., Kavakli, M. and Haque, M.M. (2018) Sensor Applications and Physiological Features in Drivers' Drowsiness Detection: A Review. *IEEE Sensors Journal*, **18**, 3055-3067. <https://doi.org/10.1109/jsen.2018.2807245>
- [2] 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[J]. 华中科技大学学报(自然科学版), 2022, 50(11): 54-65.
- [3] 刘萱, 陈华竣. 基于脑电波监测的疲劳驾驶预防系统设计[J]. 现代信息科技, 2025, 9(15): 194-198.
- [4] 陈小强, 张慧, 黄志鹏. 基于深度学习的视觉-生理多模态疲劳驾驶检测系统设计[J]. 无线互联科技, 2024, 21(20): 90-93.
- [5] 刘帅, 刘德权, 黎冠, 等. 基于脑电信号的疲劳驾驶检测算法[J]. 华北科技学院学报, 2026, 23(3): 50-59.
- [6] 谭璵元, 王越琴, 刘小明, 等. EEG 在交通安全领域中的应用研究综述[J]. 自动化博览, 2021, 38(12): 28-33.
- [7] Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P. and Lance, B.J. (2018) EEGNet: A Compact Convolutional Neural Network for EEG-Based Brain-Computer Interfaces. *Journal of Neural Engineering*, **15**, Article 056013. <https://doi.org/10.1088/1741-2552/aace8c>
- [8] Song, Y., Zheng, Q., Liu, B. and Gao, X. (2023) EEG Conformer: Convolutional Transformer for EEG Decoding and Visualization. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **31**, 710-719. <https://doi.org/10.1109/tnsre.2022.3230250>
- [9] Li, J., Fu, C., Tang, J., Zhou, L., Chen, H., Zhou, W., et al. (2026) Multimodal Phenotyping Dataset of Driving Fatigue. *Scientific Data*, **13**, Article No. 289. <https://doi.org/10.1038/s41597-026-06634-4>