

中文引用格式:邵舒羽,李燕萍,韩家琪,等. 自动驾驶接管决策中驾驶员认知状态识别研究[J]. 中国安全科学学报, 2026, 36(3): 255-263.

英文引用格式:SHAO Shuyu, LI Yanping, HAN Jiaqi. Driver cognitive state recognition in autonomous driving takeover decision making[J]. China Safety Science Journal, 2026, 36(3): 255-263.

自动驾驶接管决策中驾驶员认知状态识别研究^{*}

邵舒羽^{1,2}副教授, 李燕萍¹, 韩家琪¹

(1 北京物资学院 智能工程与供应链创新学院, 北京 101149;

2 智能物流系统北京市重点实验室, 北京 101149)

中图分类号: X910

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2026.03.0912

基金项目: 国家自然科学基金重点项目资助(62433002)。

【摘要】 为解决自动驾驶接管决策中人机协作失效问题,并精准识别驾驶员认知状态,模拟夜间高速弯道、手机分心驾驶及强光暴雨复合等3类典型场景,采集并分析驾驶行为与眼动特征的动态交互数据,构建多模态感知与认知协同的动态权重分配(DWA)特征融合框架及DWA随机森林(RF)模型,探究复杂环境下驾驶员认知状态与接管决策行为的动态作用机制。结果表明:分心状态显著延长接管时间;在强光暴雨场景中,分心与环境压力叠加导致扫视幅度锐减;疲劳状态则引发车道偏离距离增加,并伴随瞳孔直径缩小及异常扫视行为。DWA-RF模型的认知状态分类准确率达到93.6%,验证了该模型在自动驾驶接管决策中驾驶员认知状态识别的有效性。

【关键词】 驾驶员; 自动驾驶; 接管决策; 认知状态; 动态权重分配随机森林(DWA-RF)

Driver cognitive state recognition in autonomous driving takeover decision making

SHAO Shuyu^{1,2}, LI Yanping¹, HAN Jiaqi¹

(1 School of Intelligent Engineering and Supply Chain Innovation, Beijing Wuzi University, Beijing 101149, China; 2 Beijing Key Laboratory of Intelligent Logistics System, Beijing 101149, China)

Abstract: In order to address the issue of human-machine collaboration failure in the takeover decision-making of autonomous driving and achieve precise recognition of the driver's cognitive state, this paper simulates three typical scenarios, night high-speed curves, mobile phone distracted driving, and combined scenarios of strong light and heavy rain, collecting and analyzing the dynamic interaction data of driving behavior and eye movement features construct a dynamic weight allocation (DWA) distribution feature fusion framework for multimodal perception and cognition collaboration, constructed DWA-RF model, and explore the dynamic mechanism of the driver's cognitive state and takeover decision-making behavior in complex environments. The results show that the distracted state significantly prolongs the takeover time. In scenes of strong light and heavy rain, the superimposition of distraction and environmental pressure leads to a sharp reduction in the range of scanning. Fatigue causes an increase in lane departure distance, accompanied by a reduction in pupil diameter and abnormal scanning behavior. The cognitive state classification accuracy of DWA-RF constructed in this paper has reached 93.6%, verifying the

effectiveness of this model in identifying the driver's cognitive state for autonomous driving takeover decisions.

Keywords: driver; autonomous driving; takeover decision; multimodal perception; dynamic weight allocation random forest (DWA-RF)

0 引言

随着自动驾驶技术的不断发展,车辆在特定情境下仍需由驾驶员从自动模式切换至手动模式,即驾驶接管^[1]。然而,驾驶员的认知状态(如疲劳、分心等)会严重影响其接管决策能力,进而带来潜在安全风险^[2]。据统计,人为因素在交通事故中占比超过 90%,驾驶员认知状态异常是导致接管事故的核心隐患。因此,精准识别驾驶员在接管决策过程中的警觉性、注意力分配及生理状态,成为决定接管响应速度与操作精度的关键因素^[3]。

目前研究多集中在驾驶认知状态识别、非驾驶任务对驾驶接管的影响、接管预测建模等方面。例如:CHOI 等^[4]通过驾驶模拟试验表明:认知负荷和视觉负荷都会影响驾驶人员在自动驾驶接管请求后的驾驶表现。罗霜等^[5]实车研究发现,城市道路中驾驶员的分心行为会导致速度降低、加速度波动增加等驾驶绩效变化,且有经验驾驶员驾驶绩效受干扰程度显著低于新手驾驶员。张宜静等^[6]发现,手动驾驶相关的驾驶简单反应、视觉追踪和速度知觉等认知能力均会显著影响其接管绩效。YU Zhenhua 等^[7]通过模拟驾驶试验,分析信息辅助模式及水平对条件自动驾驶接管绩效的影响机制,结果表明:视觉听觉模式、危险信息与操作建议信息相结合在接管速度和变道安全性方面表现最佳。LU Guangquan 等^[8]的研究验证了在高度自动化驾驶条件下,驾驶员在执行高度认知的次要任务时,纵向驾驶安全和遵循指令的能力有所提升。高岩等^[9]进一步指出,分心复杂度和接管安全性成反比,其中手机游戏会显著延长反应时间并增加车辆纵向和横向加速度。WANG Ange 等^[10]针对多维认知需求对条件自动驾驶车辆接管性能、生理和眼动追踪测量的影响研究表明:车速和横向加速度以及生理和眼动追踪指标会对认知负荷作出反应。

综上所述,目前研究主要从生理信号分析和行为特征提取 2 个维度探索驾驶员接管状态识别,但是传统方法及单一模态难以捕捉复杂场景下的接管过程动态认知变化,同时,许多模型仍采用静态权重分配策略,无法解决复合场景下多模态特征冲突问

题,从而限制了分类精度与鲁棒性。鉴于此,笔者拟聚焦于自动驾驶接管情境中驾驶员认知状态的精准识别,构建基于多模态感知与认知协同的动态权重分配(Dynamic Weight Allocation, DWA)特征融合框架,融合驾驶行为、眼动特征与环境场景信息,并引入动态权重机制,优化特征融合以提升跨场景泛化能力和分类精度,为自动驾驶系统的人机协同决策提供理论依据与技术支撑。

1 基于自动驾驶接管决策的试验设计

1.1 自动驾驶接管试验被试

考虑到任务涉及长时间驾驶模拟和高强度认知诱导,共招募 26 名男性被试,年龄范围 23~31 岁,均具有 3 年及以上驾驶经验且无心血管疾病史,均视力正常或经矫正至正常。试验前,所有被试均签署了知情同意书,并保证在试验前 24 h 内未服用药物或饮用含酒精饮料,且前一天保证充足睡眠。

1.2 自动驾驶接管试验场景构建

构建 3 种具有代表性的环境刺激试验场景,分别为夜间高速连环弯道场景、手机分心驾驶场景、强光+暴雨复合场景。依据《道路照明设计标准》(CJJ 45—2015)、《公路路线设计规范》(JTG D20—2017)、《公路工程技术标准》(JTG B01—2014)等设置相关参数。其中夜间高速连环弯道场景共设置 8 个连续弯道,相邻弯道间距为 200 m,交替分布左右弯,每个弯道半径在 150~300 m 之间,坡度维持在 3%~5%。手机分心驾驶场景中,试验通过中控显示屏接收文字信息,每条信息长度为 20~30 字,要求在 10 s 内通过虚拟键盘输入简短回复(“是/否”)。强光+暴雨复合场景采用高强度发光二极管光源(色温 6 000 K)模拟正前方刺眼光照,光照强度维持在 5 000 lx。降雨通过系统设定随机波动在 45~55 mm/h 之间,形成动态雨幕效果,并保持能见度约 50 m,增加环境扰动真实性与可重复性。

试验采用 3(环境刺激类型)×3(认知状态)混合设计,如图 1 所示。图中,ACC(Adaptive Cruise Control)为自适应巡航控制系统。试验前随机确定 3 种认知状态(警觉、疲劳、分心)的顺序,并结合拉

丁方设计保证不同被试间的顺序均衡,每位被试完成 3×3 混合试验,实现群体层面的顺序平衡。同时,在2类高负荷任务(疲劳与分心)完成中间设置不少于 15 min 的休息。



图1 自动驾驶接管试验任务

Fig. 1 Autonomous driving takeover test task

认知状态诱导将执行2步回溯任务、持续驾驶90 min后诱发生理性疲劳、正常监控状态分别定义为分心、疲劳以及警觉状态。驾驶行为数据包括绩效数据和眼动数据。其中绩效数据为接管行为(方向盘接管时间、转向角速度)、保持行为(车道偏离距离、ACC跟车距离)、预警响应。眼动数据包括平均注视时长,ms;瞳孔直径,mm;扫视幅度,($^{\circ}$);眨眼频率,次/min。

1.3 DWA-随机森林(RF)模型

DWA-随机森林(DWA Random Forest, DWA-RF)可根据样本场景的动态特征分布,自适应调整子模型权重,解决传统随机森林在多模态特征融合中依赖静态权重造成的鲁棒性不足问题^[11]。

首先,将试验采集的多模态特征 x_i 表示为:

$$x_i = [x_i^{(h)}, x_i^{(e)}, x_i^{(v)}] \in \mathbf{R}^d, y_i \in \{1, 2, 3\} \quad (1)$$

式中: i 为样本编号; $x_i^{(h)}$, $x_i^{(e)}$, $x_i^{(v)}$ 分别为驾驶行为、眼动和环境特征; $\mathbf{R}^d$ 为 d 维实数空间,是多模态特征向量的取值空间; y_i 为真实类别(警觉、疲劳、分心),同时标准化处理各维度特征。

在训练阶段,DWA-RF将不同模态输入分配给3个子模型,每个子模型输出类别概率向量 $\mathbf{q}_k = [q_{k1}, q_{k2}, q_{k3}]$,其分量为模型内部各树投票结果的平均值,公式为:

$$H_k(x_i) = - \sum_{c=1}^3 q_{kc}(x_i) \ln q_{kc}(x_i) \quad (2)$$

式中: k 为子模型个数; $H_k(x_i)$ 为第 k 个子模型对第 i 个样本输出的概率分布对应的信息熵; c 为类别索引; $q_{kc}(x_i)$ 为第 k 个子模型对样本 x_i 属于第 c 类的预测概率。

动态权重由置信度因子、稳定度因子和场景因子3部分构成,包括置信度因子通过信息熵衡量预测不确定性,预测越确定,权重越高,公式为:

$$Q_k^{(t)}(x_i) = 1 - \frac{H_k(x_i)}{\ln 3} \quad (3)$$

式中: t 为置信度因子类型标记, $Q_k^{(t)}(x_i)$ 为 k 对置信度因子类型 t 时,对 i 的模型性能评价因子。

稳定度因子基于模型内各决策树对最可能类别预测的一致性。树间方差越小,稳定度权重越大。

场景因子依据场景条件下的历史错误率 $\varepsilon_{kl|s}$ 构建公式如下所示,且会通过滑动平均实时更新以适应场景变化。

$$\pi_{kl|s} = \frac{\exp(-\gamma \varepsilon_{kl|s})}{\sum_j \exp(-\gamma \varepsilon_{jl|s})}, \gamma > 0 \quad (4)$$

式中: $\pi_{kl|s}$ 为场景 s 条件下第 k 个子模型对应的场景因子; γ 为灵敏度系数; j 为归一化求和过程中的遍历索引; $\varepsilon_{kl|s}$ 为场景 s 条件下第 k 个子模型的历史错误率,而 $\varepsilon_{jl|s}$ 则为遍历到第 j 个子模型在场景 s 下的历史错误率。

3 类因子综合得到的原始得分公式为:

$$S_k(x_i,s) = (Q_k^{(i)}(x_i))^{\alpha} (Q_k^{(m)}(x_i))^{\delta} (\pi_{(kl)s})^{\lambda}$$
 (5)

式中: $S_k(x_i,s)$ 为场景 s 条件下,第 k 个子模型对第 i 个样本 x_i 的综合得分; α 为置信度因子的权重系数; m 为稳定度因子的类型标记, $Q_k^{(m)}(x_i)$ 为此条件下,第 k 个子模型对应的稳定度因子; δ 为稳定度因子的权重系数; λ 为场景因子的权重系数。

经归一化指数函数计算得到最终权重,公式为:

$$w_k(x_i,s) = \frac{\exp(S_k(x_i,s)/\tau)}{\sum_{j=1}^K \exp(S_j(x_i,s)/\tau)}$$
 (6)

式中: $w_k(x_i,s)$ 为 i 和 s 条件下, k 对应的最终权重; K 为子模型总数; τ 为温度系数。

按权重加权融合输出预测阶段子模型,得到分类结果。超参数 $\theta = \{\alpha, \delta, \lambda, \gamma, \tau\}$ 通过交叉验证优化,目标为最小化验证集上的交叉熵损失,公式为:

$$L(\theta) = - \frac{1}{|D_h|} \sum_{(x_i,y_i,s) \in D_h} \ln([q_f(x_i,s)]_{y_i})$$
 (7)

式中: $L(\theta)$ 为验证集上的交叉熵损失函数; θ 为模型超参数集合; $|D_h|$ 为验证集 D_h 样本数量;

$[q_f(x_i,s)]_{y_i}$ 为 $q_f(x_i,s)$ 中对应 y_i 的分量,其中, f 为融合标识,用于区分子模型输出与融合后输出; $q_f(x_i,s)$ 为经加权融合后的最终预测概率向量,区别于子模型输出的中间预测概率标量。

2 自动驾驶行为数据分析

2.1 自动驾驶绩效数据分析

3 种场景下的绩效数据结果见表 1—表 3,由表 1 可知:警觉状态下接管时间最短、转向角速度最高、车道偏离最小。疲劳状态显著延长接管时间、降低转向角速度、并增加车道偏离和跟车距离。分心状态则表现为接管时间最长、转向角速度最低、车道偏离最大且预警响应延迟由警觉的 0.45 s 递增至疲劳的 0.62 s 与分心的 0.71 s。结果表明:疲劳与分心均显著削弱驾驶员接管决策的反应速度与操作精度,导致车辆控制性能下降,其中分心驾驶的负面影响最为显著。警觉状态下的驾驶员具备最佳的情景感知和车辆控制能力,而疲劳主要造成操作迟缓与轨迹偏移,分心则因认知资源分散进一步破坏动态操控与应急处理能力^[12]。

表 1 夜间高速连环弯道场景绩效数据

Table 1 Performance data of night high-speed continuous curve scene

认知状态	接管时间/s	转向角速度/((°)·s ⁻¹)	车道偏离/m	ACC 跟车距离/m	预警响应延迟/s
警觉	1.12 ± 0.25	28.4 ± 4.2	0.18 ± 0.05	1.82 ± 0.35	0.45 ± 0.12
疲劳	1.58 ± 0.31*	22.1 ± 3.8*	0.32 ± 0.12*	2.45 ± 0.41*	0.62 ± 0.18*
分心	1.82 ± 0.37*	19.7 ± 4.5*	0.42 ± 0.15*	2.89 ± 0.53*	0.71 ± 0.21*

注: p 为显著性,*表示有显著差异,即 $p < 0.05$,表 2—表 6 同。

由表 2 可知:警觉状态下表现最佳,接管时间最短、转向角速度最高、车道偏离最小。疲劳状态下,接管时间延长,转向角速度下降,车道偏离增加。分心状态影响最为显著,接管时间显著增加,转向角速度下降,车道偏离扩大,同时 ACC 跟车距离和预警

响应延迟均显著增加。结果表明:疲劳和分心均会降低驾驶员的控制能力,但分心驾驶造成的性能退化更为严重,分心不仅显著延长接管反应时间,还显著削弱转向控制并加剧车道偏离,对动态操控能力和紧急避险时机具有更强的破坏性^[13]。

表 2 手机分心驾驶场景绩效数据

Table 2 Performance data of mobile phone distracted driving scenarios

认知状态	接管时间/s	转向角速度/((°)·s ⁻¹)	车道偏离/m	ACC 跟车距离/m	预警响应延迟/s
警觉	0.95 ± 0.28	32.1 ± 5.1	0.15 ± 0.04	1.67 ± 0.32	0.38 ± 0.10
疲劳	1.32 ± 0.34*	26.8 ± 4.9*	0.38 ± 0.14*	2.21 ± 0.47*	0.55 ± 0.16*
分心	1.67 ± 0.42*	18.4 ± 4.1*	0.45 ± 0.18*	2.95 ± 0.58*	0.82 ± 0.24*

由表 3 可知:警觉状态下驾驶员的接管时间、转向角速度、车道偏离等绩效数据仍能维持基本驾驶能力,但转向响应速度与晴朗条件下相比,降低了大约 19%。在疲劳状态下,接管时间延长,转向角速度下降,车道偏离增加,ACC 跟车距离亦显著增

加。分心状态影响最为严重,接管时间进一步延长,转向角速度下降,车道偏离扩大,预警响应延迟。结果表明:虽然警觉状态在恶劣环境下仍保持基本驾驶控制,但疲劳和分心会显著放大环境负荷的不利影响。尤其在分心状态下,感官超载与认知分散的

协同作用导致接管能力显著下降,表现为反应迟缓和控制失稳,构成倍增的安全风险^[14]。

表3 强光+暴雨复合场景绩效数据

Table 3 Performance data of combined scene of strong light and heavy rain					
认知状态	接管时间/s	转向角速度/((°)·s ⁻¹)	车道偏离/m	ACC 跟车距离/m	预警响应延迟/s
警觉	1.05 ± 0.22	25.7 ± 4.7	0.12 ± 0.03	1.52 ± 0.28	0.48 ± 0.15
疲劳	1.45 ± 0.35 [*]	21.3 ± 4.3 [*]	0.28 ± 0.11 [*]	2.15 ± 0.39 [*]	0.68 ± 0.20 [*]
分心	1.72 ± 0.40 [*]	17.9 ± 4.0 [*]	0.35 ± 0.16 [*]	2.78 ± 0.45 [*]	0.95 ± 0.27 [*]

2.2 自动驾驶眼动数据

3种场景下的眼动数据结果见表4—表6。

由表4可知:在警觉状态时,注视时长较短,瞳孔直径较大,扫视幅度适中,眨眼频率最低,体现出较高的视觉整合与注意水平;处于疲劳状态时,注视时长会延长,瞳孔缩小,扫视幅度扩大,眨眼频率增加,这反映出注意力衰退以及代偿性视觉搜索。若处于分心状态,则注视会缩短,扫视受限,瞳孔进一步收缩,眨眼频率明显上升,表现出更严重的视觉加工受损。总体来讲,疲劳驾驶会造成稳定的性能下降,而分心驾驶会引发更剧烈的眼动异常,特别是在高危场景下与驾驶风险高度相关。

表4 夜间高速连环弯道场景眼动数据
Table 4 Eye movement data for night high-speed continuous curve scenes

认知状态	平均注视时长/ms	瞳孔直径/mm	扫视幅度/(°)	眨眼频率/(次·min ⁻¹)
警觉	250 ± 30	4.2 ± 0.5	3.2 ± 0.8	8 ± 2
疲劳	320 ± 40 [*]	3.8 ± 0.6 [*]	4.5 ± 1.2 [*]	15 ± 3 [*]
分心	180 ± 25 [*]	3.5 ± 0.4 [*]	2.1 ± 0.6 [*]	25 ± 4 [*]

由表5可知:不同认知状态下,眼动特征存在明显差异。在警觉状态时,呈现出较为稳定的视觉注意分配情况,瞳孔直径较夜间高速大幅提高。疲劳状态下,注视时长变长,瞳孔缩小,扫视幅度增大,眨眼频率上升,反映出注意力下降以及代偿性视觉搜索情况。分心状态下,注视时长显著缩短,瞳孔收缩,扫视幅度骤降,眨眼频率显著上升,体现出认知资源被高度占用。跨场景比较发现,在分心状态下,手机任务会进一步加剧瞳孔收缩和扫视异常,揭示了双重负荷的叠加效应。因此,眼动指标能够敏锐反映手机分心驾驶下的认知状态变化,并揭示其高风险特征^[15]。

由表6可知:疲劳状态下,注视时长延长,瞳孔缩小,扫视幅度扩大,眨眼频率上升。分心状态下,注视显著缩短、瞳孔骤缩、扫视幅度骤降、眨眼频率飙升。跨场景对比发现,极端环境会显著放大分心驾驶的不良效应,瞳孔收缩和扫视衰减都被加剧。

眨眼频率变化和应激反应相关,这提示在此条件下可能会触发态势感知失效风险。

表5 手机分心驾驶场景眼动数据
Table 5 Eye movement data of mobile phone distracted driving scenarios

认知状态	平均注视时长/ms	瞳孔直径/mm	扫视幅度/(°)	眨眼频率/(次·min ⁻¹)
警觉	220 ± 28	4.5 ± 0.6	4.8 ± 1.0	10 ± 3
疲劳	280 ± 35 [*]	4.1 ± 0.7 [*]	6.2 ± 1.5 [*]	18 ± 4 [*]
分心	150 ± 20 [*]	3.2 ± 0.5 [*]	1.8 ± 0.4 [*]	35 ± 5 [*]

表6 强光+暴雨复合场景眼动数据
Table 6 Eye movement data of a combined scene of strong light and heavy rain

认知状态	平均注视时长/ms	瞳孔直径/mm	扫视幅度/(°)	眨眼频率/(次·min ⁻¹)
警觉	200 ± 25	4.8 ± 0.7	5.5 ± 1.2	12 ± 3
疲劳	260 ± 32 [*]	4.4 ± 0.8 [*]	7.1 ± 1.8 [*]	22 ± 4 [*]
分心	130 ± 18 [*]	2.9 ± 0.4 [*]	1.2 ± 0.3 [*]	45 ± 6 [*]

不同场景下眼动数据显著性对比如图2所示。由图2可知:手机分心场景下,环境压力源对视觉固着存在差异化调控,疲劳态注视时长相比警觉态延长,在强光暴雨场景,分心态注视时长下降。瞳孔直径方面,强光暴雨场景整体收缩,其中警觉态较夜间高速下降,手机分心态异常下降,表明前额叶—自主神经调节失衡。扫视幅度表现出压力敏感性,在强光暴雨疲劳态时激增,分心态大幅抑制。眨眼频率在强光暴雨分心态较警觉态提升明显,表明多重压力源会加剧自主神经失衡,提升风险水平。

3 认知状态识别模型构建与验证

3.1 被试数据集分割

先按照状态类别对数据展开分层抽样,每一类样本按照7:3的比例划分成训练集和测试集。考虑到驾驶行为数据存在时序依赖性,进一步运用滑动窗口机制(窗口长度5 min,步长1 min,重叠率80%)来切割连续驾驶片段,消除训练集和测试集之间时序相关性。




图2 不同场景下眼动数据

Fig. 2 Eye movement data in different scenarios

3.2 驾驶行为及眼动特征选择

采用统计检验、信息论指标、降维方法及模型可解释性分析进行特征筛选与验证,结果见表7、图3,图中方差分析(Analysis of Variance, ANOVA)区分度用于量化ANOVA对不同组别的区分能力;被试工作特征曲线(Receiver Operating Characteristic Curve, ROC)是二分类模型的核心性能评估工具;真阳性率(True Positive Rate, TPR)表示实际处于目标驾驶状态的样本中,被模型正确识别为该状态的概率;假阳性率(False Positive Rate, FPR)为实际处于“非目标状态”的样本,被模型误判为“目标状

态”的概率;图3c中的虚线是随机分类模型的ROC基准线。

由表7及图3可知:驾驶行为特征在3类认知状态间存在显著差异,即接管决策时间($F(2,147)=32.45, p<0.001$)、车道偏离($F=28.91, p<0.001$)、转向角速度($F=25.67, p<0.001$)及ACC跟车距离($F=23.54, p<0.001$)均表现出较强的组间区分度(F 为单因素ANOVA的 F 统计量,用于检验多组样本在连续变量上的均值差异)。信息增益(Information Gain, IG)结果表明:在眼动特征中,预警响应延迟($IG=0.86$)与眨眼频率($IG=0.81$)信息量最高,显著优于其他指标($p<0.01$)。这一结果与相关性分析相互印证:接管时间与认知状态的Pearson相关系数最高($r=0.78, p<0.001$),其次为车道偏离($r=0.72$)与预警延迟($r=0.68$)(r 为Pearson积矩相关系数,用于衡量2个连续变量的线性相关程度与方向)。

在降维层面,主成分分析(Principal Component Analysis, PCA)前2主成分累计解释约65%的方差,表明核心特征存在共变结构。同时,单特征预警延迟的ROC曲线下面积(Area Under the Curve, $AUC=0.89$)与眨眼频率($AUC=0.85$)具有较强判别力,当其与转向角速度组合后,模型性得到进一步提升($AUC=0.92$), F_1 分数达0.87,体现了多模态特征的互补优势。基于Shapley加法解释(Shapley Additive exPlanations, SHAP)的可解释性结果表明:预警延迟(平均SHAP= 0.27 ± 0.05)与眨眼频率(SHAP= 0.23 ± 0.04)对模型输出贡献最大,进一步验证了其作为关键特征的稳定性。

表7 特征选择结果

Table 7 Results of feature selection

特征名称	统计值	p 值	方差贡献率/%	r 值	是否选中
接管时间	$F=32.45$	<0.001	—	0.78	是
转向角速度	$F=25.67$	<0.001	—	0.65	是
车道偏离	$F=28.91$	<0.001	—	0.72	是
ACC跟车距离	$F=23.54$	<0.001	—	0.68	是
预警响应延迟	—	—	27	—	是
平均注视时长	—	—	18	—	是
瞳孔直径	—	—	15	—	否
扫视幅度	—	—	12	—	否
眨眼频率	$IG=0.86$	—	23	—	是

3.3 DWA-RF模型有效性验证

通过系统整合预警响应延迟、眨眼频率和转向

角速度3模态特征,构建了驾驶行为风险预测框架。为进一步验证所选特征与模型的稳健性,文中从特




图 3 特征选择和模型验证结果

Fig. 3 Results of feature selection and model validation

征相关性、数量敏感性、概率校准性以及决策曲线分析 4 个方面验证,结果如图 4 所示,其中,图 4c 中的虚线表示为理想校准基准线。

由图 4 可知:最大相关最小冗余 (Maximum Relevance Minimum Redundancy, mRMR) 散点图呈现出接管时间与预警延迟同时处于高相关、低冗余区,凸显了关键特征的优势。消融试验曲线表明 F_1 分数随特征数增加逐渐提升,在引入 3~5 个关键特征时性能增益最显著,并在 5 个特征时达到最佳表现。校准曲线显示预测概率与实际观测频率接近对角线,表明模型预测具有良好概率解释性。决策曲线分析表明在阈值范围 0.2~0.6 内,模型净获益高于“全部干预”和“无干预”策略,进一步验证了其在自动驾驶接管决策风险评估中的应用潜力。

为验证算法及模型有效性,采用 DWA-RF、梯度提升决策树、长短期记忆网络和支持向量机径向基函数 4 种机器学习算法对比分析,结果见表 8。

由表 8 可知:预警响应延迟、眨眼频率和转向角速度 3 模态特征组合中,DWA-RF 模型准确率达 93.6%,相比于次优模型梯度提升决策树提升 7.4%

表 8 模型性能对比

Table 8 Model performance comparison

模型	准确率/%	F_1	AUC
DWA-RF	93.6	0.91	0.96
梯度提升决策树	86.2	0.83	0.89
长短期记忆网络	81.5	0.78	0.85
支持向量机径向基函数	76.8	0.72	0.79

($p < 0.001$),且 F_1 分数(0.91 ± 0.02)与 AUC 值(0.96)均优于其他模型。上述结果表明:DWA-RF 模型基于信息熵加权的多模态特征融合,联合编码非稳态预警响应与眨眼特征及转向角速度的空间动态特性,并通过贝叶斯优化实现子模型权重的动态调整,将多源非稳态与空间动态特征统一编码,显著缓解场景冲突并提升驾驶员认知状态识别精度。

4 结 论

1) 驾驶行为与眼动特征在不同认知状态和环境场景下具有显著的动态交互效应,构建的驾驶员认知状态识别融合框架可以有效捕捉特征的互补性与场景特异性,为解决复杂环境下特征冲突问题提




图 4 模型验证

Fig.4 Model verification

供了可行路径。

2) 认知状态与环境压力存在显著的叠加效应, 分心驾驶在恶劣环境下风险倍增, 结果揭示了单一风险因子评估的局限性, 强调了在安全模型中纳入

环境与认知交互作用的必要性。

3) DWA-RF 模型通过整合驾驶行为、眼动及环境特征, 在跨场景泛化能力上展现优势, 该框架提升了认知状态识别的实时性与鲁棒性。

参 考 文 献

[1] 王长帅, 徐铖铖, 邵永成, 等. 基于生存分析的自动驾驶接管时间分析[J]. 中国安全科学学报, 2023, 33(8): 142-148.
WANG Changshuai, XU Chengcheng, SHAO Yongcheng, et al. Analysis of takeover time of automated driving based on survival analysis[J]. China Safety Science Journal, 2023, 33(8): 142-148.

[2] 郭烈, 胥林立, 秦增科, 等. 自动驾驶接管影响因素分析与研究进展[J]. 交通运输系统工程与信息, 2022, 22(2): 72-90.
GUO Lie, XU Linli, QIN Zengke, et al. Analysis and overview of influencing factors on autonomous driving takeover[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(2): 72-90.

[3] 吴付威, 杨慧, 马勇, 等. L3 级自动驾驶车辆两阶段预警对接管绩效影响研究[J]. 交通运输系统工程与信息, 2025, 25(5): 40-49.
WU Fuwei, YANG Hui, MA Yong, et al. Impact of two-stage warning on takeover performance of L3 autonomous vehicles[J]. Journal of Transportation Systems Engineering and Information Technology, 2025, 25(5): 40-49.

[4] CHOI D, SATO T, ANDO T, et al. Effects of cognitive and visual loads on driving performance after take-over request (TOR) in automated driving[J]. Applied Ergonomics, 2020, 85: DOI: 10.1016/j.apergo.2020.103074.

[5] 罗霜, 易鑫鑫, 邵毅明, 等. 城市道路下分心行为对驾驶员驾驶绩效的影响[J]. 中国安全科学学报, 2024, 34(1): 70-76.
LUO Shuang, YI Xinxin, SHAO Yiming, et al. Influences of distracted behaviors on driving performance of drivers in city[J]. China Safety Science Journal, 2024, 34(1): 70-76.

[6] 张宜静, 张志, 张洁, 等. 手动驾驶与接管情境相关认知能力对接管绩效的影响研究[J]. 载人航天, 2025, 31(4): 457-464.
ZHANG Yijing, ZHANG Zhi, ZHANG Jie, et al. Research on influence of cognitive abilities related to manual driving and takeover scenarios on takeover performance[J]. Manned Spaceflight, 2025, 31(4): 457-464.

[7] YU Zhenhua, ZHAI Linjing, JIANG Kang, et al. Impact of information-assisted modalities and levels on driver takeover performance in conditional automated driving[J]. Accident Analysis & Prevention, 2025, 220: DOI: 10.1016/j.aap.2025.108158.

[8] LU Guangquan, ZHAI Junda, LI Penghui, et al. Measuring drivers' takeover performance in varying levels of automation: considering the influence of cognitive secondary task [J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2021, 82: 96-110.

[9] 高岩, 尤志栋, 罗毅, 等. 基于驾驶模拟的自动驾驶接管行为研究[J]. 中国安全生产科学技术, 2021, 17(2): 140-146.
GAO Yan, YOU Zhidong, LUO Yi, et al. Study on take-over behavior of automated driving based on driving simulation[J]. Journal of Safety Science and Technology, 2021, 17(2): 140-146.

[10] WANG Ange, SHI Wenxin, HE Dengbo, et al. Impact of multi-dimensional cognitive demands on takeover performance, physiological and eye-tracking measures in conditionally automated vehicles[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2025, 114: 461-475.

[11] 宗学军, 王润鹏, 何戡, 等. 优化随机森林模型的工控网络异常检测[J]. 沈阳工业大学学报, 2024, 46(2): 197-205.
ZONG Xuejun, WANG Runpeng, HE Kan, et al. Industrial control network abnormal detection based on optimized random forest model[J]. Journal of Shenyang University of Technology, 2024, 46(2): 197-205.

[12] AZEVEDO-SA H, JAYARAMAN S, ESTERWOOD C, et al. Real-time estimation of drivers' trust in automated driving systems[J]. International Journal of Social Robotics, 2021, 13(8): 1 911-1 927.

[13] CHEN Jiansong, ZHANG Qixiang, CHEN Jinxin, et al. A driving risk assessment framework considering driver's fatigue state and distraction behavior [J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25 (12): 20 120-20 136.

[14] 任立海, 聂珍龙, 于潇, 等. 基于脑电信号的不良驾驶状态识别研究综述[J]. 中国公路学报, 2024, 37(8): 216-230.
REN Lihai, NIE Zhenlong, YU Xiao, et al. Review on recognition of unsatisfactory driving status based on electroencephalogram[J]. China Journal of Highway and Transport, 2025, 37(8): 216-230.

[15] ZHAO Xia, LI Zhao, ZHAO Chen, et al. Distraction-level recognition based on stacking ensemble learning for IVIS secondary tasks[J]. Expert Systems with Applications, 2024, 244: DOI: 10.1016/j.eswa.2023.122849.



作者简介: 邵舒羽 (1989—),男,河南周口人,博士,副教授,主要从事应急物流、人因工程、应急管理等方面的研究。E-mail: shaoshuyu@bwu.edu.cn。