自动驾驶与人工驾驶模式下的注意力动态：驾驶模拟研究

作者

Yuan Cai[1], Mustafa Demir[2], Farzan Sasangohar[2], Mohsen Zare*[1]

1- UTBM，ELLIADD-ERCOS，贝尔福邮政分区，法国*2-* 工业与系统工程系，德克萨斯农工大学，学院站，德克萨斯州，美国

***通讯作者：**姓名：Mohsen Zare 部门：
ELLIADD-ERCOS 大学： *UTBM* 地址：
UTBM，90100，贝尔福，Cedexe 电
子邮箱：Mohsen.zare@utbm.fr

致谢

本研究在欧盟地平线2020研究与创新计划及PAsCAL项目（资助编号815098）的框架内开展。我们感谢Maxime Larique、Nicolas Bert和Florian Girardot协助进行数据收集。

摘要

研究目的：本研究旨在探讨自动驾驶汽车不同驾驶模式下，驾驶员对道路、中央后视镜、嵌入式人机界面（HMI）和速度计等不同区域的注意力变化。

背景： 自动驾驶车辆（AV）融入交通系统后，带来了严峻的安全问题，尤其是在模式转换期间驾驶员重新介入方面。以往的事故凸显了驾驶员过度依赖自动化的风险，也表明有必要了解动态注意力分配，以保障自动驾驶过程中的安全。

方法：开展了一项高保真驾驶模拟。研究采用眼动追踪技术测量不同驾驶模式（自动模式、手动模式和过渡模式）下的注视时长、注视次数和首次注视时间，以评估驾驶员如何将注意力分配到不同的兴趣区域（AOI）。

结果：研究结果表明，驾驶员的注意力在不同驾驶模式下存在显著差异。在手动模式下，注意力始终集中于道路；而在自动模式下，驾驶员对嵌入式人机界面的注视时间较长。在交接和接管阶段，注意力会在环境要素与技术要素之间动态转移。

结论：研究揭示，驾驶员的注意力分配取决于驾驶模式。这些发现有助于设计能够契合驾驶员注意模式的自动驾驶汽车自适应人机界面。通过根据驾驶情境呈现相关信息，此类系统能够改善人车交互，支持有效的模式转换，并提升整体安全性。

应用：对不同驾驶模式下视觉注意动态的系统分析日益受到重视，因为这有助于自适应人机界面设计和驾驶员准备状态干预。广义线性混合模型的研究结果可直接应用于自适应人机界面或驾驶员培训项目的设计，以增强注意力并提高安全性。

关键词：注意力、自动驾驶、眼动、人-自动化交互、人机界面。

引言

近年来，自动化网联汽车的兴起有望带来重大的经济和社会变革。据预测，仅在美国，这些技术每年就能创造高达 1.2 万亿美元的经济效益（Clements & Kockelman, 2017）。这项技术

尽管自动驾驶技术前景可期，但由于偶尔发生致命事故，其应用也引发了担忧。最早的案例之一是2018年Uber自动驾驶汽车事故，这起致命事故发生在美国亚利桑那州，凸显了自动驾驶

驾驶中的注意力

自动驾驶过程中的视觉注意力对于安全应对意外事件至关重要。视觉注意力是指在复杂视觉场景中筛选相关信息并过滤无关细节的认知过程（McMains & Kastner, 2009）。通常通过眼动

Ma 等人（2020年）证明，认知工作负荷与视觉注意力相互竞争，在心理需求较高时，认知过程往往优先于视觉注意力。同样，研究表明，注视行为，尤其是注视次数，会受到驾驶员在接

对驾驶自动化的信任

自动驾驶期间，驾驶员的视觉注意力各不相同，有些人经常将视线从道路上移开，而另一些人则始终保持专注。这种差异可能受到诸如对自动化的信任等因素的影响（Hergeth 等人

较简单的系统相比，使用多种自动化系统辅助时，参与者对道路的注意力较少。要优化驾驶员与自动驾驶系统之间的交互，必须建立经过良好校准的信任。自动驾驶系统减轻驾驶员的驾驶任务

尤其是，视觉注意力与驾驶员对自动化的信任之间的交互值得进一步研究。以往大多数研究都关注参与者执行非驾驶相关任务的情况（Guo 等人，2024；Hecht 等人，2020；Liang 等人

研究问题与假设

本研究旨在探讨两个主要研究问题，以深入揭示自动驾驶情境下视觉注意力、信任与驾驶员行为之间的复杂关系：**(1)** 在包括自动化、交接、手动和接管在内的四种驾驶模式中，随着时间推移，通过眼动追踪测量的注意力是否会在技术因素和环境因素的各个兴趣区（*AOI*）之间发生变化？

假设***1***：据推测，随着时间推移，注意力在不同感兴趣区域之间的分配会因驾驶模式而显著变化。在手动驾驶模式下，由于主动驾驶的认知需求较高，驾驶员会将更多注意力分配给环境因素。在自动驾驶模式下，对技术因素（例如平板电脑、速度计）的注视时长会更加稳定。在交接模式下，随着控制权转交给驾驶员，注意力会转向技术因素和环境因素；而在接管模式下，为了重新掌控车辆，注意力会在这些因素之间快速转移。总体而言，与自动驾驶和交接模式相比，手动驾驶和接管模式预计会呈现更动态的注意力转移。

(2) 驾驶信任水平如何影响四种驾驶模式（自动化、交接、手动和接管）下，驾驶员对环境因素和技术因素的注意力分配?

假设 ***2***：假设随着信任水平的提高，参与者对监控相关兴趣区（例如速度计、中央后视镜）的注意力会降低，尤其是在自动化模式下。同时，较高的信任水平预计会将注意力转向次要任务，例如与平板电脑相关的兴趣区，从而导致这些任务上的注视时长更长、注视次数更多。预计信任与注意力之间呈非线性关系（Tenhundfeld 等人，2022），较高的信任水平会导致注意力出现更明显的转移。

方法

参与者

使用 G*Power3（Faul 等人，2007）进行了先验功效分析，以检验七个仿真事件中两个条件的均值，采用 F 检验，效应量为中等（$\eta^2_p = 0.06$；Cohen，1988），alpha（∝）设为 0.05。分析确定需要 26 名参与者才能达到 0.95 的功效。为应对潜在的缺失数据，我们最初从法国东部大学及其周边社区随机招募了 40 名参与者参加实验。然而，有 6 名参与者未能完成任务，因此最终样本包括 34 名参与者。研究结束时收集的人口统计学特征显示，参与者总体上为较年轻的成年人（M_{age}= 33 和 SD_{age}= 16；男性 = 15 和女性 = 19）。

参与者须符合以下纳入标准：持有有效驾驶执照；过去一年内经常驾驶，累计驾驶距离至少为3,000公里；能流利使用法语；总体健康状况良好；听力和视力正常或矫正后达到正常水平（例如，色盲者不纳入本研究）；无癫痫病史；年龄为18至85岁；并能熟练使用标准电脑鼠标和键盘。参与者在研究期间每小时可获得10欧元报酬，总计约30欧元（€）。

模拟驾驶测试平台

仿真环境由三个主要部分组成：（1）模拟器；（2）用于控制模拟器的个人电脑；（3）用于向用户显示人机界面的平板电脑。模拟器配备全景投影屏幕和一辆经过改装的标致308车辆，其动力系统已被移除（图1a）。车辆配有传感器、力反馈机制和电子元件，可与模拟器个人电脑无缝连接。模拟器为参与者提供沉浸式环境和逼真的驾驶体验。它配备驾驶舱和前方屏幕布局，模拟汽车的内部结构和视野，使参与者能够操作车辆控制装置并与道路环境互动，体验与现实驾驶十分接近（图1b）。仿真软件运行于集群中的一台个人电脑上。另外四台个人电脑专用于计算虚拟视景，并通过三台投影仪将画面投射到面向汽车的大型柱形屏幕上，形成180°前方视野；此外，还有三台显示器面向后视镜，用于呈现后方视野。该模拟器能够模拟L3级自动驾驶，支持手动与自动驾驶模式之间的切换。



图1. (a) 配备真实标致308车辆的全景投影屏幕；**(b)** 驾驶员在仿真过程中与人机界面平板交互。

嵌入式人机界面设计

该模拟器的多通道人机界面采用安卓平板电脑（一台 10 英寸安卓平板电脑）开发，并通过 Arduino Mega 2560 在模拟器、PC 和平板电脑之间建立接口。Arduino 会转发各组件之间的事件

，并根据平板指令控制仪表盘LED灯。平板显示屏的设计参考了对现有汽车人机界面的对标分析，确保符合行业惯例和交通法规。该人机界面刻意采用简洁设计，聚焦关键信息，以尽量减少分心，同时通过仪表盘LED灯、音频/语音消息和触摸屏文字通知，突出显示关键的自动驾驶事件。

人机界面通过视觉、灯光、听觉和语音提示等多种信号，向驾驶员传达自动驾驶活动的相关信息。它还提供了一个控制按钮，用于接管或移交驾驶责任，并告知用户车辆的环境感知情况。为模拟车辆对周围环境的感知反馈，设计的人机界面会显示以下信息：当前道路类型（城市、乡村或高速公路）、当前限速、即将发生的潜在事件（如交通拥堵、障碍物（故障车辆）或道路施工）、网联自动驾驶汽车（CAV）的环境感知能力水平（优秀、中等或较差），以及自动驾驶可用性状态（图2）。

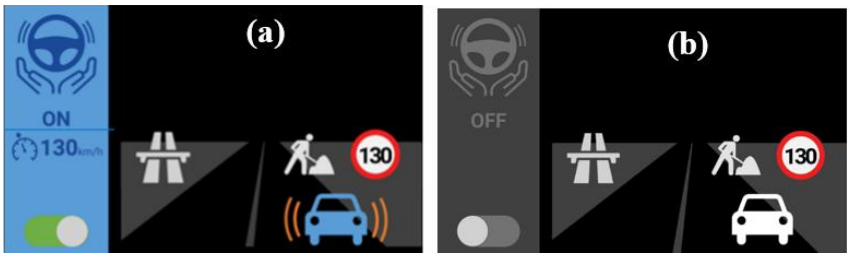

图2。 不同条件下触摸屏平板界面的截图：（**a**）主动自动化期间的反馈显示，标明当前法定限速（130 km/h）、道路类型（高速公路）、即将发生的事件（道路施工）以及中等感知水平；（**b**）自动驾驶禁用时的反馈显示。

仿真场景

该仿真场景评估了用户在不同道路状况和交通状况下与自动驾驶系统的交互（图 3）。场景开始时，受试者启动发动机，并在畅通的乡间道路上手动驾驶。进入郊区后，人机界面提示

可以使用自动驾驶功能，受试者随即将其启用。随后，汽车驶过交通日益繁忙的乡村地区，在遇到道路施工时自动调整速度和行驶轨迹，并驶出施工路段后恢复至法定速度。在多个时点，人机界面会指示受试者接管车辆，受试者通过转向或踩下踏板完成接管。之后，受试者驶入高速公路；随着交通状况变化，包括遇到交通拥堵时汽车自动调整速度，人机界面会重新启用自动驾驶。汽车驶过一系列不同的道路状况，包括另一处道路施工路段和一段交通拥堵后，人机界面会多次提示受试者接管，并根据需要重新启用自动驾驶。场景最后，汽车自动停靠在路边，受试者关闭发动机。

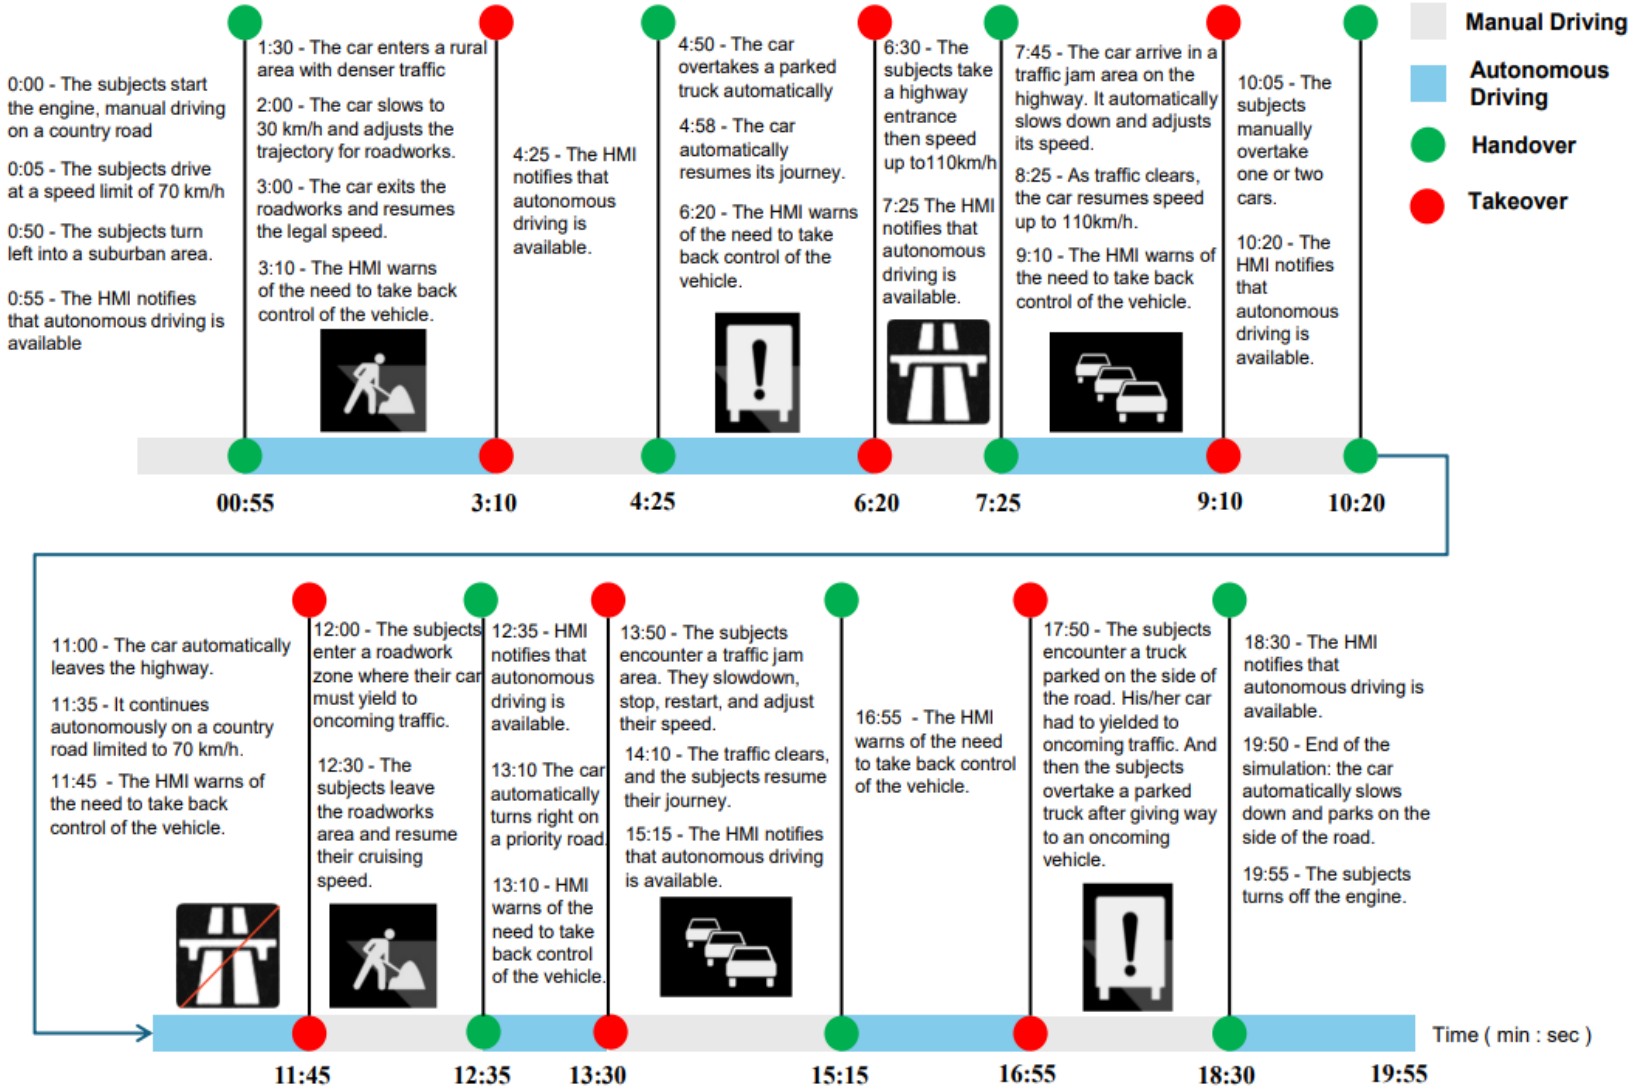

图3. 仿真　　用于评估不同道路状况下自动驾驶交互的场景　　.

实验设计

实验流程

由于COVID-19疫情，参与者必须在线登记，并在前往大学设施期间佩戴口罩。抵达后，参与者接受了有关卫生规程和实验流程的说明。随后，他们填写了人口统计问卷，内容涉及个人信息、驾驶经验以及对自动驾驶车辆的态度。之后，研究人员协助参与者佩戴所需的测量设备，包括皮肤电反应、Novocar心跳测量设备和腕部活动测量设备。

参与者通过将驾驶舱调整至自己偏好的设置，并进行15分钟的驾驶实验环节，熟悉驾驶模拟器；随后休息5分钟，以记录基线生理数据。实验要求参与者驾驶一辆3级自动驾驶车辆穿越各种环境，并根据场景中不同的信号进行数次交接和接管操作。实验结束后，研究人员取下传感器，参与者随后参加半结构化访谈，讨论其体验、对自动驾驶车辆的信任程度以及信号的有效性。

设备与仪器

为评估驾驶期间的注视行为，我们使用 Tobii Pro Glasses 2 眼动追踪系统，记录受试者在多种感兴趣区域内的眼动，这些区域包括人机界面平板、道路和速度计（图4）。该系统由一个外形类似普通眼镜的可穿戴头戴单元，以及一个用于采集驾驶任务期间眼动数据的记录单元组成。我们使用 Tobii Glasses Controller软件对系统进行校准、管理录制、处理参与者数据并定义感兴趣区域。记录频率，即每秒采集的注视点数量，设为 50 Hz。在分析眼动追踪数据时，我们首先将视野划分为十个不同的感兴趣区域，以捕捉详细的注视模式，如图4所示。其中，挡风玻璃区域内有四个感兴趣区域，包括左侧和右侧景观、灯带和道路；平板界面内有四个，另有一个速度计区域和一个中央后视镜区域。然而，为了简化数据结构，并以更

便于应用的宏观层面理解注意力分配，我们决定将挡风玻璃和平板电脑内的感兴趣区域分别合并为两个总体类别：一个涵盖挡风玻璃内的所有区域，另一个涵盖整个平板区域。聚焦于这些较大的功能区域，更符合我们的首要研究目标，即了解驾驶员如何在主要驾驶环境（挡风玻璃）和次要车载系统（平板电脑）之间分配视觉注意力。此外，合并感兴趣区域增加了各类别中的数据量，从而提高了研究结果的统计稳健性。

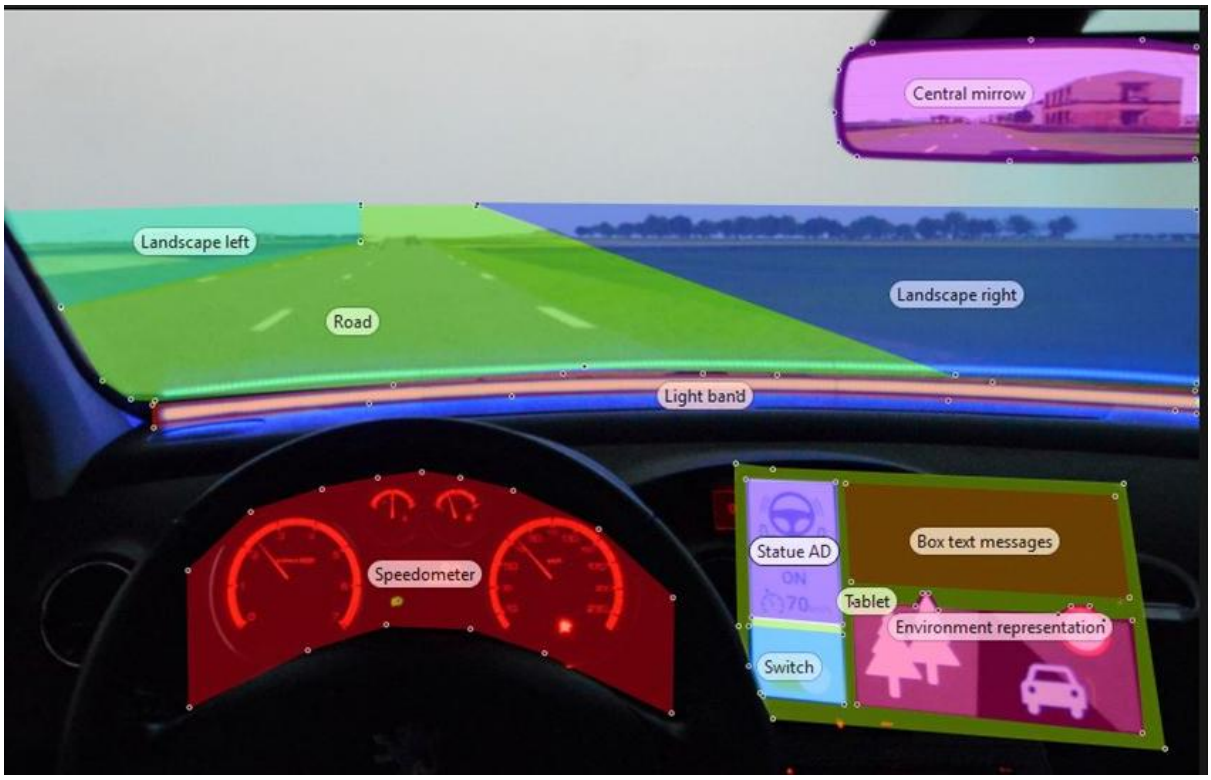

图2。 本研究用于分析注视行为的感兴趣区域。

指标

总体而言，本研究通过以下测量设备收集数据，包括眼动追踪、心率、皮肤电反应和腕部运动。然而，我们的分析主要聚焦于三项具体的眼动追踪指标和自我报告的信任，这些指标是本研究目标关注的重点。

眼动追踪。我们为每位参与者考察了三项指标：总注视时长、注视次数和首次注视时间。注视是指注视点在特定位置相对

稳定的时刻，表明视觉注意力集中于该处（Martinez-Conde 等，2004）。速度计和中央后视镜的测量值直接从眼动追踪软件（Tobii）中获取，而环境和平板电脑的测量值则需要通过额外的数据预处理计算得出，汇总见表1。

表1。基于图4所示区域的感兴趣区域测量指标及其计算方法概述。

测量指标定义	数据预处理	研究解读
注视时长占比： **注视时长：** 所占比例 总时间内， 参与者的注视 持续固定在某个 特定区域内 视觉 环境。	环境：通过汇总注视时间计算 涵盖四个指定的环境区域（右侧和 左侧景观、道路和灯带），并将结果除以 兴趣区总时长。 平板电脑：通过汇总各区域的注视时间计算 四个平板电脑和绿色区域，然后将结果除以 兴趣区总时长 速度计：**计算方式为**将对 速度计的注视时间除以兴趣区总时长 中央后视镜：计算方式为将对 中央后视镜的注视时间除以兴趣区总时长	**视觉注意力分配：** 这些区域代表了关键区域 位于参与者的视野 之内，将它们结合起来可以让我们 to 评估 整体 注意力 分布 在这些关键区域之间 的视觉环境。 So, we can 评估 *how* 参与者如何分配其视觉 不同部分之间的注意力 涉及各因素：环境、平板电脑、 速度计和中央后视镜。
占比 **注视次数：** 总数 单次注视 在特定的 兴趣区内 在视觉 环境中。	环境：通过求和计算总注视次数 四个指定区域的注视，并将其划分 为兴趣时间总注视次数。 平板电脑：通过累加 平板电脑和绿色区域内的注视次数，计算总注视次数，然后 将结果除以兴趣时间总注视次数。 速度计：通过将注视次数除以 速度计注视次数除以兴趣时间总注视次数 中央后视镜：计算方法为将 中央后视镜的注视次数除以兴趣时间总注视次数	**视觉注意分布：** 汇总这些区域的注视次数 后得出 ，我们可以评估 参与者的视线转移有多频繁 至这些区域，从而深入了解 关于他们的视觉注意力如何 分布在四个因素上。
首次时间 **注视：时间** 从.....经过的时间 视觉的开端 刺激或场景 开始，直至 参与者的注视 注视某一特定 AOI.	环境：通过以下方法计算首次注视时间 确定参与者注视任意一个所需的最短时间 四个指定区域中的。 平板电脑：通过确定以下内容计算首次注视时间 参与者必须注视四个平板电脑中任意一个的最短时间 以及绿色区域。	**视觉注意力的优先级：**通过 测量时间 参与者 注视每个区域，我们可以评估 这些区域吸引注意力的速度 注意力，帮助我们理解 其中的即时视觉优先级 四个因素。

驾驶中的自我报告信任。参与者在每个实验环节的驾驶任务结束后填写问卷，其中包含七项关于信任和专业知识的李克特量表自我报告测量项。具体而言，关于信任，研究结束时提出了以下问题：请在 1 到 7 的量表上为您对该系统的信任程度评分。

数据分析与结果

广义线性混合模型（GLMM）

分析之前，使用夏皮罗-威尔克检验评估响应变量的正态性，结果显示注视时长（FD：$W = 0.814$，$p < .001$）、注视次数（FC：$W = 0.869$，$p < .001$）和首次注视时间（TFF：$W = 0.562$，$p < .001$）显著偏离正态分布。鉴于这些连续响应变量呈正偏态，且实验设计具有嵌套结构，因此分别对注视时长（FD）、注视次数（FC）和 TFF 应用分层广义线性混合模型（GLMM）。为处理偏态分布，采用伽马分布和对数链接函数，因为该方法适用于正偏态数据，并能确保预测值严格为正（Nelder & Wedderburn，1972）。

这些广义线性混合模型采用拉普拉斯近似下的最大似然估计进行拟合（Ju 等，2020年）。首先，为解决数据集中零值“0”可能引发的问题，向全部三个响应变量加入了一个小常数，从而生成FD_{shift}、 FC_{shift}和TFF_{shift}的平移版本。这些调整确保其与广义线性混合模型中所使用的伽马分布兼容，因为伽马族要求分析值为严格正值。通过应用该变换，在保留原始数据中有意义变异性的同时，维持了模型所依据的统计假设的完整性。每个模型均使用 bobyqa 优化器（Powell, 2009）进行拟合，最大迭代次数为$1\ X\ 10^5$ ，以确保收敛。分析在 RStudio 中使用 lme4 软件包（Bates 等，2024）的 glmer() 函数完成。

注视时长（***FD***）

为预测注视时长$_{shift}$，模型将固定效应纳入嵌套结构，并明确将时间（线性）建模为模式（m：自动化、交接、手动、接管）内的变量，同时将模式建模为因素（f：平板电脑、环境、速度计、中央后视镜）内的嵌套变量。在模型构建步骤开始时，最初考虑了时间的线性项和高阶多项式项，即二次项和三次项；然而，这些高阶项最终未纳入模型，因为加入它们

并未显著改善模型拟合，也未能进一步解释注视时长$_{shift}$的方差（$p > .05$）。此外，为每位参与者纳入了时间（线性）的随机截距和斜率，以考虑个体在基线注视时长及其随时间变化方面的差异。因此，模型的固定效应和随机效应可用数学形式表示为：

$$\log\left(E[\mathrm{FD}_{\mathrm{Shift},ij} \mid X_{ij}]\right) = \beta_0 + \sum_f \beta_f f + \sum_{m(f)} \beta_{m(f)} m(f) + \sum_{t_1(m(f))} \beta_{t_1(m(f))} t_1(m(f)) + u_{0j} + u_{1j} t_1 \quad (1)$$

在公式 1 中，项 $E[FD_{Shift,ij} \mid X_{ij}]$ 表示在给定预测变量集 (X_{ij}) 的情况下，受试者 j 的观测值 i 的 FD$_{Shift,\ ij}$ 的期望值（均值）。该预测变量集包括每个因素的固定效应预测变量 $(\sum_f \beta_f f)$、嵌套于 f 中的模式 (m) 的固定效应 $(\sum_{m(f)} \beta_{m(f)} m(f))$，以及 t_1 的效应（嵌套于 m 中的线性时间：f：$\sum_{t_1 m\ f}\ \beta_{t_1(m(f))\,()} t_1(m(f))$）。此外，模型还纳入随机效应项 $((u_{0j} + u_{1j} t_1))$，以反映受试者相对于固定效应的个体特异性偏差，其中包括随机截距 (u_{0j})，用于捕捉每位受试者 (j) 基线响应的变异性；以及随机斜率 (u_{1j})，允许 t_1 的效应因受试者而异。假设 u_{0j} 和 u_{1j} 服从均值为零且具有方差-协方差结构 $(N(0, \Sigma))$ 的多元正态分布。结果是在这一层级嵌套框架下进行解读，而非依据交互项，以揭示时间效应如何随因素和模式的嵌套组合而变化（见表2）。

在总结用于预测FD_{shift}的广义线性混合模型（GLMM）结果之前，我们计算了类内相关系数（ICC），以评估分层模型中可归因于不同层级的方差比例，即量化FD_{shift} 的变异有多少是由个体差异（被试水平）驱动的，又有多少是由涉及f、m,和t_1的嵌套结构所造成的差异。分析结果显示，总组内相关系数为0.84，表明总方差的83.8%可由受试者差异与嵌套结构的综合效应解释。被试水平组内相关系数为0.018，说明总方差中仅有1.8%可归因于受试者的个体差异，这些差异由t_1的随机截距和斜率所捕捉。相比之下，嵌套结构组内相关系数为0.82，表明82%的方差

可由与分层设计相关的固定效应解释。也就是说，FD_{shift} 的变异主要由层级结构驱动，而非受试者个体差异。此外，模型不存在奇异性，证实了随机效应设定及方差划分的合理性。

广义线性混合模型（GLMM）中的随机效应设定在受试者层级，包含截距以及时间（线性）的斜率。各自的方差（σ^2）和标准差（SD）分别为：随机截距 $\sigma^2 = 0.05$（标准差 = 0.22）、时间（线性）的随机斜率 $\sigma^2 = 0.003$（标准差 = 0.05）（截距与斜率之间的相关为 0.36），以及残差 $\sigma_\epsilon^2 = 0.47$（标准差 = 0.69）。标准化残差范围为 -1.46 至 10.83，中位数为 -0.13，表明存在轻微正偏，但仍处于模型诊断的可接受范围内。模型拟合指标如下：赤池信息准则 AIC = 14,975.0，贝叶斯信息准则 BIC = 15,183.4，对数似然= -7451.5，偏差 = 14,903.0。这些结果表明，时间嵌套于模式、模式嵌套于因素的嵌套结构（因素 → 模式 → 时间）得到了恰当建模，并在受试者层级考虑了随机变异；标准化残差和拟合指标支持该模型的适用性。

表2中汇总的固定效应结果表明，注视时长$_{shift,}$在嵌套层级内存在显著影响，这说明注视时长$_{shift}$ 受到各因素内驾驶模式的影响。这些嵌套层级内基于时间的效应通常较弱。例如，自动化模式下平板电脑上的注意力变化可忽略不计（$\beta_{Std} = -0.003$，$p = .169$），接管模式下中央后视镜上的注意力变化也可忽略不计（$\beta_{Std} = -0.016$，$p = .271$）。另一方面，手动模式下平板电脑上的注意力（$p < .001$）以及交接期间中央后视镜上的注意力（$p = .002$）均出现显著变化。

如表2所示，基于时间的效应的显著结果（因素 ⟹ 模式 ⟹ 时间（t_1））表明，对于嵌套于手动模式中的平板电脑，时间每增加一个单位，注视时长（FD_{Shift}）的比例就减少0.016个标准化单位（$\beta_{std} = -0.016$，$p < .001$）。这一下降表明，随着时间推移，分配给平板电脑相关区域的视觉注意力逐渐减少（图5）。对于嵌套于手动模式中的速度计，线性时间分量的标准化系数同样为负值，FD_{Shift} 每当时间增加一个单位，就减少0.006个标准化单位

（时间 β_{std} = -0.006，p = .002）。这一减少表明，参与者随着时间推移分配给速度计的视觉注意力减少，这可能是因为他们逐渐适应或熟悉了手动模式，并减少了对速度相关信息的依赖。

表2。 注视时长固定效应的广义线性混合模型结果，展示注视时长这一视觉注意力分配的替代指标如何受到不同模式及因素组合的影响。

因素					因素 ⟹ 模式					因素 ⟹ 模式 ⟹ 时间 (t_1)			
	β (标准误)	β_{Std}	*t*值	*Pr(>|z|)*		*β* (标准误)	β_{Std}	*t*值	*Pr(>|z|)*	*β* (标准误)	β_{Std}	*t*值	*Pr(>|z|)*
平板电脑	-4.71 (0.09)	-0.076	-53.26	< .001	自动化	0.68 (0.09)	0.011	7.52	< .001	-0.19 (0.14)	-0.003	-1.38	0.169
					交接	2.89 (0.09)	0.046	31.47	< .001	0.10 (0.14)	0.002	0.72	0.473
					接管	3.06 (0.09)	0.049	32.54	< .001	0.07 (0.18)	0.001	0.40	0.691
					手动	N/A	N/A	N/A	N/A	-0.98 (0.16)	-0.016	-6.20	< .001
速度计	-1.93 (0.07)	-0.031	-28.76	< .001	自动化	-1.24 (0.07)	-0.020	-17.68	< .001	0.16 (0.14)	0.003	1.15	0.250
					交接	-0.06 (0.09)	-0.001	-0.68	0.497	-0.13 (0.22)	-0.002	-0.60	0.548
					接管	0.25 (0.08)	0.004	3.19	**0.001**	0.13 (0.19)	0.002	0.68	0.495
					手动	N/A	N/A	N/A	N/A	-0.37 (0.12)	-0.006	-3.06	**0.002**
中央后视镜	-4.91 (0.11)	-0.079	-45.83	< .001	自动化	0.80 (0.11)	0.013	6.98	< .001	-0.31 (0.18)	-0.005	-1.76	0.078
					交接	1.83 (0.34)	0.029	5.35	< .001	-0.58 (0.66)	-0.009	-0.88	0.379
					接管	1.38 (0.34)	0.022	4.02	< .001	-1.01 (0.92)	-0.016	-1.10	0.271
					手动	N/A	N/A	N/A	N/A	-0.47 (0.26)	-0.008	-1.80	0.071
环境	N/A	N/A	N/A	N/A	自动化	-0.05 (0.07)	-0.001	-0.69	0.490	-0.14 (0.12)	-0.002	-1.14	0.253
					交接	-0.41 (0.07)	-0.007	-6.24	< .001	-0.11 (0.13)	-0.002	-0.89	0.371
					接管	-0.49 (0.07)	-0.008	-6.92	< .001	0.01 (0.15)	0.000	0.07	0.944
					手动	N/A	N/A	N/A	N/A	0.07 (0.13)	0.001	0.54	0.588

注：*“β”*和*“β (标准误)”*分别表示非标准化回归系数及其标准误，而*“β”*表示标准化回归系数。因素⟹ 模式⟹ 时间的符号框架中指定了模式内时间（线性）和因素内模式。*“N/A”*表示手动模式，“环境”用作参考条件。

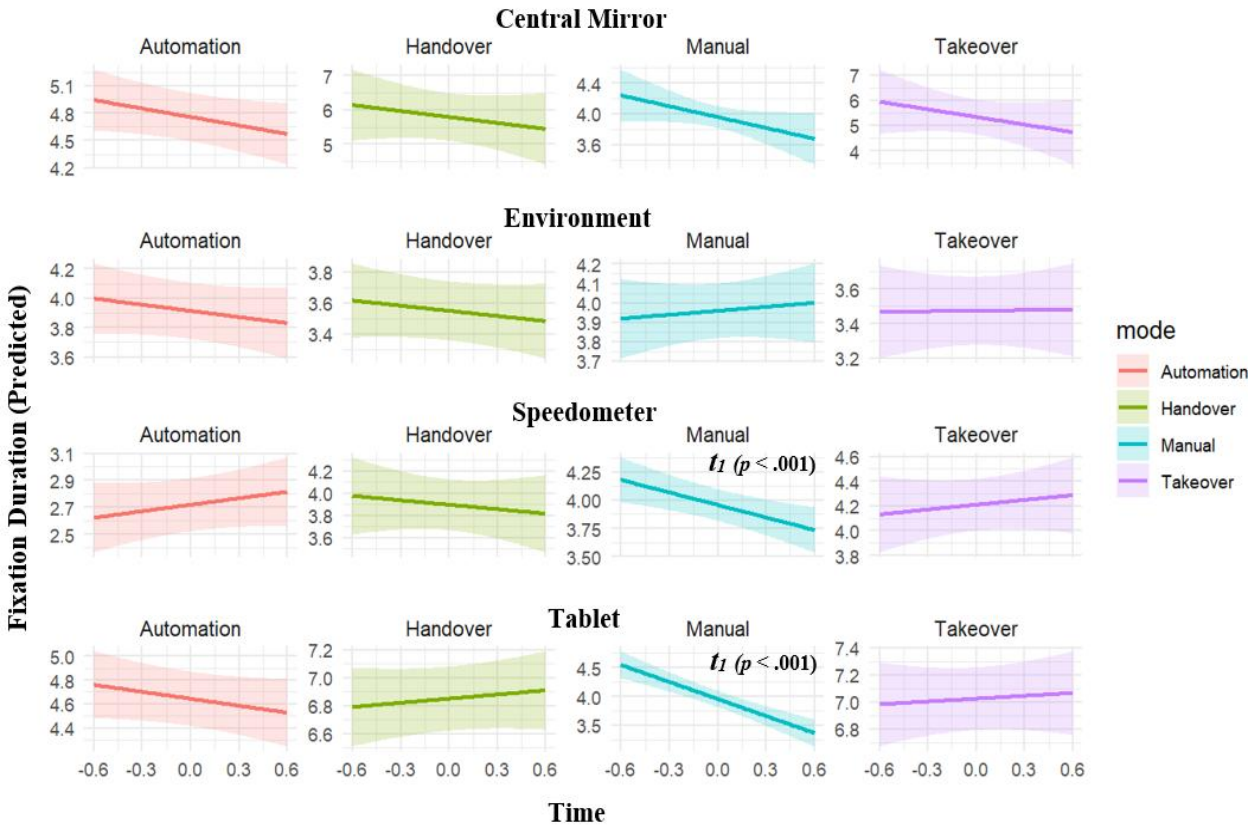

图3。各因素内不同模式下随时间变化的预测注视时长（线性）。横轴表示时间（线性），采用标准化中心化单位（即与均值的偏差）。阴影区域表示95%置信区间（95%置信区间），突显了各因素内不同模式下注意力的变化。

在模式与因素的交互作用（因素 → 模式）呈现显著固定效应后，我们进行了两两对比分析，以比较各因素内的不同模式，从而揭示参与者在每种模式下如何分配其视觉注意力，结果汇总于表3。以下总结各因素内显著的模式效应。对于环境因素，注视时长$_{Shift}$ 在手动模式下显著高于接管模式（$p < .001$），但手动模式与自动化模式（$p = .506$）或交接模式（$p < .342$）之间没有差异。自动化模式下的注视时长$_{Shift}$ 显著高于交接模式和接管模式（$p < .001$），而交接模式与接管模式之间没有显著差异，$p = .353$。这些结果表明，参与者在手动模式下将更多视觉注意力分配给环境，反映了该阶段更高的视觉需求。

对于平板电脑因素，自动化模式引发的FD_{Shift} 显著高于手动模式和交接模式（$p < .001$）。与所有其他模式相比，手动模式的FD_{Shift} 始终显著最低

（$p < .001$），而交接模式与接管模式之间无差异（$p = 1.000$）。对于速度计，自动化模式的FD_{Shift}显著低于手动模式、交接模式和接管模式（$p < .001$），而后三种模式的FD_{Shift}相同。这些结果表明，参与者在自动化模式下将显著更多的注意力分配给速度计，而其他模式的注意力水平相对相似。对于中央后视镜因素，与自动化模式、交接模式和接管模式相比，手动模式下的FD_{Shift}显著更低（$p < .001$）。此外，自动化模式的FD_{Shift}显著低于交接模式（$p = .001$），且略低于接管模式（$p = .081$）；交接模式与接管模式之间则未观察到差异（$p = 1.000$）。这些发现表明，在以控制为导向的过渡模式（即交接和接管）下，参与者更加关注中央后视镜，反映出情境意识在主动控制中的重要性。

总体而言，基于模式的效应表明，过渡模式（例如接管模式）会使参与者将更多视觉注意力集中于中央后视镜，而自动化则会引发对驾驶技术相关方面（例如平板电脑或速度计）的更多注意。相比之下，手动模式使参与者的注意力更明显地转向环境，这反映了主动控制所带来的更高视觉需求。

表3。层级结构中嵌套于因素内的各模式之间的注视持续时间（FD）$_{shift}$ 两两对比分析。

因素	**对比**（分子 / 分母）	θ	$SE\ \theta$	β_{Std}	**z**检验	**p**值
环境	手动/自动化	0.88	0.04	2.90	-2.71	0.506
	手动/交接	1.14	0.05	3.76	2.93	0.342
	手动/接管	1.31	0.06	4.32	5.69	0.000
	自动化/移交	1.29	0.06	4.26	5.65	0.000
	自动化/接管	1.49	0.07	4.89	8.28	0.000
	交接／接管	1.15	0.06	3.78	2.91	0.353
平板电脑	手动/自动化	0.62	0.04	2.04	-7.71	0.000
	手动 / 交接	0.12	0.01	0.39	-34.07	0.000
	手动 / 接管	0.11	0.01	0.38	-33.98	0.000
	自动化/移交	0.19	0.01	0.63	-32.10	0.000
	自动化/接管	0.18	0.01	0.61	-31.92	0.000
	交接／接管	0.97	0.05	3.18	-0.60	1.000
速度计	手动/自动化	3.02	0.15	9.94	22.91	0.000
	手动／交接	0.96	0.06	3.17	-0.59	1.000
	手动／接管	0.87	0.05	2.88	-2.51	0.671

	自动化/移交	0.32	0.02	1.05	-17.90	0.000
	自动化/接管	0.29	0.02	0.95	-22.49	0.000
	交接／接管	0.91	0.06	2.98	-1.43	0.999
中央镜像	手动/自动化	0.63	0.05	2.08	-5.79	0.000
	手动 / 交接	0.22	0.05	0.72	-6.53	0.000
	手动 / 接管	0.28	0.07	0.94	-5.37	0.000
	自动化 / 交接	0.35	0.08	1.14	-4.67	0.001
	自动化 / 接管	0.45	0.10	1.48	-3.49	0.081
	交接／接管	1.30	0.41	4.28	0.83	1.000

注。*"θ"*和"标准误 *θ"*分别表示两组均值之比"均值比"及其标准误，而*"β"*表示标准化对比系数。如果 $\theta > 1$, 则分子具有更长的注视持续时间（FD）$_{Shift}$ ，而不是分母。

注视次数（$\boldsymbol{FC}$）

为预测 FC_{Shift} ，同时考虑实验设计的嵌套结构，我们应用了第二个分层广义线性混合模型。在模型构建过程中，我们最初同时考虑了时间的线性项和高阶多项式项，具体包括二次项和三次项。我们将线性项（t_1）和二次项（t_2）作为嵌套于模式中的固定效应，并进一步将模式嵌套于因素中。然而，由于纳入三次项并未显著改善模型拟合，也未能为 FC_{shift} 的方差提供额外解释，因此未纳入三次项，$p > .05$。此外，由于初始模型存在奇异性问题，我们通过移除时间的随机斜率来简化随机效应结构，即t_1 和t_2, ，分析中仅保留参与者的随机截距。该模型对响应变量采用伽马分布和对数链接函数，以确保预测值始终为严格正值。

在预测 FC_{shift} 之前，计算了组内相关系数（ICC），以评估分层模型中不同层级所占的方差比例，即量化 FC_{shift} 的变异有多大程度是由个体差异（被试水平）驱动的，相对于由涉及 f、m、$t1$ 和 t_2 的嵌套结构所导致的差异。分析显示，总组内相关系数为 0.847，表明总方差的 84.7% 可由被试水平差异与嵌套结构的综合效应解释。被试水平组内相关系数为 0.0033，表明总方差中仅有 0.33% 归因于受试者之间的个体差异，该差异由随机截距捕捉。相比之下，嵌套结构组内相关系数为 0.844,

表明 84.4% 的方差可由与分层设计相关的固定效应解释。FC_{shift} 的变异几乎完全由层级结构而非个体受试者差异驱动。此外，模型并未出现奇异性，证实了随机效应设定及方差划分的适当性。因此，该模型可用公式3进行数学表示：

$$\log\left(E[\mathrm{FC}_{\mathrm{Shift},ij} \mid X_{ij}]\right) = \beta_0 + \sum_f \beta_f f + \sum_{m(f)} \beta_{m(f)} m(f) + \sum_{t_1(m(f))} \beta_{t_1(m(f))} t_1(m(f)) + \sum_{t_2(m(f))} \beta_{t_2(m(f))} t_2(m(f)) + u_{0j} \quad (3)$$

其中，Y_{ij} 表示参与者*j*的观测值*i*的FC_{ij} 。与公式 1 不同， $\beta_{t_2(m(f))} t_2(m(f))$表示嵌套于模式和因素中的二次时间效应（即非线性趋势）；也就是说，$\beta_{t_2(m(f))}$量化了时间的曲线变化（二次项）如何影响每个因素内各嵌套模式中的预期FC_{Shift} 。随机截距 u_{0j} 服从均值为零“0”、方差为（σ^2）的正态分布，以解释受试者间差异。

广义线性混合模型中的随机效应（$u_{0j} = \sim N(0, \sigma^2)$）在受试者层级设定，并包含随机截距。随机截距的方差（σ2）和标准差（*SD*）分别为 $\sigma 2 = 0.01$（$SD = 0.07$）。残差方差为 $\sigma_\epsilon^2 = 0.23$（$SD = 0.48$）。标准化残差范围为 -2.05 至 7.49，中位数为 -0.07，表明存在轻微正偏，但仍处于模型诊断可接受的范围内。模型拟合指标如下：赤池信息准则 = -4464.1、贝叶斯信息准则 = -4174.7、对数似然 = 2282.0，以及偏差 = 4564.1。总体而言，随机效应结果表明，受试者层级的随机变异得到了适当控制；标准化残差和拟合指标也支持模型具有足够的适用性。

FC_{shift} 表 4 的结果显示，各因素中驾驶模式的嵌套层级具有显著影响，这表明FC_{shift} 受到每个因素下不同驾驶模式的影响。在平板电脑的交接模式和手动模式中，观察到了显著的基于时间的效应。因此，平板电脑中嵌套于手动模式的时间（二次项）（平板电脑 → 手动 → 时间（t_2）；见表 4）

相对于参考情境（环境中的手动模式）具有统计显著性，p <.001。

平板电脑嵌套手动模式中，显著的线性时间效应（t_1）表明，随着时间每增加一个单位，FD_{Shift} 的比例便下降0.39个标准化单位（β_{Std} = -0.391，p = .012），反映出随着任务推进，平板电脑的视觉优先级逐渐降低。对于二次时间分量（t_2），显著的正向效应（β_{Std} = 0.79，p < .001）表明存在非线性趋势；也就是说，视觉注意力最初有所下降（更快地将注意力转离平板电脑），随后有所上升（将注意力转向平板电脑的速度变慢），这凸显了手动模式下注意力优先级随时间动态调整的特点（见图6）。 对于平板电脑中的交接模式，显著的正向二次时间效应（β_{Std} = 0.270，p = .028）表明视觉注意力转移呈非线性模式。参与者对平板电脑相关区域的注视次数最初增加（注意力转移变慢），随后减少（更快地将注意力转离平板电脑），反映出交接过程中视觉优先级的动态调整。

用于预测FC_{Shift} 的最终广义线性混合模型呈现了因素、模式和时间的固定效应系数（标准化），如表 4 所示。此外，还列出了简单斜率分析的结果。随机效应表示为参与者相对于固定效应的特异性偏差，如下式所示：

$$\log(E[\mathrm{FC}_{\mathrm{Shift},ij} \mid X_{ij}]) = -0.437 + (-3.981) f_{\mathrm{Tablet}} + (-1.614) f_{\mathrm{Speedometer}} + (-4.156) f_{\mathrm{Central\ Mirror}} + (0.148) m_{\mathrm{Automation}}(f_{\mathrm{Environment}}) + (-0.391) t_1(m_{\mathrm{Manual}}(f_{\mathrm{Tablet}})) + (0.785) t_2(m_{\mathrm{Manual}}(f_{\mathrm{Tablet}})) + (0.270) t_2(m_{\mathrm{Handover}}(f_{\mathrm{Tablet}})) + u_{0j}.$$

(4)

表 4。广义线性混合模型固定效应结果显示，随着时间推移、处于不同模式时，视觉注意力在四个因素间的分布情况。注：*"β"* 和 *"β*（标准误）"分别指非标准化回归系数及其标准误，而*"β"* 表示标准化回归

因素					因素 ⟹ 模式					因素 ⟹ 模式 ⟹ 时间（线性）				因素 ⟹ 模式 ⟹ 时间（二次项）			
	β（标准误）	β_{Std}	*t*值	*Pr(>|z|)*		*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*	*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*	*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*
平板电脑	-3.28 (0.06)	-3.981	-53.77	< .001	自动化	0.56 (0.06)	0.679	8.93	< .001	-0.10 (0.09)	-0.122	-1.08	0.278	-0.14 (0.09)	-0.175	-1.56	0.120
					交接	2.22 (0.06)	2.688	35.02	< .001	0.06 (0.10)	0.076	0.65	0.515	0.22 (0.10)	0.270	2.20	**0.028**
					接管	2.22 (0.07)	2.687	32.59	< .001	-0.02 (0.14)	-0.028	-0.16	0.871	-0.26 (0.14)	-0.310	-1.82	0.069
					手动	N/A	N/A	N/A	N/A	-0.32 (0.13)	-0.391	-2.54	**0.012**	0.65 (0.13)	0.785	5.07	< .001
速度计	-1.33 (0.05)	-1.614	-29.09	< .001	自动化	-1.10 (0.05)	-1.334	-23.00	< .001	0.02 (0.09)	0.030	0.27	0.789	-0.10 (0.09)	-0.124	-1.14	0.255
					交接	0.04 (0.06)	0.051	0.68	0.498	-0.07 (0.14)	-0.080	-0.46	0.648	0.10 (0.14)	0.117	0.67	0.504
					接管	0.10 (0.06)	0.120	1.70	0.089	-0.05 (0.16)	-0.061	-0.32	0.751	-0.30 (0.16)	-0.362	-1.86	0.063
					手动	N/A	N/A	N/A	N/A	-0.17 (0.08)	-0.201	-1.96	0.051	0.02 (0.08)	0.019	0.19	0.851
中央镜像	-3.43 (0.07)	-4.156	-47.06	< .001	自动化	0.47 (0.08)	0.565	5.97	< .001	-0.17 (0.11)	-0.206	-1.54	0.124	-0.16 (0.11)	-0.190	-1.41	0.157
					交接	1.63 (0.28)	1.973	5.82	< .001	0.10 (0.48)	0.127	0.22	0.827	-0.48 (0.61)	-0.582	-0.79	0.427
					接管	1.25 (0.26)	1.517	4.89	< .001	-0.50 (0.80)	-0.603	-0.62	0.536	0.14 (0.76)	0.173	0.19	0.852
					手动	N/A	N/A	N/A	N/A	-0.20 (0.17)	-0.248	-1.20	0.232	-0.03 (0.18)	-0.037	-0.17	0.864
环境	N/A	N/A	N/A	N/A	自动化	0.12 (0.05)	0.148	2.69	**0.007**	-0.02 (0.08)	-0.022	-0.22	0.828	0.00 (0.08)	-0.002	-0.02	0.982
					交接	-0.14 (0.05)	-0.164	-2.99	**0.003**	0.02 (0.08)	0.022	0.21	0.833	-0.04 (0.08)	-0.047	-0.47	0.637
					接管	-0.25 (0.05)	-0.301	-4.84	< .001	0.13 (0.13)	0.155	1.00	0.318	0.19 (0.13)	0.232	1.53	0.127
					手动	N/A	N/A	N/A	N/A	0.06 (0.08)	0.072	0.71	0.480	-0.01 (0.08)	-0.007	-0.07	0.947

系数——模式内时间和因素内模式以因素 ⟹ 模式 ⟹ 时间的符号框架表示。"不适用"代表手动模式，"环境"用作参照条件。

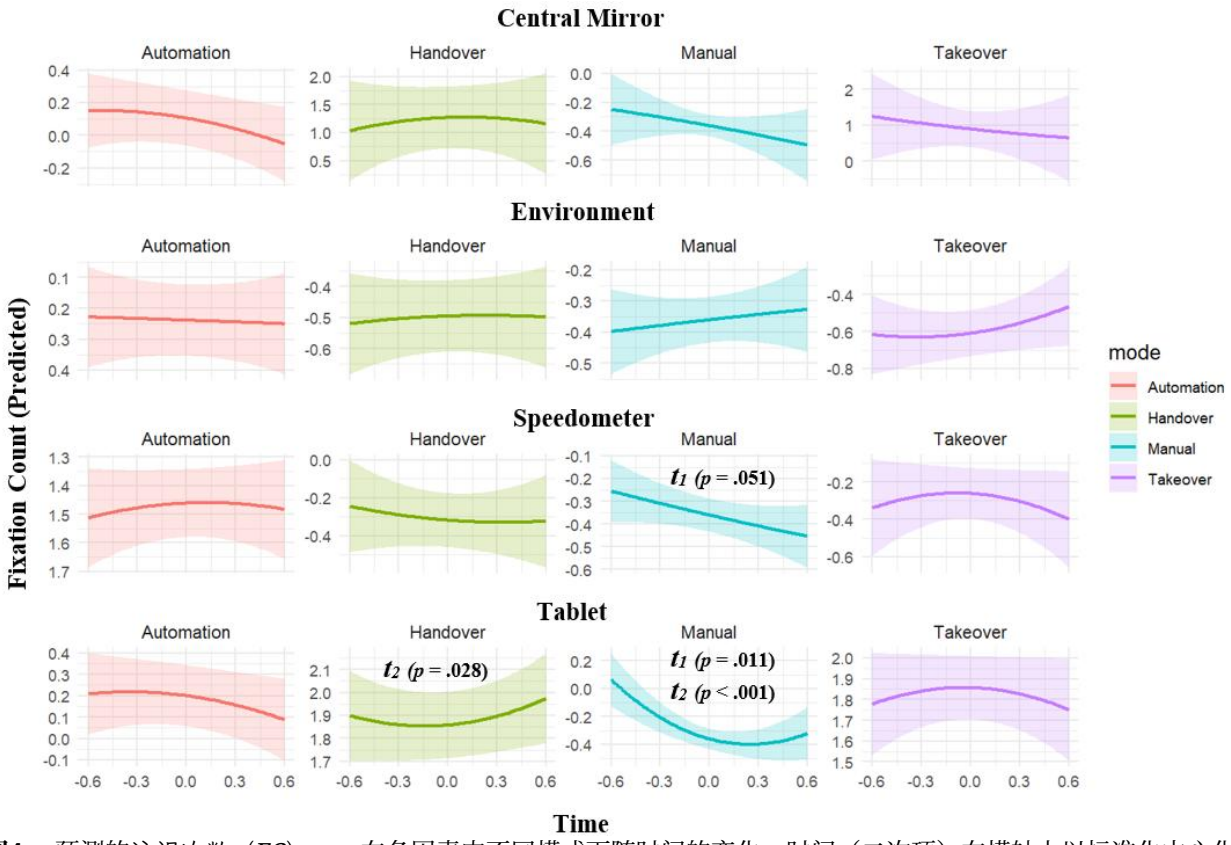

图4。 预测的注视次数（*FC*）$_{Shifted}$ 在各因素内不同模式下随时间的变化。时间（二次项）在横轴上以标准化中心化单位表示（即与均值的偏差）。阴影区域表示95%置信区间，突出显示各因素内不同模式之间注意力的变化。

在因素（因素→ 模式）中模式的固定效应显著之后，进行了两两对比分析，以比较每个因素内的不同模式，揭示参与者在这些模式之间如何转移视线，并突出视觉注意模式的差异，结果汇总于表5。对于环境因素，FC_{Shift} 在接管模式下显著低于手动模式（$p < .001$），但与自动化（$p = .488$）或交接（$p = .332$）相比无显著差异。此外，交接和接管模式下的FC_{Shift} 显著高于自动化（$p < .001$），而交接与接管之间无显著差异（$p = .743$）。这些结果表明，环境因素中的视线转移在交接和接管模式下更为频繁，反映出过渡阶段较高的视觉注意力。对于平板电脑因素，手动模式下的FC_{Shift} 显著低于其他三种模式（$p < .001$），而交接和接管模式下的FC_{Shift} 高于

自动化（$p < .001$），但二者相等（$p = 1.000$）。根据注视次数，对平板电脑因素的视觉注意分布显示，手动模式下的注视次数显著少于其他模式，而交接和接管模式下的注视比自动化更为频繁，反映出过渡阶段更高的监控需求。

对于速度表因素，自动化模式的FC_{Shift} 显著低于手动、交接和接管模式（$p < .001$），而后三种模式的FC_{Shift} 相近（$p > .05$）。速度表因素的视觉注意分布表明，自动化模式下无需频繁监控速度，而手动、交接和接管模式均要求持续关注速度相关信息。对于中央后视镜因素，手动模式的FC_{Shift} 显著低于自动化、交接和接管模式（$p < .001$）。自动化模式的FC_{Shift} 也显著低于交接模式（$p = .007$）；自动化模式与接管模式之间（$p = .139$）以及交接模式与接管模式之间（$p = 1.000$）则未观察到显著差异。这些结果表明，手动模式下对中央后视镜的视线转移极少，而过渡模式下视线转移增多，凸显了这些模式的监控需求。

总体的基于模式的效应表明，视觉注意力分配因模式和因素而显著不同。过渡模式（交接和接管）始终伴随着更频繁的视线转移，尤其是转向环境和平板电脑，这反映出监控需求有所增加。手动模式下的视线转移总体较少，尤其是转向平板电脑和中央后视镜的视线转移减少，表明注意力集中在当前任务需求上。相比之下，自动化模式下转向速度计和中央后视镜的视线转移较少，凸显了自动化控制期间对这些区域的依赖降低。

表5。层级结构中各因素内嵌套模式之间FC_{shift} 的两两对比分析。

因素	**对比** *(分子 / 分母)*	θ	标准误 θ	β_{Std}	z检验	p值
环境	手动/自动化	0.88	0.04	2.90	-2.73	0.488
	手动/移交	1.14	0.05	3.76	2.94	0.332
	手动/接管	1.29	0.06	4.24	5.08	**< .001**
	自动化/移交	1.29	0.06	4.25	5.69	**< .001**

	自动化/接管	1.46	0.07	4.79	7.59	**< .001**
	交接／接管	1.13	0.06	3.71	2.41	0.743
平板电脑	手动/自动化	0.57	0.04	1.87	-9.00	**< .001**
	手动/移交	0.11	0.01	0.36	-35.02	**< .001**
	手动/接管	0.11	0.01	0.36	-33.45	**< .001**
	自动化/移交	0.19	0.01	0.63	-32.13	**< .001**
	自动化/接管	0.19	0.01	0.63	-30.04	**< .001**
	交接／接管	0.99	0.06	3.26	-0.13	1.000
速度计	手动/自动化	3.02	0.14	9.93	23.07	**< .001**
	手动/移交	0.96	0.06	3.16	-0.62	1.000
	手动/接管	0.91	0.05	2.98	-1.77	0.987
	自动化/移交	0.32	0.02	1.05	-18.04	**< .001**
	自动化/接管	0.30	0.02	0.99	-20.95	**< .001**
	交接／接管	0.94	0.07	3.10	-0.87	1.000
中央镜像	手动/自动化	0.63	0.05	2.06	-5.93	**< .001**
	手动 / 交接	0.20	0.06	0.65	-5.76	**< .001**
	手动 / 接管	0.28	0.07	0.93	-5.14	**< .001**
	自动化/移交	0.31	0.09	1.03	-4.17	**0.007**
	自动化/接管	0.45	0.11	1.49	-3.30	0.139
	交接／接管	1.44	0.52	4.74	1.01	1.000

注。“θ”和“$SE\ \theta$”分别指两组均值之比（“均值比”）及其标准误，而“β_{Std}”表示标准化对比系数。如果 $\theta > 1$，分子的 FC_{Shift} 高于分母。

首次注视时间（***TFF***）

用于预测 TFF_{Shift} 的最终广义线性混合模型与公式3所示结构相同。该模型包含嵌套在模式内、并进一步嵌套在因素内的线性（t_1）和二次（t_2）时间成分。模型仅保留参与者的随机截距，以捕捉个体在基线注视时间上的差异。与先前的设定一致，响应变量采用伽马分布和对数链接函数，以确保预测值始终为正。

首先，计算了组内相关系数，以评估首次注视时间的方差中可归因于嵌套结构和个体层面差异的比例。受试者与嵌套结构综合效应的总组内相关系数为组内相关系数 = 0.5496，表明首次注视时间方差的54.96%可归因于受试者之间的差异以及嵌套因子结构。进一步分解显示

被试水平组内相关系数（随机截距）为组内相关系数 = 0.053，表明总方差的5.31%归因于受试者之间的差异。嵌套结构中模式内时间（线性和二次）以及因素内模式的组内相关系数为组内相关系数 = 0.497，表明因素、模式和时间成分层级结构中的独特情境差异大约解释了TFF_{Shift}方差的50%。

广义线性混合模型中的随机效应（$u_{0j} = \sim N(0, \sigma^2)$）在受试者层级设定，随机截距为$\sigma^2 = 0.28$（标准差 = 0.53），残差方差为$\sigma_{\epsilon}^2 = 2.38$（标准差 = 1.54）。标准化残差范围为-0.65至11.65，中位数为-0.26，表明存在轻微正偏，但仍处于模型诊断可接受的范围内。模型拟合指标如下：赤池信息准则= 9404.0，贝叶斯信息准则= 9693.5，对数似然= -4652.0，偏差= 9304.0。总体而言，随机效应结果表明受试者层级的随机变异已得到适当考虑，标准化残差和拟合指标支持该模型的充分性。

基于此，公式5在公式3所引入的层级结构基础上进一步构建，纳入相同的组成部分，以考虑本研究的嵌套设计。它与本研究的嵌套设计相一致，并凸显了多层次预测变量及被试水平随机变异如何影响视觉注意优先级（以TFF_{Shift}衡量）：

$$\log(E[\mathrm{TFF}_{\mathrm{Shift},ij} \mid X_{ij}]) = \beta_0 + \sum_f \beta_f f + \sum_{m(f)} \beta_{m(f)} m(f) + \sum_{t_1(m(f))} \beta_{t_1(m(f))} t_1(m(f)) + \sum_{t_2(m(f))} \beta_{t_2(m(f))} t_2(m(f)) + u_{0j} \quad (5)$$

表6展示了用于预测TFF_{Shift}的广义线性混合模型的固定效应结果，其中较小的均值表示注意力转移更快。总体而言，因素内模式的嵌套层级表明，模式会显著影响注意模式，尤其是在交接和接管阶段，此时注意力往往会下降。如表6和图6所示，这些因素中各模式的时间趋势（包括t_1和t_2）各不相同；在平板电脑、速度计和环境因素中，手动模式和自动化模式的效应尤为显著。因此，较小的TFF_{Shift}值表示注意力转移更快、视觉优先级更高，而较大的值则表示注意力转移更慢、优先级更低。

时间效应的结果被解释为嵌套效应，而非交互作用，以反映数据的层级结构。

显著结果表明，对于嵌套在手动模式中的平板电脑因素，线性时间分量显示，时间每增加一个单位，TFF 就增加 0.028 个标准化单位（β_{Std} = .028，p < .001）。这表明，随着时间推移，平板电脑相关区域的视觉优先级逐渐降低。显著的二次分量呈现负向趋势，反映出一种非线性变化：TFF 起初下降（注意更快），随后上升（注意更慢）（β_{Std} = -.029，p < .001）。这一模式凸显了平板电脑相关刺激的优先化在手动模式下会动态变化。

对于嵌套在自动化模式中的环境因素，线性时间分量的标准化系数为正（时间每增加一个单位，增加 β_{Std} = 0.014 个单位），表明环境相关区域的视觉优先级持续下降（p = .003）。相反，在手动模式下，线性效应为负，表明随着时间每增加一个单位，TFF_{Shif} 减少 0.015 个单位，说明随着时间推移，环境相关区域的视觉优先级不断提高（p = .001）。此外，手动模式下环境因素的正向二次时间分量揭示了一种非线性趋势：TFF_{Shif} 起初上升（注意更慢），随后下降（注意更快）（β_{Std} = 0.009，p =.043）。这凸显了视觉注意优先级随时间推移而动态调整。因此，根据标准化系数并聚焦于表6中的显著效应，GLMM 的TFF_{Shift} 结果公式根据结果更新如下：

$$\log(E[\text{TFF}_{\text{Shift},ij} \mid X_{ij}]) = 0.002 + 0.063 f_{\text{Tablet}} + 0.021 f_{\text{Speedometer}} + 0.07 f_{\text{Central Mirror}}$$
$$-0.013 m_{\text{Automation}}(f_{\text{Environment}}) + 0.042 m_{\text{Automation}}(f_{\text{Speedometer}}) - 0.016 m_{\text{Handover}}(f_{\text{Environment}})$$
$$-0.049 m_{\text{Handover}}(f_{\text{Tablet}}) - 0.014 m_{\text{Handover}}(f_{\text{Speedometer}}) - 0.048 m_{\text{Handover}}(f_{\text{Central Mirror}})$$
$$-0.015 m_{\text{Takeover}}(f_{\text{Environment}}) - 0.052 m_{\text{Takeover}}(f_{\text{Tablet}}) + 0.007 m_{\text{Takeover}}(f_{\text{Speedometer}})$$
$$-0.06 m_{\text{Takeover}}(f_{\text{Central Mirror}}) - 0.015 t_1(f_{\text{Environment}} : m_{\text{Manual}}) + 0.028 t_1(f_{\text{Tablet}} : m_{\text{Manual}})$$
$$+0.014 t_1(f_{\text{Speedometer}} : m_{\text{Manual}}) + 0.014 t_1(f_{\text{Environment}} : m_{\text{Automation}}) + 0.009 t_2(f_{\text{Environment}} : m_{\text{Manual}})$$
$$-0.029 t_2(f_{\text{Tablet}} : m_{\text{Manual}}) + u_{0j}$$

(6)

表6。广义线性混合模型（GLMM）结果：TFF_{Shift} 在不同模式下随时间变化时，视觉注意优先级在四个因素间的分布固定效应。注：*"β"* 和 *"β*（标准误）"分别指非标准化回归系数及其标准误，而*"β"* 表示标准化回归系数。模式内时间和因素内模式以因素 ⟹ 模式 ⟹ 时间的符号框架表示。"不适用"表示手动模式，"环境"为参照条件。

因素					因素 ⟹ 模式					因素 ⟹ 模式 ⟹ 时间（线性）				因素 ⟹ 模式 ⟹ 时间（二次项）			
	β（标准误）	β_{Std}	*t*值	*Pr(>|z|)*		*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*	*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*	*β*（标准误）	β_{Std}	*t*值	*Pr(>|z|)*
平板电脑	3.29 (0.17)	0.063	19.12	< .001	自动化	0.05 (0.18)	0.001	0.28	0.778	-0.06 (0.26)	-0.001	-0.25	0.805	0.27 (0.25)	0.005	1.11	0.268
					交接	-2.59 (0.18)	-0.049	-14.71	< .001	-0.04 (0.27)	-0.001	-0.15	0.885	-0.18 (0.27)	-0.003	-0.66	0.508
					接管	-2.73 (0.19)	-0.052	-14.31	< .001	0.12 (0.41)	0.002	0.30	0.766	0.32 (0.39)	0.006	0.81	0.419
					手动	N/A	N/A	N/A	N/A	1.46 (0.34)	0.028	4.23	< .001	-1.55 (0.37)	-0.029	-4.22	< .001
速度计	1.08 (0.13)	0.021	8.14	< .001	自动化	2.20 (0.14)	0.042	16.13	< .001	0.06 (0.26)	0.001	0.23	0.818	0.09 (0.24)	0.002	0.37	0.715
					交接	-0.73 (0.18)	-0.014	-4.09	< .001	-0.04 (0.27)	-0.001	-0.15	0.885	0.21 (0.39)	0.004	0.54	0.589
					接管	0.37 (0.16)	0.007	2.27	**0.023**	-0.04 (0.43)	-0.001	-0.09	0.928	0.26 (0.42)	0.005	0.62	0.535
					手动	N/A	N/A	N/A	N/A	0.71 (0.25)	0.014	2.86	**0.004**	0.47 (0.25)	0.009	1.85	0.065
中央镜像	3.65 (0.20)	0.07	17.93	< .001	自动化	-0.14 (0.22)	-0.003	-0.64	0.523	0.09 (0.31)	0.002	0.32	0.751	0.20 (0.31)	0.004	0.64	0.522
					交接	-2.50 (0.78)	-0.048	-3.20	**.001**	-1.47 (1.30)	-0.028	-1.13	0.259	-1.62 (1.68)	-0.031	-0.96	0.335
					接管	-3.14 (0.68)	0.060	-4.59	< .001	-2.19 (1.89)	-0.042	-1.16	0.248	-1.81 (1.99)	-0.034	-0.91	0.365
					手动	N/A	N/A	N/A	N/A	0.65 (0.48)	0.012	1.35	0.176	-0.13 (0.51)	-0.003	-0.26	0.795
环境	N/A	N/A	N/A	N/A	自动化	-0.70 (0.13)	-0.013	-5.54	< .001	0.72 (0.24)	0.014	2.99	**0.003**	0.25 (0.24)	0.005	1.06	0.292
					交接	-0.85 (0.13)	-0.016	-6.59	< .001	0.04 (0.24)	0.001	0.14	0.886	0.24 (0.23)	0.005	1.02	0.306
					接管	-0.77 (0.15)	-0.015	-5.14	< .001	-0.48 (0.41)	-0.009	-1.16	0.248	-0.56 (0.38)	-0.011	-1.50	0.135
					手动	N/A	N/A	N/A	N/A	-0.77 (0.24)	-0.015	-3.19	**0.001**	0.46 (0.23)	0.009	2.03	**0.043**

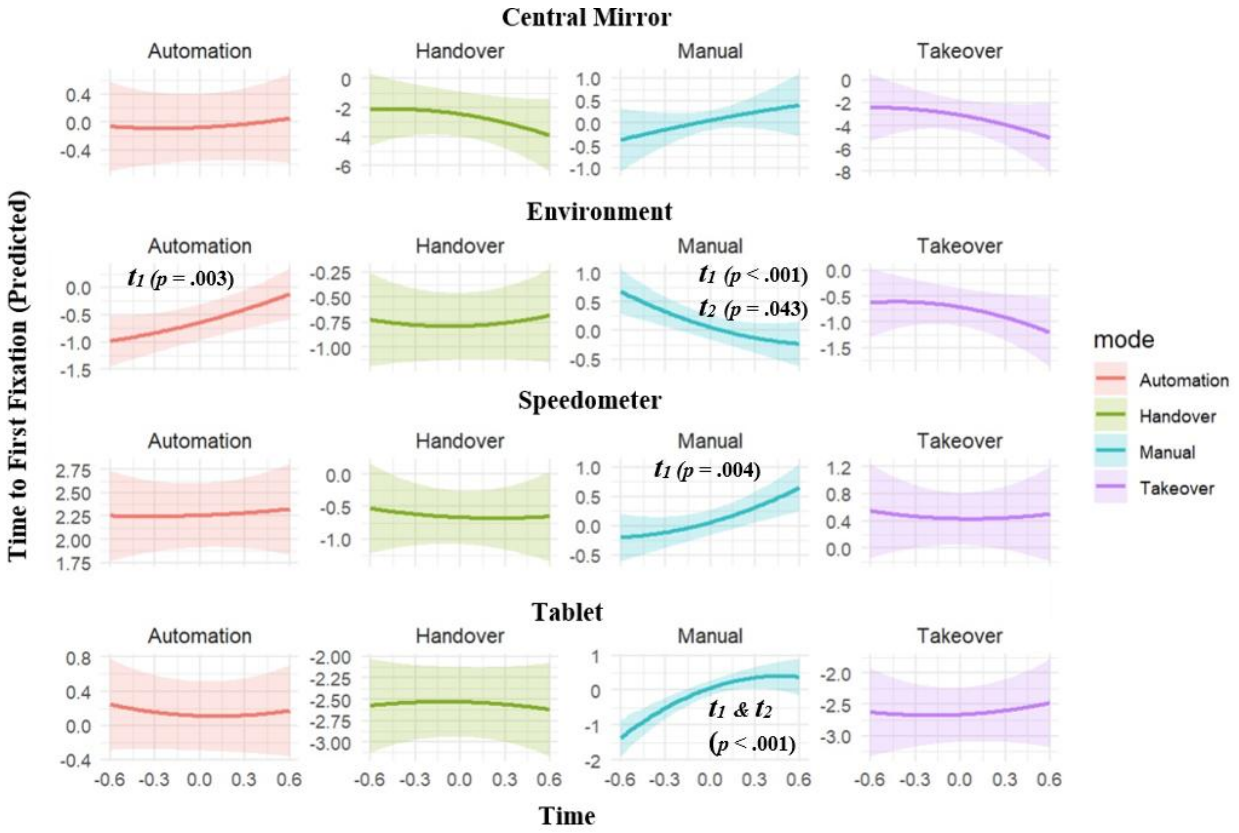

图 5. 各因素内不同模式随时间变化的预测TFF_{Shift}。横轴表示标准化中心化单位（即与均值的偏差）。阴影区域表示 95%置信区间，突出显示各因素内不同模式之间注意力的变化。

在 TFF_{Shift}中，鉴于因素内模式的固定效应显著（因素 → 模式），我们进行了两两对比分析，以比较各因素内的不同模式，从而揭示这些区域吸引注意力的速度，帮助我们了解四个因素中的即时视觉优先级，汇总如下：

表 7。对于环境因素，TFF_{Shift} 在手动模式下显著高于其他三种模式（$p < .001$），而其他三种模式之间未观察到差异（$p = 1.000$）。对于环境因素，参与者在手动模式下将视觉注意力优先分配给环境的速度较慢，而其他模式下的注意力分配速度相同且更快。

对于平板电脑因素，TFF_{Shift} 在手动模式下显著高于交接、接管和自动化模式（$p < .001$）。自动化模式下的TFF_{Shift} 也显著高于交接和接管模式（$p < .001$），而交接和接管模式之间未观察到差异（$p = 1.000$）。手动模式下优先分配注意力的速度较慢，反映出对平板电脑的即时注意力较少，这可能是因为它在手动控制任务中的相关性较低；而自动化模式和过渡模式（交接和接管）下优先分配注意力的速度较快，则凸显了平板电脑在支持任务监控和模式转换方面的作用。

对于速度表因素，TFF_{Shift} 在手动模式下显著低于自动化模式（$p < .001$）和交接模式（$p = .016$），但与接管模式相比无显著差异（$p = .667$）。与交接模式和接管模式相比，自动化模式的 TFF_{Shift} 显著较高（$p < .001$）；交接模式则显著低于接管模式（$p < .001$）。手动模式和交接模式下更快的优先化表明，速度监控对于需要立即执行的控制任务至关重要；而自动化模式下优先化较慢，说明自动驾驶时对速度信息的依赖有所降低，接管模式则体现了过渡阶段的中间优先级。

对于中央后视镜因素，TFF_{Shift} 在手动模式下显著高于接管模式（$p = .001$），但与自动化模式或交接模式相比无显著差异（$p = 1.000$ 和 $p = .252$）。与接管模式相比，自动化模式的 TFF_{Shift} 也显著较高（$p = .002$）；交接模式与接管模式之间则未观察到显著差异（$p = 1.000$）。手动模式下优先化较慢，表明参与者在主动控制期间较少立即依赖后视镜；交接模式和接管模式下优先化较快，则凸显了过渡期间即时情境意识的重要性，而自动化模式体现了中间水平的视觉优先级。

总体而言，TFF_{Shift} 的基于模式的效应反映了参与者的即时视觉优先级如何随驾驶模式和因素而变化。在手动模式下，对于平板电脑和中央后视镜等因素，优先级较低，这表明这些区域在直接控制时并不那么重要，因为参与者会专注于监控速度计和环境等更为紧迫的驾驶任务。相比之下，

在交接和接管模式下，参与者对中央后视镜和平板电脑等因素的优先级更高，凸显了这些阶段对情境意识和任务转换的更高需求。自动化模式下，参与者对速度计的优先级较低，这表明由于控制权移交给系统，他们对某些视觉区域的依赖有所降低。

表 7。层级结构中各因素内嵌套模式之间TFF_{shift} 的两两对比分析

结构。

因素	对比（分子 / 分母）	θ	$SE\ \theta$	β_{Std}	z检验	p值
环境	手动/自动化	2.11	0.27	0.11	5.85	**< .001**
	手动/移交	2.39	0.31	0.12	6.73	**< .001**
	手动/接管	2.16	0.31	0.11	5.33	**< .001**
	自动化/移交	1.13	0.15	0.06	0.97	1.000
	自动化/接管	1.02	0.15	0.05	0.16	1.000
	交接／接管	0.90	0.13	0.05	-0.72	1.000
平板电脑	手动/自动化	0.93	0.16	0.05	-0.41	1.000
	手动/移交	13.00	2.28	0.67	14.59	**< .001**
	手动/接管	15.01	2.78	0.77	14.64	**< .001**
	自动化/移交	13.97	1.98	0.72	18.59	**< .001**
	自动化/接管	16.14	2.47	0.83	18.13	**< .001**
	交接／接管	1.16	0.18	0.06	0.93	1.000
速度计	手动/自动化	0.11	0.01	0.01	-16.31	**< .001**
	手动/移交	2.02	0.36	0.10	3.96	**0.016**
	手动/接管	0.67	0.11	0.03	-2.51	0.667
	自动化/移交	18.58	3.32	0.96	16.36	**< .001**
	自动化/接管	6.21	0.98	0.32	11.53	**< .001**
	交接／接管	0.33	0.06	0.02	-5.64	**< .001**
中央镜像	手动/自动化	1.13	0.25	0.06	0.58	1.000
	手动 / 交接	11.25	8.87	0.58	3.07	0.252
	手动 / 接管	20.74	13.78	1.07	4.56	**0.001**
	自动化/移交	9.91	7.70	0.51	2.95	0.326
	自动化 / 接管	18.27	11.89	0.94	4.46	**0.002**
	交接／接管	1.84	1.84	0.10	0.61	1.000

注。“θ”和“标准误 θ”分别表示两组均值之比（“均值比”）及其标准误，而“β_{Std}”表示标准化对比系数。如果 $\theta > 1$，则分子的 TFF_{Shift} 高于分母。

基于Trus预测动态眼动行为的多元回归分析 t

我们进行了多元回归分析，以探究驾驶信任如何预测不同驾驶模式下的眼动追踪行为。该分析使用R软件及其相关程序包，并遵循三个关键步骤：*(1)* 评估偏度：我们使用e1071程序包（Meyer等，2023）评估了三个因变量眼动追踪变量的偏度。偏度值超过±1的变量表明存在显著的非正态性，因此使用stats程序包（*Stats*程序包 - *R*文档，n.d.）（Tabachnick和Fidell，2006）进行了对数变换，以降低偏度。正态化后，偏度值处于可接受范围内（±1），确保数据满足回归分析所需的正态性假设。(2) 标准化驾驶信任：使用dplyr（Wickham等，2014）和stats程序包对自变量驾驶信任进行标准化，使其均值为0、标准差为1。此外，还创建了驾驶信任的二次项（*tr2*），以解释潜在的曲线效应，从而探究不同驾驶信任水平如何影响注意力。回归模型同时将标准化的驾驶信任变量及其二次项作为预测变量。(3) 多元回归：我们使用broom（Robinson等，2014）和stats程序包进行多元回归，根据驾驶信任的线性项和二次项预测各项眼动追踪结果。结果包括线性项和二次项驾驶信任的标准化回归系数（β）、标准误（*SE* β）、*t*检验值、*p*值以及调整后的*R2*（R^2_{Adj}）。

多元回归结果显示，在多种驾驶模式下，信任对注视时长有显著影响，尤其是在涉及平板电脑的任务中（见表8）。在自动化模式下，信任与注视时长之间存在显著的正向二次关系，$\beta = 0.18$，$t(2.33)$，$p = .027$，表明随着信任水平提高，注视时长也会增加，且在信任水平较高时，这种效应更强。同样，在交接模式下，信任被发现是注视时长的显著预测因子，$\beta = 3.08$，$t(3.13)$，$p = .004$，信任水平越高，注视时长就会显著增加。此外，交接模式下显著的二次效应，$\beta = 2.68$，$t(3.49)$，$p = .002$，表明随着信任水平上升，注视时长的增加速度会加快

至更高水平。在接管模式下也观察到类似的模式，其中发现存在显著的二次关系，$\beta = 2.03$，$t(2.36)$，$p = .026$，表明随着信任水平提高，注视时长也会增加，且在信任水平较高时增加得更快。这些发现表明，信任在决定平板电脑相关任务中的注视时长方面发挥着重要作用，信任水平越高，注视时间越长。

表8。基于线性（*tr*）和二次（tr^2）信任项预测注视时长的多元回归结果。

因素	模式（R^2_{Adj}）	Term	*β*	*SE*	*t*	*p*
Tablet	自动化（$R^2_{Adj} = 0.184$）	tr	0.02	0.10	0.20	0.843
		tr^2	0.18	0.08	2.33	**0.027**
	交接（$R^2_{Adj} = 0.344$）	tr	3.08	0.99	3.13	**0.004**
		tr^2	2.68	0.77	3.49	**0.002**
	手动（$R^2_{Adj} = 0.032$）	tr	0.08	0.09	0.96	0.348
		tr^2	0.03	0.07	0.45	0.659
	接管（$R^2_{Adj} = 0.178$）	tr	1.85	1.12	1.65	0.111
		tr^2	2.03	0.86	2.36	**0.026**
Environment	自动化（$R^2_{Adj} = 0.071$）	tr	4.80	3.23	1.49	0.148
		tr^2	1.83	2.57	0.71	0.482
	交接（$R^2_{Adj} = 0.022$）	tr	2.70	3.47	0.78	0.442
		tr^2	0.53	2.76	0.19	0.849
	手动（$R^2_{Adj} = 0.049$）	tr	4.40	3.60	1.22	0.231
		tr^2	1.82	2.86	0.64	0.530
	接管（$R^2_{Adj} = 0.030$）	tr	2.70	3.32	0.81	0.423
		tr^2	-0.12	2.64	-0.04	0.965
Remodeled	自动化（$R^2_{Adj} = 0.049$）	tr	0.29	0.34	0.87	0.393
		tr^2	0.31	0.27	1.15	0.262
	手动（$R^2_{Adj} = 0.003$）	tr	0.32	1.14	0.28	0.782
		tr^2	0.15	0.90	0.16	0.870
	接管（$R^2_{Adj} = 0.023$）	tr	0.56	1.24	0.45	0.656
		tr^2	-0.37	0.99	-0.37	0.711
Carriers	自动化（$R^2_{Adj} = 0.071$）	tr	-0.09	0.07	-1.22	0.234
		tr^2	-0.03	0.06	-0.47	0.644

Note. “*β*”表示标准化回归系数，“SE *β*”表示其标准误 r.

信任对注视次数也有显著影响，尤其是在平板电脑上，见表9。在自动化模式下，信任与注视次数之间存在显著的二次关系，$\beta = 0.01$,$t(2.24)$, $p = .033$，这表明随着信任水平提高，参与者注视平板电脑的频率也随之增加，且

这种影响在信任水平较高时更为明显。同样，在交接模式下也观察到显著的二次效应，$\beta = 0.04$, $t(2.25)$, $p = .033$，这表明注视次数随着信任水平提高而增加，尤其是在信任水平较高时。这些结果表明，随着信任水平提高，参与者与平板电脑相关兴趣区的交互更加频繁，尤其是在自动化模式和交接模式下，且信任水平较高时这种影响更强。

表9。 通过线性（*tr*）和二次（tr^2）信任项预测注视次数的多元回归结果。

因素	模式（R^2_{Adj}）	Term	*β*	*SE*	*t*	*p*
Tablet	自动化（$R^2_{Adj} = 0.162$）	tr	0.00	0.00	0.40	0.689
		tr^2	0.01	0.00	2.24	**0.033**
	交接（$R^2_{Adj} = 0.153$）	tr	0.02	0.02	1.14	0.262
		tr^2	0.04	0.02	2.25	**0.033**
	手动（$R^2_{Adj} = 0.037$）	tr	0.01	0.01	1.03	0.311
		tr^2	0.00	0.01	0.51	0.613
	接管（$R^2_{Adj} = 0.050$）	tr	0.01	0.02	0.31	0.759
		tr^2	0.02	0.01	1.15	0.259
Environment	自动化（$R^2_{Adj} = 0.001$）	tr	0.00	0.02	0.15	0.878
		tr^2	0.00	0.01	0.13	0.900
	交接（$R^2_{Adj} = 0.009$）	tr	-0.01	0.04	-0.32	0.749
		tr^2	-0.01	0.03	-0.50	0.624
	手动（$R^2_{Adj} = 0.010$）	tr	-0.01	0.02	-0.42	0.679
		tr^2	0.00	0.02	0.09	0.932
	接管（$R^2_{Adj} = 0.023$）	tr	0.02	0.04	0.43	0.673
		tr^2	-0.01	0.03	-0.41	0.685
Speedometer	自动化（$R^2_{Adj} = 0.031$）	tr	0.00	0.01	0.56	0.583
		tr^2	0.00	0.00	0.94	0.357
	交接（$R^2_{Adj} = 0.129$）	tr	0.10	0.06	1.74	0.095
		tr^2	0.06	0.06	0.97	0.342
	手动（$R^2_{Adj} = 0.023$）	tr	0.01	0.02	0.80	0.431
		tr^2	0.01	0.01	0.58	0.567
	接管（$R^2_{Adj} = 0.003$）	tr	0.00	0.01	-0.19	0.851
		tr^2	0.00	0.01	-0.25	0.801
Rearview Mirror	自动化（$R^2_{Adj} = 0.024$）	tr	0.00	0.00	-0.71	0.482
		tr^2	0.00	0.00	0.01	0.995

Note. “*β*”表示标准化回归系数，“SE *β*”指其标准误 r.

信任与首次注视时间之间的关系在平板电脑和中央后视镜中也均具有显著性，汇总见表10。在自动化模式下，信任与平板电脑上的首次注视时间之间发现了显著的负二次项

关系，β = -0.22，t(−3.45)，p = .002。随着信任水平提高，参与者注视平板电脑所需的时间减少，并且这种效应在较高信任水平下更加明显，表明更高的信任水平会使参与者更快地与平板电脑进行视觉参与。相反，在中央后视镜中，自动化模式下信任与首次注视时间之间呈现显著的正向关系，β = 0.24，t(2.41)，p = .023。较高的信任水平与中央后视镜更长的首次注视时间相关，这表明随着信任水平提高，参与者减少了对中央后视镜等对象的监控注意力。

表10.以线性（tr）和二次（tr^2）信任项预测首次注视时间的多元回归结果。

因素	模式（R^2_{Adj}）	Term	*β*	*SE*	*t*	*p*
Tablet	自动化 (R^2_{Adj} = 0.341)	tr	-0.01	0.08	-0.11	0.910
		tr^2	-0.22	0.06	-3.45	**0.002**
	交接 (R^2_{Adj} = 0.044)	tr	-0.12	0.10	-1.12	0.272
		tr^2	-0.06	0.08	-0.75	0.462
	手动 (R^2_{Adj} = 0.042)	tr	-1.49	3.52	-0.42	0.675
		tr^2	1.89	2.75	0.69	0.497
	接管 (R^2_{Adj} = 0.047)	tr	-0.02	0.10	-0.20	0.846
		tr^2	-0.08	0.08	-1.08	0.291
Minivan	自动化 (R^2_{Adj} = 0.033)	tr	-0.01	0.10	-0.11	0.916
		tr^2	-0.07	0.08	-0.92	0.367
	交接 (R^2_{Adj} = 0.024)	tr	-0.07	0.09	-0.75	0.459
		tr^2	-0.05	0.07	-0.71	0.481
	手动 (R^2_{Adj} = 0.011)	tr	-0.03	0.12	-0.22	0.831
		tr^2	-0.05	0.10	-0.57	0.570
	接管 (R^2_{Adj} = 0.148)	tr	-0.09	0.06	-1.62	0.116
		tr^2	0.03	0.05	0.59	0.563
Remodeps	自动化 (R^2_{Adj} = 0.026)	tr	-1.65	3.14	-0.52	0.604
		tr^2	-2.13	2.50	-0.85	0.401
	交接 (R^2_{Adj} = 0.017)	tr	0.02	0.12	0.14	0.893
		tr^2	-0.07	0.13	-0.53	0.602
	手动 (R^2_{Adj} = 0.033)	tr	-0.12	0.17	-0.71	0.483
		tr^2	-0.13	0.13	-0.95	0.352
	接管 (R^2_{Adj} = 0.013)	tr	0.01	0.09	0.11	0.914
		tr^2	-0.03	0.07	-0.48	0.638
Car Mirror	自动化 (R^2_{Adj} = 0.179)	tr	0.24	0.10	2.41	**0.023**
		tr^2	0.07	0.08	0.86	0.398

手动 ($R^2_{Adj} = 0.051$)	tr	-5.14	5.78	-0.89	0.386
	tr^2	-4.41	5.46	-0.81	0.430

注：“β”和“标准误 β”分别指标准化回归系数和其标准误。

讨论与结论

本研究围绕两个主要研究问题展开，旨在加深我们对不同驾驶模式下认知需求的理解，并探讨其对自动驾驶车辆人机界面设计的启示。第一个问题考察了在四种不同驾驶模式下，眼动追踪测得的注意力如何在与技术因素和环境因素相关的不同兴趣区之间变化：自动化、交接、手动和接管。研究结果支持了第一项假设，即注意力会因驾驶模式不同而在各兴趣区之间显著变化。例如，在手动模式下，参与者始终将更多注意力分配给环境因素，这与主动驾驶的较高认知需求要求持续关注环境这一假设相符，但注意力转移并没有预期的那么动态。这与 Pipkorn 等人（2024年）的研究结果一致：反复接收到接管请求（TOR）并不会影响手动驾驶期间对环境的注意力。另一方面，在自动化模式下，正如假设所预期的那样，参与者对平板电脑等技术因素的注视时长保持稳定，这反映了较低的认知需求以及对自动化系统的一贯依赖。Guo 等人（2024年）的研究进一步支持了这一发现，该研究指出，对平板电脑的注意力主要与评估是否有必要接管有关。在交接模式下，参与者如预期般在技术因素与环境因素之间动态转移注意力，这反映了车辆控制权逐步从车辆转交给驾驶员的过程。与假设相符，接管模式表现出最动态的注意力转移，参与者迅速在各兴趣区之间重新分配注意力，以重新掌控车辆。Merat 等人（2014年）也发现，接管过程中的注意力存在很大变异，尤其是在控制权转换出乎意料或由干扰因素触发时。这种注意力变异会导致视觉注意力和驾驶控制稳定得更慢，凸显了驾驶员在从自动化控制突然转为手动控制时，重新建立情境意识所面临的挑战。

第二个问题考察了对自动化的信任如何影响四种驾驶模式下对环境因素和技术因素的注意力分配。信任显著影响注视时长、注视次数和首次注视时间，尤其是在平板电脑相关兴趣区中。正如假设所预期，且与既往研究（Demir 等人，2021年；N. Tenhundfeld 等人，2022年；N. L. Tenhundfeld 等人，2019年）一致，信任的二次效应揭示了这种关系具有非线性特征，信任水平越高，影响越显著。结果证实，随着对自动化的信任增加，参与者在自动化、交接和接管模式下对速度计和中央后视镜等监控相关兴趣区的注意力会减少。另一方面，信任度提高会使参与者更快开始关注平板电脑。这些发现表明，随着信任增加，参与者的注意力会从监控相关任务转向平板电脑相关任务或次要任务。这一模式与 Hergeth 等人（2016年）此前的研究发现一致；他们同样观察到，对自动化系统信任度较高的参与者较少监控系统。在交接模式和接管模式下，较高的信任度与更短的次要任务首次注视时间相关，这表明参与者对管理车辆控制权转换更有信心。

眼动追踪指标

注视时长衡量参与者的视线停留在特定兴趣区内的总时间，而注视次数则记录视线转向这些区域的频率。结果显示，注视时长和注视次数呈现出相似的模式，因为两者都能揭示参与者如何在不同兴趣区之间分配视觉注意力，这与 Liang 等人（2021）的既有研究结果一致。

对于环境因素，手动模式下的注视时长随时间显著变化，表明注意力随时间逐渐增强。这种注意力的增强可能源于维持情境意识的需要，正如注意力—情境意识模型（Bellenkes 等人，1997）所指出的，该模型认为情境意识会引导注意力分配。较高水平的注意力有助于保持良好的情境意识。相比之下，自动化模式下的驾驶员随着时间推移，监视道路的频率往往降低，对驾驶环境分配的注意力也减少。在接管模式下，

随着时间推移，驾驶员对环境因素的注意力出现波动并有所增强，这与 Gold 等人（2013）的研究结果一致：驾驶员从自动化模式切换过来时，需要额外的时间来恢复情境意识，从而能够更专注于驾驶环境。

对于速度表因素，也观察到了类似的模式。在接管模式下，注视时长和注视次数均随时间显著增加。这表明，参与者重新获得车辆控制权后，会更加关注速度计。可以理解为，驾驶员需要手动控制车速，因此会将更多注意力分配给速度计。Pipkorn 等人（2024）的研究也报告称，在接管模式下，速度计上的注视时长百分比显著增加。这表明，在接管过程中，驾驶员会暂时优先监控速度，而非感知环境，这可能会暂时延迟他们对道路的关注。

首次注视时间。

首次注视时间是指从视觉刺激或场景开始呈现到参与者的注视落在特定感兴趣区域所经过的时间。它反映了这些区域吸引注意力的速度，有助于我们了解四个因素中即时的视觉优先级。对于环境因素，不同模式之间未发现显著差异，表明注意力分配保持一致。对于平板电脑，自动化模式下参与者的注视时间随时间缩短，这可能是因为驾驶的认知需求降低；而手动模式下首次注视时间较长，说明驾驶员的认知负荷有所增加，注意力集中在道路上，没有时间关注平板电脑。这意味着自动化使视觉信息处理更加容易，而手动任务则需要更持续的注意力（Y. Ma 等人，2020）说明视觉注意力与认知注意之间存在此消彼长的关系。这意味着在手动模式下，驾驶员需要投入心理资源来解读与驾驶任务相关的视觉信息。随着认知工作负荷增加，认知注意比视觉注意占用更多资源。

在速度表因素方面，仅自动化模式下观察到显著波动，表明注意力焦点会随任务复杂性而变化；其他模式下注意力则保持稳定，说明视觉需求较低

。在中央后视镜因素方面，自动化模式和手动模式下首次注视时间均出现波动，而手动模式下该时间后来急剧缩短，这可能是由于任务疲劳或注意力分散所致。交接模式和接管模式下则保持稳定，反映出这些情况下的认知需求较低。Winter 等人（2016）发现，在不可靠自动化程度较高时，参与者会感到更加沮丧，这会导致注意力焦点波动、警觉性提高，从而影响他们的注意力。

启示

在自动驾驶三级或更高级别下，驾驶员不再需要监控车辆或道路，因此可以参与非驾驶相关任务（Kim 等人，2021年）。然而，在自动化系统偶尔发生故障时，驾驶员仍需保持警觉，以便接管车辆控制权（Sever 和 Contissa，2024年）。我们的仿真未设置非驾驶相关任务，参与者只需在必要时响应接管请求。对环境因素和平板电脑因素的注意力分配结果，对于解释驾驶员的认知负荷发挥着重要作用。丹尼尔·卡尼曼（Kahneman，1973年）提出了认知资源容量有限理论，认为个体必须耗费认知资源来处理有关外部事件的信息。我们的研究结果显示，自动驾驶期间，驾驶员倾向于对平板电脑因素保持稳定的注意力；接管请求发出时，注意力则会出现波动。我们推测，驾驶员在自动驾驶期间将平板电脑视为稳定因素，而将环境视为动态因素。因此，驾驶员以稳定的水平将认知资源分配给平板电脑，但在需要响应接管请求时，资源分配会动态转变。手动驾驶期间，驾驶员会将更多注意力分配给环境，这反映出处理周围信息所需的认知负荷较高。Wintersberger 等人（2018年）发现，在自然任务边界处发出接管请求，可通过降低认知负荷改善接管表现。由此可以推断，自动驾驶系统应根据驾驶员的参与程度，在最佳时机发出接管请求，以确保平稳过渡、尽量减少注意力的突然转移，并提升整体安全性。接管请求会增加驾驶员的工作负荷，因此显著影响驾驶员注意力的动态变化。多次接管请求提高了驾驶员对

平板电脑操作的接受度，并导致自动驾驶期间驾驶员对平板电脑的注意力下降，这与 Hecht 等人（2020年）先前的研究结果一致。然而，Hecht 等人未发现频繁发出接管请求会对信任产生显著影响，并将此结果解释为：与系统的整体可靠性或参与者对自动化系统的熟悉程度相比，信任对接管操作的敏感度可能较低。此外，Merat 等人（2014年）发现，与可预测的、基于系统的自动化退出相比，自动化因干扰而退出时，驾驶员的视觉注意力更加不稳定。本研究中某些模式下注视次数的波动可能与这种变化有关，这表明控制环境中的不可预测性会影响驾驶员保持视觉注意力稳定的能力。

实践应用

Ulahannan 等人（2020年）的先前研究探讨了自适应人机界面。在充分描述驾驶员的注意模式后，人机界面设计便能利用注意力的动态变化，呈现最恰当的信息。驾驶员对不同感兴趣区域的注意力分配比例各不相同，这表明通过精心设计人机界面布局，有望优化驾驶员的监控任务。具体做法是根据各项信息与驾驶情境的相关性及重要性进行优先级排序。例如，在驾驶负荷较高的情况下，接口可以调整为仅显示最关键的信息，从而减少分心和认知负荷，并提升可用性（Korthauer 等人，2020年）。我们的研究结果表明，驾驶员对环境的注意力较少，而对平板电脑的注意力较多。这意味着应在人机界面平板上增加更多信息和说明，解释车辆正在做什么以及这样做的原因。还可以在人机界面平板上显示车辆后方的交通状况，因为驾驶员往往较少关注中央后视镜。

研究局限性

在长时间手动驾驶期间，驾驶员主要专注于监控道路状况，同时利用剩余的注意力容量处理其他信息，这一点值得关注（Hughes 和 Cole，1986年）。这表明，驾驶员可能会根据任务需求和可用的认知资源，以不同方式分配视觉注意力（Birrell 和 Fowkes，2014年）。然而，我们的研究并未明确考虑

人类剩余视觉这一因素，这可能导致对手动驾驶期间注视行为的分析出现误差。

对于3级自动驾驶车辆，尽管驾驶员大部分时间无需手动控制车辆，但仍须监控道路状况。在这种状态下长时间监控可能导致无聊、单调和疲劳，进而影响注意力和安全性（Coughlin等人（2011））。我们的实验定期让驾驶员进入自动驾驶状态，每次持续数分钟，但未能捕捉长期监控所引发的视觉行为变化。这一遗漏可能限制了研究结果在L3自动驾驶场景中的普适性。

结论

本研究探讨了自动驾驶车辆在不同驾驶模式下的认知需求和注意力动态，重点考察驾驶员如何分配注意力，以及对自动化的信任如何影响这种分配。主要发现包括：

- **注意力分配**：驾驶员会根据驾驶模式以不同方式分配注意力。在手动模式下，驾驶员更关注环境因素；而在自动化模式下，注意力则转向技术因素（例如平板电脑）。在交接和接管过程中，注意力会动态转移，这凸显了驾驶员重新获得控制权时面临的挑战。

- **信任与注意力**：对自动化的信任程度越高，驾驶员对监测任务的注意力越少，而对次要任务（如平板交互）的关注越多。对自动化的信任会影响驾驶员在控制权转换期间的响应速度。

未来方向

我们将探索整合生理测量（例如心率变异性、脑电图），将其作为补充指标来评估驾驶员的认知工作负荷。这些测量有助于更全面地了解驾驶员在

自动驾驶过程中的生理和心理状态，使研究人员能够实时评估认知工作负荷，并开发更完善的自适应系统。

此外，注意力有时被视为与信息加工相关的认知负荷。当认知资源有限时，唤醒水平决定可用认知资源的数量。不同个体的唤醒水平各不相同，并受认知能力影响；唤醒水平越高，可用的认知资源就越多。唤醒是指驾驶员对刺激的反应性，可以通过研究其与自动驾驶车辆接管表现之间的关系来加以考察。了解唤醒水平如何影响驾驶员在接管事件中重新掌控车辆的能力，有助于设计干预策略，优化驾驶员的准备状态并改善接管结果。这也有助于设计自适应警报系统，帮助驾驶员维持最佳唤醒水平，确保从自动化平稳过渡到手动控制。

最后，开展纵向研究，追踪随着驾驶员接触自动化系统的时间增加，其信任和注意模式如何随时间演变，将具有重要价值。此类研究可以揭示驾驶员对自动驾驶的熟悉程度如何影响其认知工作负荷、信任水平和注意力分配，并最终为设计能够长期更好地支持驾驶员参与和安全的系统提供依据。

致谢

待定：如有，请提供

参考文献

Banks, V. A., Plant, K. L., & Stanton, N. A.（2018）。驾驶员失误还是设计者失误：运用知觉循环模型探究2016年5月7日特斯拉致命事故的相关情形。《安全科学》，*108*，278–285。https://doi.org/10.1016/j.ssci.2017.12.023 Bates, D., Maechler, M., Bolker [aut, B., cre, Walker, S., Christensen, R. H. B., Singmann, H., Dai, B., Scheipl, F., Grothendieck, G., Green, P., Fox, J., Bauer, A., simulate.formula), P. N. K.（共同版权归属者，Tanaka, E., & Jagan, M.（2024）。*lme4*：采用*"Eigen"*和*S4*的线性混合效应模型（版本1.1-35.5）[计算机软件]。https://cran.r-project.org/web/packages/lme4/index.html

Bellenkes, A. H., Wickens, C. D., & Kramer, A. F.（1997）。视觉扫描与飞行员专业能力：注意灵活性和心理模型发展的作用。《航空、航天与环境医学》，*68*（7），569–579。Birrell, S. A., & Fowkes, M.（2014）。使用车载智能驾驶辅助系统时的注视行为：一项真实道路驾驶研究。《交通研究*F*辑：交通心理学与行为》，*22*，113–125。https://doi.org/10.1016/j.trf.2013.11.003 Brainard, J.（2018）。新闻速览。《科学》，*359*（6382），1310–1312。https://doi.org/10.1126/science.359.6382.1310 Brown, R. D., & Galster, S.（无日期）。可靠与不可靠自动化对动态飞行任务中心理工作负荷、情境意识、信任和信心主观测量的影响。年度会议。Canellas, M., & Haga, R.（2020）。任何等级都不安全：美国国家公路交通安全管理局的自动化等级是自动驾驶车辆的责任风险（SSRN学术论文3567225）。社会科学研究网络。https://papers.ssrn.com/abstract=3567225 Clements, L. M., & Kockelman, K. M.（2017）。自动驾驶车辆的经济影响。《交通研究记录》，*2606*，106–114。https://doi.org/10.3141/2606-14 Cohen, J.（1988）。行为科学的统计功效分析。L. Erlbaum Associates。Coughlin, J. F., Reimer, B., & Mehler, B.（2011）。监控、管理并促进驾驶员安全与福祉。《*IEEE*普适计算》，*10*（3），14–21。IEEE普适计算。https://doi.org/10.1109/MPRV.2011.54 Demir, M., McNeese, N. J., Gorman, J. C., Cooke, N. J., Myers, C. W., & Grimm, D. A.（2021）。人机自主协作中的队友信任与交互动态探索。《*IEEE*人机系统汇刊》，*51*（6），696–705。IEEE人机系统汇刊。https://doi.org/10.1109/THMS.2021.3115058 Faul, F., Erdfelder, E., Lang, A.-G., & Buchner, A.（2007）。G*Power 3：一款适用于社会科学、行为科学和生物医学科学的灵活统计功效分析程序。《行为研究方法》，*39*（2），175–191。https://doi.org/10.3758/BF03193146 Gold, C., Damböck, D., Lorenz, L., & Bengler, K.（2013）。“接管！”驾驶员需要多久才能重新进入控制环？人因与工效学会年会论文集，*57*（1），1938–1942。https://doi.org/10.1177/1541931213571433 Guo, L., Wang, X., Xu, L., & Guan, L.（2024）。基于认知计算模型对两阶段接管系统中的注意力分配和接管表现建模：考量多次监控请求的作用。《人体工学》，*0*（0），1–20。https://doi.org/10.1080/00140139.2024.2340671 Hecht, T., Kratzert, S., & Bengler, K.（2020）。预测型人机界面和不同转换频率对城市自动驾驶期间接受度、工作负荷、可用性和注视行为的影响。《*Information*》，*11*（2），文章2。https://doi.org/10.3390/info11020073 Hergeth, S., Lorenz, L., Vilimek, R., & Krems, J. F.（2016）。保持警觉：高度自动化驾驶期间以注视行为衡量自动化信任。《人因》，*58*（3），509–519。https://doi.org/10.1177/0018720815625744 Huff, E. W., DellaMaria, N., Posadas, B., & Brinkley, J.（2019）。我是否太老而不适合开车？老年人对自动驾驶汽车的看法。第*21*届国际会议论文集

*ACM SIGACCESS*计算机与无障碍会议, 500–509. https://doi.org/10.1145/3308561.3353801 Hughes, P. K., & Cole, B. L. (1986). 驾驶时什么会吸引注意力？《人体工学》, *29*(3), 377–391. https://doi.org/10.1080/00140138608968272 Ju, K., Lin, L., Chu, H., Cheng, L.-L., & Xu, C. (2020). 广义线性混合模型的拉普拉斯近似、惩罚拟似然和自适应高斯–埃尔米特求积：针对稀疏数据二元结局的荟萃分析。《*BMC*医学研究方法学》, *20*(1), 152. https://doi.org/10.1186/s12874-020-01035-6 Kahneman, D. (1973). 《注意与努力》. Prentice-Hall公司. Kim, S., van Egmond, R., & Happee, R. (2021). 用户界面对接管表现的影响：实证证据综述。《*Information*》, *12*(4), 第4篇文章. https://doi.org/10.3390/info12040162 Korthauer, A., Guenther, C., Hinrichs, A., Ren, W., & Yang, Y. (2020). 在城市中观察车辆驾驶：用于自动驾驶的增强现实车内人机界面。第*22*届人机交互与移动设备及服务国际会议, 1–5. https://doi.org/10.1145/3406324.3425895 Liang, N., Yang, J., Yu, D., Prakah-Asante, K. O., Curry, R., Blommer, M., Swaminathan, R., & Pitts, B. J. (2021). 利用眼动追踪探究接管前视觉参与对自动驾驶期间情境意识的影响。《事故分析与预防》, *157*, 106143. https://doi.org/10.1016/j.aap.2021.106143 Llaneras, R. E., Salinger, J., & Green, C. A. (2013). 能力受限的自动驾驶系统相关人为因素问题：驾驶员对前方道路的视觉注意力分配。驾驶评估会议, *7*(2013), 第2013篇文章. https://doi.org/10.17077/drivingassessment.1472 Ma, X., Yu, W., Zhao, C., Wang, C., Zhou, W., Zhao, G., Ma, M., Wang, W., Yang, L., Mu, R., Wang, H., & Li, J. (2023). 高速公路自动驾驶的法律决策。《*IEEE*智能车辆汇刊》, 1–14. IEEE智能车辆汇刊. https://doi.org/10.1109/TIV.2023.3318214 Ma, Y., Qi, S., Zhang, Y., Lian, G., Lu, W., & Chan, C.-Y. (2020). 不同认知工作负荷下驾驶员的视觉注意力特征：一项道路驾驶行为研究。《国际环境研究与公共卫生杂志》, *17*(15), 第15篇文章. https://doi.org/10.3390/ijerph17155366 Martinez-Conde, S., Macknik, S. L., & Hubel, D. H. (2004). 注视性眼动在视觉感知中的作用。《自然评论：神经科学》, *5*(3), 229–240. https://doi.org/10.1038/nrn1348 McMains, S. A., & Kastner, S. (2009). 视觉注意。在 M. D. Binder, N. Hirokawa, & U. Windhorst (编), 《神经科学百科全书》 (第4296–4302页). 施普林格. https://doi.org/10.1007/978-3-540-29678-2_6344 Merat, N., Jamson, A. H., Lai, F. C. H., Daly, M., & Carsten, O. M. J. (2014). 转向手动驾驶：驾驶员从高度自动化车辆恢复控制时的行为。《交通研究*F*辑：交通心理学与行为》, *27*, 274–282. https://doi.org/10.1016/j.trf.2014.09.005 Mesquita, D., Maciel, G., Antonialli, F., & Rezende, D. (2023). 自动驾驶车辆与残疾人：对相关文献的科学计量与整合分析。《科学计量研究杂志》, *11*, 332–343. https://doi.org/10.5530/jscires.11.3.36

Meyer [aut, D., cre, Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., C++-code), C.-C. C. (libsvm, & C++-code), C.-C. L. (libsvm. (2023). *e1071*：统计系概率论组（原名：*E1071*）的杂项函数，维也纳工业大学（版本1.7-13）[计算机软件]。https://CRAN.R-project.org/package=e1071 Nelder, J. A., & Wedderburn, R. W. M. (1972). 广义线性模型。皇家统计学会期刊：*A*辑（综合）, *135*(3), 370–384. https://doi.org/10.2307/2344614 Peng, Q., & Iwaki, S. (2020). 高度自动化驾驶接管任务中年轻与年长驾驶员的视觉注意力。载于 Q. Gao & J. Zhou (编), 老年人口的信息技术人因：技术、设计与用户体验（第210–221页）。施普林格国际出版公司. https://doi.org/10.1007/978-3-030-50252-2_16 Pipkorn, L., Dozza, M., & Tivesten, E. (2024). 在公共道路自动驾驶期间，接管请求前后驾驶员的视觉注意力。《人因》, *66*(2), 336–347. https://doi.org/10.1177/00187208221093863 Powell, M. J. D. (2009). 用于无导数有界约束优化的*BOBYQA*算法（NA2009/06；第26–46页）。剑桥大学. http://bison.ihep.su/~kachaev/books/Powell/NA2009_06_bobyqa_bound_constrained.pdf Prakken, H. (2017). 关于使自动驾驶车辆遵守交通法规的问题。人工智能与法律, *25*(3), 341–363. https://doi.org/10.1007/s10506-017- 9210-0 Robinson, D., Hayes, A., & Couch, S. (2014). *broom*：将统计对象转换为整洁小表（第1.0.7版）数据集]。https://doi.org/10.32614/CRAN.package.broom Schartmüller, C., Weigl, K., Löcken, A., Wintersberger, P., Steinhauser, M., & Riener, A. (2021). 高效非驾驶相关任务显示界面：视觉行为及其对有条件自动化驾驶的影响。多模态技术与交互, *5*(4), 第4篇文章. https://doi.org/10.3390/mti5040021 Sever, T., & Contissa, G. (2024). 自动驾驶法规——现状如何？交通研究跨学科视角, *24*, 101033. https://doi.org/10.1016/j.trip.2024.101033 *stats*程序包—*R*文档。（无日期）。检索于2024年10月2日，网址：https://rdocumentation.org/packages/stats/versions/3.6.2 Tabachnick, L. S., & Fidell, B. G. (2006). 多元统计学的应用. Allyn & Bacon. Tenhundfeld, N., Demir, M., & de Visser, E. (2022). “现实世界”中的自动化信任评估：从业者使用的新型自动化信任测量技术要求。认知工程与决策期刊, *16*(2), 101–118. https://doi.org/10.1177/15553434221096261 Tenhundfeld, N. L., de Visser, E. J., Haring, K. S., Ries, A. J., Finomore, V. S., & Tossell, C. C. (2019). 通过熟悉特斯拉Model X的自动泊车功能来校准对自动化的信任。认知工程与决策期刊, *13*(4), 279–294. https://doi.org/10.1177/1555343419869083 Ulahannan, A., Jennings, P., Oliveira, L., & Birrell, S. (2020). 设计自适应界面：利用眼动追踪对部分自动化车辆中信息使用随时间的变化进行分类。*IEEE Access*, *8*, 16865–16875. IEEE Access. https://doi.org/10.1109/ACCESS.2020.2966928

Wang, L., Zhong, H., Ma, W., Abdel-Aty, M. 与 Park, J.（2020年）。网联车辆和自动驾驶车辆技术能够预防多少起碰撞事故：一项荟萃分析。《事故分析与预防》，*136*，105299。https://doi.org/10.1016/j.aap.2019.105299 Wickham, H., François, R., Henry, L., Müller, K. 与 Vaughan, D.（2014年）。*dplyr*：数据操作语法（第 1.1.4 版）[数据集]。https://doi.org/10.32614/CRAN.package.dplyr Winter, J. C. F. D., Stanton, N. a., Price, J. s. 与 Mistry, H.（2016年）。不同程度的不可靠自动化驾驶对自我报告的工作负荷和次要任务表现的影响。《国际车辆设计杂志》，*70*(4)，297–324。https://doi.org/10.1504/IJVD.2016.076736 Wintersberger, P., Riener, A., Schartmüller, C., Frison, A.-K. 与 Weigl, K.（2018年）。让我在接管之前完成：面向高度自动化车辆的注意力感知设备集成。第十届国际汽车用户界面与交互式车辆应用会议论文集，53–65。https://doi.org/10.1145/3239060.3239085 Zihui, G. U. O., Weiwei, G. U. O. 与 Jiyuan, T. a. N.（2022年）。接管自动驾驶车辆的驾驶员眼动特征与行为分析。《中国安全生产科学技术》，*32*(1)，65。https://doi.org/10.16265/j.cnki.issn1003-3033.2022.01.009