通过分析双向驾驶特征对高级驾驶辅助系统的短期和长期驾驶行为进行分类

Mudas 博士 ser Seraj，阿尔伯塔大学土木与环境工程系 ta

摘要—深入了解个体的驾驶行为和习惯，对交通运行、安全和能源管理至关重要。联网车辆（CV）技术旨在解决这三个方面的问题，因此，识别驾驶模式是为联网车辆设计个性化高级驾驶辅助系统（ADAS）的必要环节。本研究旨在满足这一需求，采用独特方法分析驾驶员的双向（即纵向和横向）控制特征，并通过简单的基于规则的分类流程对其驾驶行为和习惯进行分组。我们分析了来自密歇根州安娜堡真实世界联网车辆测试平台 Safety Pilot Model Deployment 的高分辨率驾驶数据，以识别高速公路、主干道和匝道等不同道路类型上的多样化驾驶行为。利用加加速度、前车车头时距和横摆角速度这三种车辆特征，在短期分类中将驾驶特征分为两组（安全驾驶和敌意驾驶），并将**驾驶员的**驾驶习惯归为三类（平静型驾驶员、理性型驾驶员和激进型驾驶员）。我们在未分类的数据集上测试了所提出的分类模型，以验证模型对超速和剧烈加速的判别能力。通过所提出的方法，我们成功识别出 86.**31 ± 9**.84% 的超速实例和 87.**92 ± 10**.04% 的急剧加速实例。此外，本研究进一步开发了一种高级驾驶辅助系统界面，可**与驾驶员实时**交互，将有关驾驶行为和习惯的信息转化为反馈并提供给个体驾驶员。我们提出了一种自适应且灵活的分类方法，用于从自然驾驶数据中识别短期和长期驾驶行为，进而识别并最终向驾驶员传达不良驾驶行为模式。

索引词— 高级驾驶辅助系统、激进驾驶、联网车辆、驾驶行为、安全驾驶。

I. Introduction

T对个体驾驶行为的分类在识别危险驾驶模式方面发挥了至关重要的作用，

车辆燃料消耗优化、个性化车辆控制系统设计以及电源管理系统设计。基于网联自动驾驶车辆（CAV）的交通运输系统逐步扩展并不断融合，这进一步凸显了理解驾驶员个体行为的必要性。如今，驾驶行为的识别与分类被视为正确设计和评估高级驾驶辅助系统（ADAS）以及提升网联自动驾驶汽车交通安全的关键[1]–[6]。然而，对真实道路驾驶情况的观察表明，驾驶行为是驾驶员针对外生环境（包括道路类型、周边交通以及驾驶员的身体和心理状态等因素）所做即时决策的结果。鉴于这些即时驾驶决策是多种因素复杂融合的产物，本研究旨在通过分析双向控制和驾驶员决策，动态识别不同类型的驾驶行为。我们的首要目标是开发一种灵活而准确的分类过程，以识别驾驶行为及个别驾驶员的驾驶习惯。

驾驶行为是一个复杂的概念，而人们通常将“驾驶行为”与“驾驶习惯/风格”联系起来，这使其定义和识别更加困难。根据相关文献对这些术语的理解，它们之间的关联有助于厘清不同的分类层次。驾驶行为仅关注驾驶员的即时决策，并与驾驶员所经历的驾驶条件相关。因此，准确理解环境有助于更深入地认识驾驶行为 [7]–[9]。此外，由于习惯性影响发生变化，同一驾驶员在不同时间面对相同驾驶条件时，决策也可能有所不同。另一方面，个体驾驶员偏好的驾驶行为会随着时间推移不断累积，并逐渐形成驾驶习惯或驾驶风格 [1], [10]–[13]。驾驶行为会随外部因素变化，且往往难以预测；相比之下，驾驶习惯则会在较长时期内稳步改变。区分驾驶行为与驾驶习惯这两个概念十分必要，以便区分任何一次行程中观察到的驾驶行为，以及从累积的驾驶历史中逐渐形成的驾驶习惯。

本文提出一种简化方法，通过分析驾驶员在不同道路上的加加速度、横摆角速度和前向车头时距曲线，动态识别驾驶行为。加加速度、横摆角速度和前向车头时距曲线被视为反映驾驶员纵向和横向控制决策的指标。借助这些指标，我们旨在对任意给定驾驶员的行为进行明确分类。为此，我们希望从两个方面为驾驶行为研究作出贡献：1），通过分析用于分类的双向驾驶特征，我们能够生成更准确的表征，从而更好地识别危险驾驶行为；2），我们能够建立并区分两种不同的行为

用于分类单次行程行为和累积驾驶历史。此外，本文介绍了我们设计的一种便捷、统一的高级驾驶辅助系统界面，可实时向驾驶员警示不安全驾驶行为。该界面还可让驾驶员和监管机构根据累积的过往驾驶行为，查看驾驶习惯。

对网联自动驾驶汽车日益增长的了解需求，凸显了开展驾驶行为综合研究的必要性。交通管理部门若采用基于本研究结果提出的方法，便可借助这项前景广阔的技术提供高效的高级驾驶辅助系统应用，从而提升交通通行效率与安全性。因此，本研究的主要贡献如下：

i. 本研究的首项贡献是结合纵向和横向驾驶特征，从真实世界驾驶数据中检测不良驾驶模式。ii. 本研究的另一项贡献是捕捉驾驶员即时反应（即短期行为）随驾驶习惯（即长期行为）演变的过程。iii. 最后，所建立的分类模型旨在提出一种简单而信息丰富的高级驾驶辅助系统，用于向驾驶员传达检测到的行为信息。

为更好地呈现研究结果，本文结构安排如下：第二节总结驾驶员行为分类领域的主要文献，指出当前认知中的不足，并概述本研究将如何弥补这些不足。接下来，第三节将详细介绍所提出的分类方法。随后，第四节评估所提出的方法在识别行为模式时的性能，并介绍拓展当前研究的计划。最后，本文对研究结果进行总结。

II. Literature Review

驾驶行为和习惯的识别长期以来一直受到研究人员的关注，尤其是对于提升道路安全而言。Gibson 和 Crooks [14] 开展了早期的驾驶心理学研究，并得出结论：驾驶主要取决于驾驶员对周围环境的感知。具体而言，安全驾驶取决于驾驶员的心理安全空间区域。其他研究则确定了不同的物理测量指标，用于捕捉驾驶员在驾驶过程中的感知决策 [15]–[24]。一些具体的驾驶测量指标包括超速和／或急刹车 [25]–[31], 颠簸驾驶 [1], [32]–[34], 跟车过近 [35],[36], 车道选择 [37], [38], 转向角 [29], [35], [38], [39],横向加速度 [26], 以及超车时的超车间隙[40]。这些测量指标涵盖了驾驶的纵向和横向特征，有助于对驾驶行为进行分类。尽管速度和加速度是常用的驾驶行为测量指标，但研究发现，加加速度曲线对安全关键型驾驶行为更为敏感 [1]。就纵向控制而言，与速度、加速度或加加速度曲线相比，决策时间和／或车头间距更能具体反映敌意驾驶 [35]。由于驾驶过程中保持稳定的车头时距是安全驾驶员普遍认可的社会规范，因此，选择较短且不稳定的车头时距，部分原因可能是激进意图。另一方面，横向控制行为通常与转向角、横向加速度或车道选择有关。这些特征的变异增大，可以区分安全与不安全驾驶。纵向和横向驾驶特征在界定驾驶行为方面都发挥作用，但二者的综合影响仍未得到探究。

驾驶行为识别研究的一项主要动机，是开发修正驾驶行为的技术[41]–[47]。近年来，基于联网车辆（CV）的高级驾驶辅助系统通过个性化通信，已应用于驾驶行为修正 [48]–[51]。要设计能够考虑驾驶员需求、可接受性和偏好的高级驾驶辅助系统，必须同时纳入驾驶行为和驾驶习惯进行驾驶员识别[52]。然而，文献中根据收集到的驾驶特征标注驾驶行为的方法差异很大。主要标注技术包括基于规则的方法 [1],[9], [19], [53], [54], 、基于模糊逻辑的方法 [3], [55]–[57], 以及基于机器学习方法的技术 [2], [8], [12], [19], [28], [58],[59]。由于计算简单、稳健且易于解释，许多研究采用基于规则的驾驶行为识别技术。变量集规模较大时，基于规则的方法会产生复杂的分类过程，而这类问题可以通过基于模糊逻辑的方法解决。由于大型多变量数据集日益普及，机器学习方法近来已成为从业者的常用方法。机器学习方法能够利用包含更多变量的大数据识别驾驶模式，但这类标注技术往往结构复杂精细，且结果难以解释。为避免这些缺陷，我们采用少量变量和相对大型的数据集，并探讨了基于规则和基于机器学习的标注技术，以选择一种适用于未标注训练数据的理想技术。尽管本研究选用的数据集乍看之下可能较小，但我们认为其规模足以体现驾驶员驾驶行为的变化，并展示所提出的分类方法。此外，所选数据集包含的行程，其记录数量高于该数据集中其余行程，因此可能涵盖大多数可能的变化。

回顾与驾驶行为识别、辨认和分类相关的文献后，我们注意到，在分类中整合双向控制决策，能够提高精准分类的可能性，因为结合这两类特征可以捕捉到更丰富的多样性，而这些多样性可能会被单维度的基于特征的分类所忽略。本研究的另一项关键贡献，是展示了短期和长期驾驶行为分类中，驾驶行为如何逐渐发展并转变为驾驶习惯。最后，我们设计了一套用户友好的实时警告系统，供驾驶行为界面使用。该系统能够提供长期驾驶习惯信息，也是当前研究未来的拓展方向。

III. 方ETHODOLOGY

本研究尝试对短期和长期驾驶行为进行分类。短期分类反映驾驶员单次行程中的行为，而长期分类则代表驾驶员基于以往驾驶经验形成的驾驶习惯。两种驾驶行为分类均在整个分类时段内采用固定时长（5秒）的滑动窗口。短期驾驶行为分为以下两个不同类别：安全驾驶和敌意驾驶：

- 安全驾驶：在一次行程中，驾驶员能够预判周围道路环境，并做出沉着的控制决策时所产生的驾驶实例。
- 敌意驾驶：在一次行程中，驾驶员未能评估周围道路环境，而是通过采取冲动且危险的控制决策进行补偿时所产生的驾驶实例。

从驾驶历史中以往行程所收集的短期分类的持续累积，有助于进行长期驾驶员行为分类。在这一分类过程中，驾驶员被分为三类：平静型驾驶员、理性型驾驶员和激进型驾驶员。

- 平静型驾驶员：在分析期间，其累计攻击性驾驶实例所占比例低于规定的下限阈值
- 理性型驾驶员：在分析期间，其累计攻击性驾驶实例所占比例处于下限阈值与上限阈值之间
- 激进型驾驶员：在分析期间，其敌意驾驶实例累计占比高于上限阈值

A. 数据准备

本研究使用的数据取自 Safety Pilot Model Deployment (SPMD) 项目的[60] 数据库[61]。该项目通过集成安全设备以及弗吉尼亚理工交通研究所[62]开发的基于雷达的数据采集系统，采集了密歇根州安娜堡道路上的真实世界驾驶数据。这些数据通过研究数据交换平台网站[63].获取。63辆配备传感器的车辆用于收集信息这些车辆共采集了13,792次行程的数据，其中包含7,843万个数据点，采样频率为10 Hz。安装在这些联网车辆上的传感器持续采集信息，包括车辆标识、行程标识、GPS经度、GPS纬度、GPS协调世界时、车载制动状态、车载前照灯状态、车载车速、车载加速度、车载转向位置、车载油门位置、车载横摆角速度等。从这个大型数据集中，我们按每次行程可用数据记录数降序排列，选取了排名前550的行程（~4%）用于研究，共计794万条记录（10.12%）。在配备车辆的数据采集系统收集的各类运行数据中，我们选择了三个特征用于驾驶行为分类：加加速度、横摆角速度和前车车头时距。在分析中，这三个特征代表了各位驾驶员采取的纵向和横向控制决策。

作为加速度/减速度的一阶导数和速度的二阶导数，加加速度在驾驶行为分类中比速度或加速度更有效[1]。此外，这一单一特征还纳入了每位驾驶员的纵向和横向决策。本研究的加加速度数据由车辆的数据采集系统（即集成安全设备（ISD））测得，该系统以 10 Hz 的频率记录车载加速度数据。这个主要数据文件包含多个字段，详细记录了车辆位置和速度、基于GPS的数据的保真度指标以及车辆操作数据（转向、油门位置等）。作者从这一大型数据集中提取加速度数据，以计算加加速度数据。

横摆角速度用于衡量车辆的横向运动速率，并表征驾驶员的横向行为。与先前的特征计算不同，我们以相同的频率直接从车辆的 ISD系统获取了这一特征的测量值。前车车头时距的测量值反映了驾驶员的纵向控制决策，因为车辆之间的间距往往决定了跟车行为。我们从作为车辆ISD单元组成部分安装的雷达单元收集了前车车头时距数据。当同一车道内 200 m 范围内有其他车辆时，这些雷达会记录雷达与前方车辆之间的距离。这三个相互补充的特征——加加速度、横摆角速度和前车车头时距——结合起来，能够捕捉驾驶员双向控制的瞬时变化

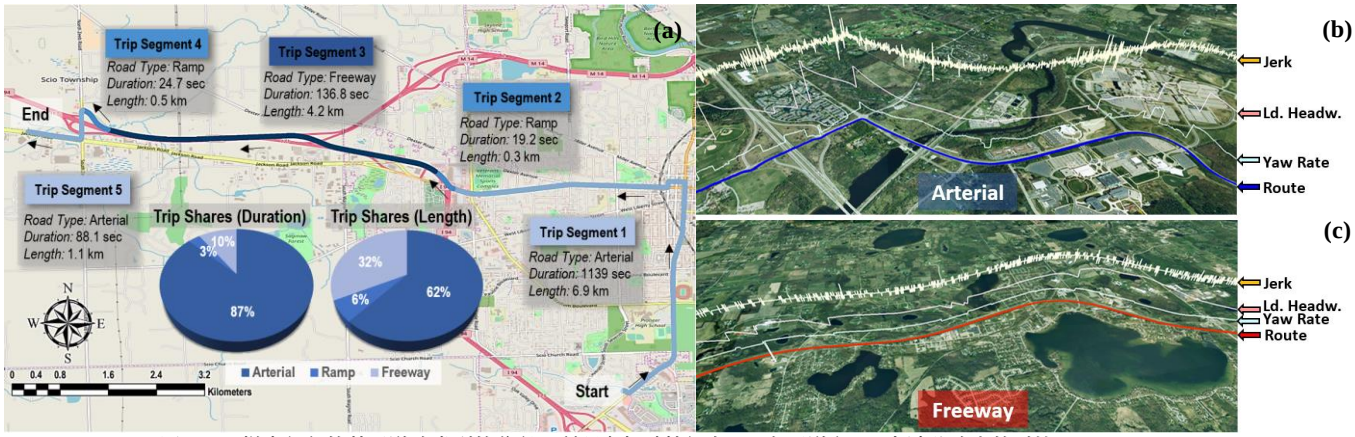

图 1. (a) 样本行程的基于道路类型的分段；所研究驾驶特征在 (b) 主干道和 (c) 高速公路上的对比。

决策，从而有助于实时分类驾驶员行为。

B. 驾驶员行为分类算法

从选定的550个行程中提取了上述用于分类的三个特征。除这三个特征外，数据集还包含车辆标识、行程标识、纬度、经度和时间戳，这些信息用于确定行程路线的地理位置，并根据道路类型对路线进行划分 [图1(a)]。图1(a)展示了数据集中一个样本行程的分段情况。根据行程的经度和纬度信息，将数据点标注在地图上。利用相同的信息，根据行程经过的道路类型（即主干道、匝道和高速公路）将行程划分为不同路段。图1(a)以三种深浅不同的蓝色表示本研究所考虑的三类道路，并展示了不同路段的详细信息。图中的两个饼图分别说明了整个行程中各类道路的行程时长和行程长度所占的比例。基于高速公路与主干道之间的驾驶环境存在显著差异这一假设，我们按道路类型划分行程。由于驾驶行为会直接受到周围环境的影响，采用相同标准对不同道路类型下的驾驶行为进行分类将导致错误的分类。此外，对分类特征的视觉观察也显示，不同道路类别之间存在显著差异[图1(b, c)]。图1(b, c)突出显示了图1(a)所绘制行程中不同道路类型特征之间的差异。主干道上的特征曲线[图1(b)] 显示出的特征值波动幅度大于高速公路上的特征曲线 [图1(c)]。与高速公路相比，主干道上的三个特征均表现出相对更大的变异范围。

为突出驾驶行为的差异，根据 GPS位置（即经度、纬度）将每次行程划分为三种道路类型：高速公路、主干道和匝道。将相同道路类型的特征归为一组，以分类短期和长期驾驶行为。在训练数据集（550 次行程）中，分别有 66.20%（526 万个数据点）、31.76%（252 万个数据点）和 2.04%（16 万个数据点）被标记为高速公路、主干道和匝道。

根据每个时间戳的地理位置按照道路类型对特征进行排序后，绘制了其分布图

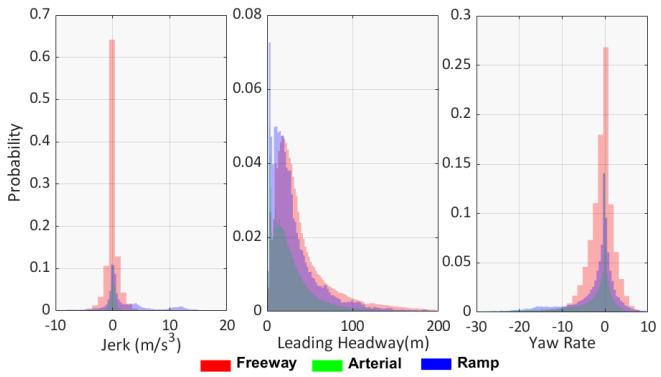

图2. 不同道路类型下所研究特征的分布。

（图2）。我们采用非配对双样本t检验比较了每种道路类型的数据集，以验证不同道路类型之间存在显著特征差异的假设。每一对道路类型（即高速公路与主干道、主干道与匝道、高速公路与匝道）的比较结果均显示，各特征的均值存在显著差异（即p值< 0.0001），置信水平为99%，同时假设所检验样本的方差不齐。

确认不同道路类型之间存在归因差异后，我们计算了三种道路类型下每个特征的绝对均值，并将其存储在数据库中。接下来，我们使用长度为 $t_c = 5$ 秒（50 个数据点）的滑动窗口，计算所有行程中每个特征的标准差。随后，将测得的标准差除以时间窗口内当前道路类型对应的绝对均值，计算变异系数（CoV）（公式 1）。由于 CoV 是衡量相对变异性的指标，因此在识别敌意驾驶行为以进行分类时，采用了每种驾驶特征的这一统计属性。最后，我们将每种道路类型下各特征的 CoV 数据集缩放至 [0 1] 范围（公式 2）。由于所研究特征的绝对值差异显著，作者没有采用这些特征的绝对值，而是使用缩放后的（即标准化后的）变异系数进行分类。

$$\mathrm{CoV_f(t)} = \frac{\mathrm{SD_f(t - t_c,\ t)}}{\bar{\mathrm{f}}_{\mathrm{R}}} \tag{1}$$

$$\mathrm{CoV'_f(t)} = \frac{\mathrm{CoV_f(t) - CoV^{min}_{f,R}}}{\mathrm{CoV^{max}_{f,R} - CoV^{min}_{f,R}}} \tag{2}$$

Here, CoV_f t) = coefficient 特征 f（即加加速度、前车车头时距、横摆角速度）的变异系数在时间 t 的值；$SD_f(t - t_c,\ t)$ = 特征 f 在时间 $t - t_c$ 和 t 之间的标准差（$t_c = 5sec$）；$\bar{f}_R$= 道路类型 R 上特征 f 绝对值的均值；$CoV'_f(t)$= 特征 f 在时间 t 的缩放变异系数；$CoV_{f,\ R}^{min}$ = 当前道路类型 R 上特征 f 的最小变异系数；$CoV_{f,\ R}^{max}$ = 当前道路类型 R 上特征 f 的最大变异系数。

完成缩放并获得未标注特征的变异系数后，我们便可以探索短期驾驶行为的标注方法，并将 K近邻（KNN）、层次聚类和神经网络自组织映射作为可行的划分聚类选项，通过无监督机器学习方法对行为特征进行分类。在这些方法中，有几位研究人员使用 K近邻

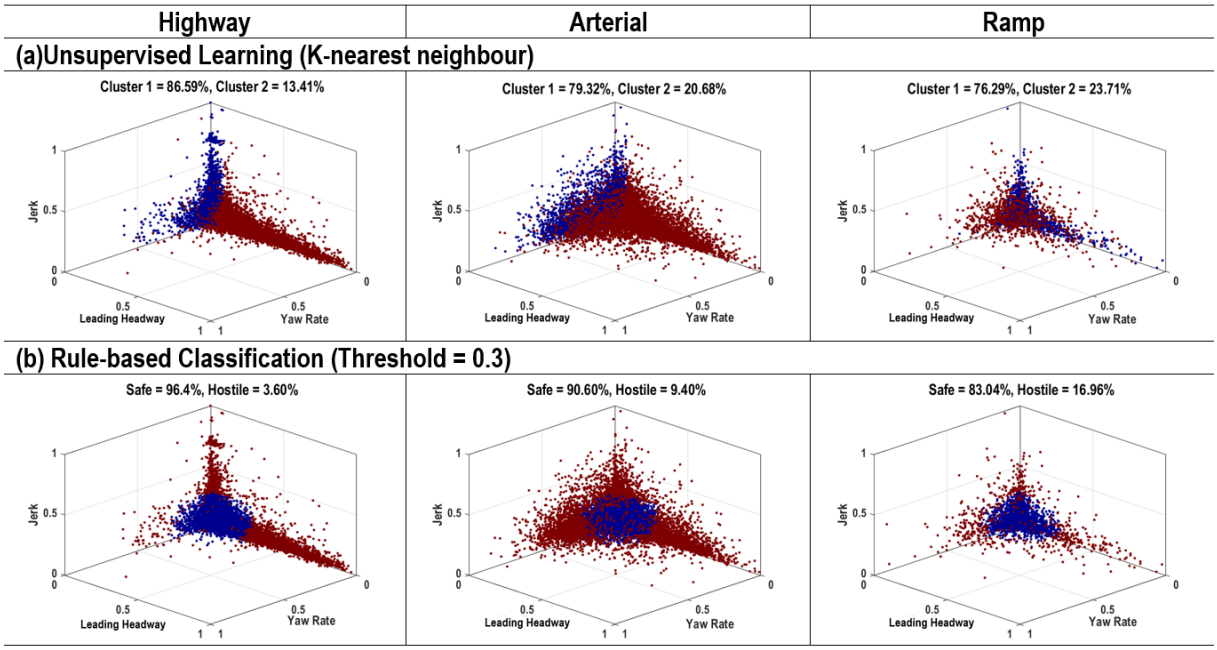

图 3。标注 使用（a）无监督学习和（b）基于规则的分类方法对所研究特征的缩放后的变异系数值进行标注 .

对驾驶行为进行分类 [2], [28]。K近邻处理大型数据集的高效性，使其成为未标注特征数据标注的理想候选方法。然而，K近邻聚类的输出未能提供合理的分类 [图 3(a)]。K近邻产生的簇无法体现两个簇之间的明确差异。增大簇的数量会使分类变得更加复杂，却无法恰当地解释各个簇的特征。此外，针对高速公路和主干道的簇无法在分类过程中涵盖全部三个特征的影响。K近邻对交通特征的不合理划分促使我们考察更为简单的基于规则的分类方法。

采用基于规则的分类流程，我们选择缩放后的变异系数的一个阈值来标记驾驶决策。如果三个特征中的任一特征的缩放后的变异系数值高于该阈值，则该时间窗口内的驾驶行为会被标记为“敌意驾驶”。在标记交通行为的过程中，我们探索了变异系数的不同阈值，以确定阈值的敏感性。结果表明，降低缩放后的变异系数阈值会导致“敌意驾驶”的占比提高。因此，为了保持在较为保守的范围内

表I

短期分类学习器算法

1. 已识别的道路类型及其对应的变异系数，位于时间窗口 $[(t - t_c),\ t]$
2. 一个未标记的训练集，S_u t = $\{(\text{横摆角速度变异系数}_{f=\{jerk,ld.\ headw.,\ 横摆角速度\}}(t)\}_{t=1}^{T}$ 其中，T = 表示训练样本数。
3. 如果变异系数$'_{jerk}(t)$ | 变异系数$_{ld.\ headw.}$，(t) | 变异系数$_{yaw\ rate}$，(t) >阈值，则 驾驶行为$_{short-term}[(t - t_c),\ t]$ = 敌意驾驶

行为识别中，我们选择了一个较小的阈值

表 II 长期分类算法

1. Ave愤怒程度、道路类型特定的敌意驾驶感知 势与受研究驾驶员的总体敌意驾驶百分比
2. 训练数据集中各道路类型的平均敌意驾驶占比 类型及总体行程
3. (a) 特定道路类型分类
   若 %Hostile 驾驶R < 阈值$_{lower}$ × %Hostile 驾驶R 训练
   则驾驶行为$_{long-term}$(R) = 道路类型 'R' 上的平静型驾驶员
   否则如果阈值$_{lower}$ × %Hostile 驾驶R训练 ≤ %Hostile 驾驶R ≤ 阈值$_{upper}$ × %Hostile 驾驶R训练
   则驾驶行为$_{long-term}$(R) = 道路类型 'R' 上的理性型驾驶员
   否则如果 %$_{敌意驾驶R}^{训练}$ > 阈值$_{上限}$ × %$_{敌意驾驶R}^{训练}$
   然后驾驶行为$_{long-term}$(R) = 道路类型 'R' 上的激进型驾驶员
   此处，R = 道路类型（即高速公路、主干道、匝道）。
3. (b) 总体分类
   如果 ∑ %Driving$_R$ × R={freeway,arterial,ramp} %Hostile 驾驶R) < 阈值 ∑ = %$_{较低}$Driving$_{R训练}$ × R {高速公路,主干道,匝道} %Hostile 驾驶R 训练
   然后驾驶行为$_{long-term}$ =平静型驾驶员
   否则，如果阈值$_{lower}$ × ∑$_{R=\{高速公路,主干道,匝道\}}$ %$_{驾驶R}^{训练}$ × %$_{敌意驾驶R}^{训练}$ ≤ ∑ %Driving$_R$ × R={高速公路,主干道,匝道} %Hostile 驾驶R) ≤ 阈值 ∑ = %$_{上}$Driving$_{R训练}$ × R {freeway,arterial,ramp} %Hostile 驾驶R 训练
   然后驾驶行为$_{long-term}$ =理性型驾驶员
   否则，如果 ∑ %Driving$_R$ × R={freeway,arterial,ramp} %Hostile 驾驶R) > 阈值$_u$ ∑ = %$_{pper}$Driving$_{R训练}$ × R {freeway,arterial,ramp} %Hostile 驾驶R 训练
   然后驾驶行为$_{long-term}$ =激进型驾驶员

缩放后的变异系数（0.3）[图3(b)]。完成标记过程后，我们在已标注训练数据上执行了几种监督分类学习方法（即逻辑回归、判别分析、支持向量机和决策树），以确定最佳分类模型。在采用10折交叉验证进行探索的模型中，决策树模型对所有道路类型的训练数据进行正确分类时达到了最高准确率（~100%），因此被用作短期分类器。表I总结了标记训练数据集所涉及的步骤，以便后续进行分类。

虽然用于行为分类的阈值对所有道路类型（即高速公路、主干道、匝道）都相同，但该阈值应用于研究特征的缩放后变异系数值，这些值是通过将不同范围的特征值进行平衡并转换为共同单位得到的。如前文图 2 所示，这些特征的取值范围因道路类别不同而存在显著差异。因此，对缩放后的参数应用相同阈值，会使不同道路类别对应不同的变异系数值。最终，对于特定道路类别上的特定特征，行为分类界限保持不变；而随着道路类型和特征的变化，它又呈现出动态特性。

随后，我们利用“敌意驾驶”在总驾驶实例中所占的特定道路类型占比测量值，对长期驾驶行为进行分类。例如，在总训练数据中，驾车经过主干道时表现出“敌意驾驶”行为的样本占 9.40%。为了识别特定驾驶员在主干道上的长期驾驶行为，我们考虑已累积的分类驾驶历史（即安全、敌意），并将主干道上累积敌意驾驶判定的占比与训练数据中的“敌意驾驶”占比进行比较。在此分析中，我们将 0.5 视为下限阈值、1.0 视为上限阈值，据此将长期驾驶行为分为平静、理性和激进三类。如果某驾驶员在主干道上的累积“敌意驾驶”占比低于 4.7%（= 0.5 × 9.4%），则将其归类为主干道上的“平静型驾驶员”。另一方面，如果同一占比高于 9.4%，则将该驾驶员归类为主干道上的“激进型驾驶员”。我们采用类似流程，对驾驶员在其他道路类型上的长期行为以及整体出行历史进行分类。表 II 描述了基于道路类型和整体驾驶历史进行长期行为分类的流程。

为进一步阐明长期行为分类过程，下面通过一个假设情境进行说明。假设某位驾驶员共完成了 30 次行程，并按照短期行为分类过程收集、缩放和存储了三项特征值（即加加速度、横摆角速度、前车车头时距）。随后，使用指定的三种道路类型（即高速公路、主干道、匝道）以及全部行程，测量这 30 次行程的平均敌意驾驶比例，以进行长期行为分类。通过分析这位道路使用者的 30 次行程驾驶历史，我们设想，其在高速公路、主干道和匝道上的平均敌意驾驶行为分别占总驾驶时间的 5.17%、4.27% 和 11.84%。在评估全部行程的驾驶行为时，我们会发现所有行程的平均敌意驾驶占比为 2.95%。从驾驶员的历史记录中获得这些数值后，会将其与训练数据集中存储的特定道路类型及总体平均敌意驾驶占比进行比较。训练数据集中的平均敌意驾驶占比在高速公路、主干道、匝道和全部行程中分别为 3.60%、9.40%、16.96% 和 5.79%。计算完成后，这些数值将通过比较驾驶员的敌意驾驶占比与训练数据集中的敌意驾驶占比，作为特定道路类型分类的依据。在本例中，发现该驾驶员在高速公路上的敌意驾驶占比（5.14%）超过了训练数据中高速公路上的敌意驾驶占比（3.60%）的 1.0 ×

因此，根据该驾驶员 30 次行程的驾驶历史，其长期行为被分类为高速公路上的“激进型驾驶员”。同样，按特定道路类型进行长期分类，会将该驾驶员在主干道、匝道及所有行程中的行为分别归类为“平静型驾驶员”[4. 0 5 × 9 40], [0 5 × 16 96 < 11 84 < 27 <% . . %“理性型驾驶员”. . % . %

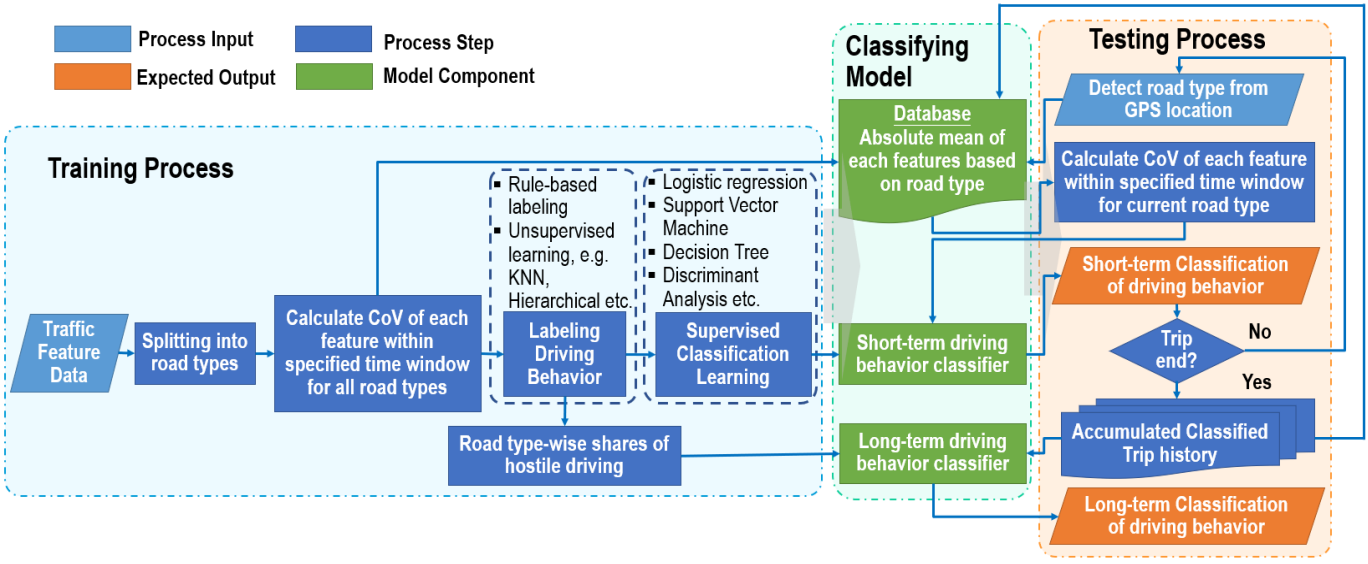

图4. 驾驶行为分类算法流程图。



图 5. 一次测试行程的短期驾驶行为分类。

1 0 × 16 96 [0 5 × 5 79 < . . %]
2 95 < 1 0 × 5 79], **4**

以及“理性型驾驶员” . . % . % . . %。图中以流程图的形式展示了所实现的分类算法，以详细说明行为分类过程的进展。

IV. Performance Evaluation

利用训练数据生成的分类模型被应用于“测试行程”，以对驾驶行为进行分类。为了符合“测试行程”的定义，我们从数据库中其余的 110 次行程（不包括用于训练的行程）中，选取数据点数量最多的行程（占训练行程的 20%）；这表明这些行程较长，因此预计包含最多样的行为变化。我们采用相同的 5 秒时间窗口（50 个数据点）来重塑分类特征数据。所提出的分类模型对选定的测试行程进行了短期和长期分类。测试行程中，整段行程的攻击性驾驶实例占比在 1.45% 至 18.53% 之间，平均为 5.67%。图 5 展示了一个测试行程样本的整段行程短期分类结果，其中显示了驾驶道路类型、分类特征的变异系数曲线，以及一次时长为 28 分 23.7 秒（341 个时间戳）的行程中的敌意驾驶实例。全部 110 次行程均已分类；短期驾驶行为分类器针对特定道路类型和整段行程采用了相同的处理流程。

尽管分类模型通过纵向和横向特征识别确定了敌意驾驶行为，但我们尚未检验所识别行为的准确性。为此，我们将每次行程的速度和加速度曲线作为敌意行为的显式识别指标。随后，测量预先设定时间窗口内的平均速度，并将其与相应道路类型的限速进行比较。之后，将平均速度超过限速 10 英里/小时的时间戳标记为“敌意驾驶”实例。因此，这种分类方法仅使用驾驶员的超速行为。多项研究将超速选作识别异常驾驶实例的控制特征 [64]–[66]。第二个流程测量了根据急剧加速度变化确定的分类结果中各时间窗口的加速度范围。加速度范围高于 2.5 m/s^2 的时间戳被标记为“敌意驾驶”行为。此前已有多项研究采用类似方法，通过加速度变化识别独特的驾驶事件 [25], [28], [65], [67]–[69]。我们将两种显式分类指标（即按超速分类、按急剧加速度变化分类）与模型分类结果（即短期驾驶行为分类）进行比较，以评估所提出方法识别行为差异的能力。图 6 展示了使用上述方法对一个样本行程进行行为分类的结果。

对于样本行程，将所生成分类模型的短期行为分类与基于超速的分类进行比较，准确率为87%。采用基于急剧加速的分类进行类似比较，行为识别的准确率为84%。另一项超速识别分析表明，对于样本行程，所提出的短期分类模型在23个超速实例中准确识别出19个为敌意驾驶行为。同样，与基于急剧加速度变化的分类相比，短期分类识别出25个实例中的17个。在全部110次测试行程中，与基于超速的分类相比，识别准确率平均为86.31%，标准差为9.84%。同样，与基于急剧加速度变化的分类相比，平均准确率为87.92%，标准差为10.04%。

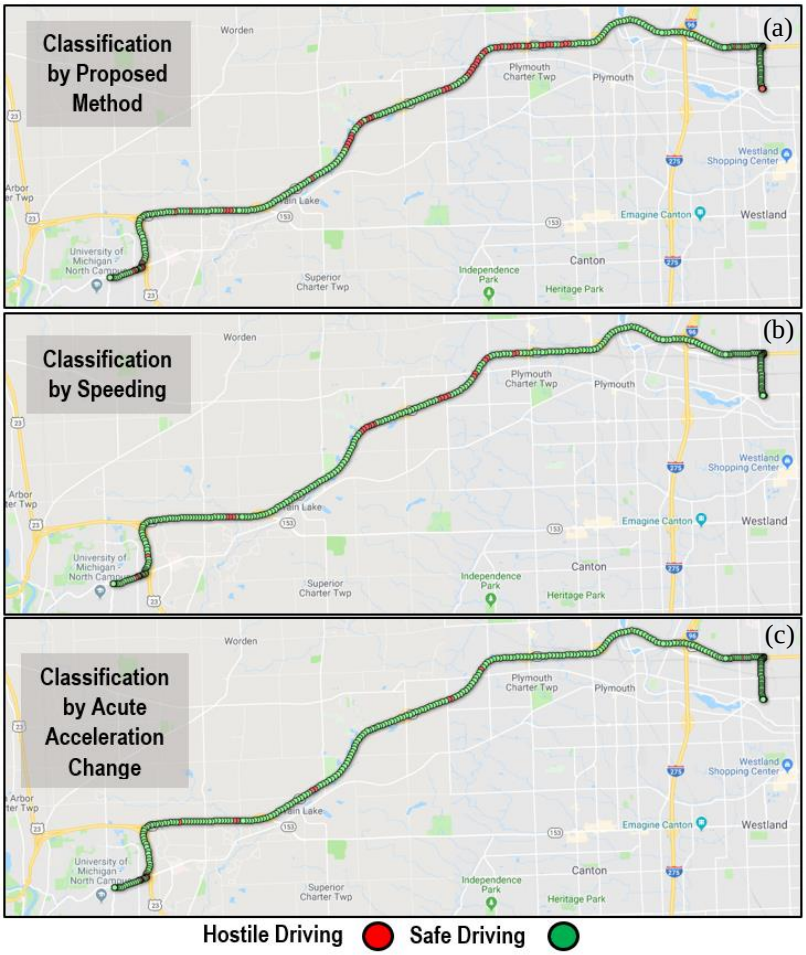

图 6. (a) 所提出的分类方法与 (b) 基于超速的分类、(c) 基于急剧加速度变化的分类的评估。

基于多个驾驶特征的短期分类进一步与 Murphey 等人 [1] 提出的分类过程进行了比较，以展示所提方法在识别极端驾驶行为方面的能力。Murphey 等人 [1] 提出了一种基于单一特征（即加加速度）的驾驶行为分类方法，将其分为三组（即平静、正常、激进）。各组的划分基于加加速度曲线变异系数的阈值（例如，某一时间窗口的变异系数 < 0.5，则驾驶行为 = 平静；0.5< 某一时间窗口的变异系数< 1.0，则驾驶行为 = 正常；1.0 < 某一时间窗口的变异系数，则驾驶行为 = 激进）。为测量变异系数，基于11个标准驾驶循环，在不同道路类型和不同服务水平下测量了平均加加速度值。图7(a)展示了采用 [1], 中方法对样本行程的分类，图7(b)展示了采用本文所提方法对同一行程的分类。选择高速公路服务水平C、主干道和匝道服务水平CD的平均加加速度值，以遵循基于加加速度的分类，因为这些服务水平通常适用于这些道路类别。所提方法通过分析三个特征，将行程中13.09%的驾驶识别为攻击性驾驶实例；而 Murphey 等人 [1], 的方法则将6.92%的驾驶识别为激进驾驶实例。因此，附加特征能够将攻击性驾驶实例的识别率提高近47%。值得注意的是，用于计算变异系数的平均加加速度值在两种方法中有所不同，因此加加速度曲线的尺度也不同。此外，与 [1], 中的方法相比，所提出的方法针对不同道路类型采用了不同的阈值，这些阈值通过分析训练数据集生成。

为说明所提出分类过程的长期行为分类功能，我们假设此前已分类的 110 次测试行程是在不同时间由同一名驾驶员驾驶的。由于无法获取数据集中有关驾驶员的人口统计信息，我们认为有必要作出这一假设。因此，我们无法将数据集与特定驾驶员关联起来。在此情境下，我们通过短期分类测量了特定道路类型及所有行程的敌意驾驶占比。我们还将每次行程的敌意比例与训练数据的敌意比例进行比较，并通过将训练数据中的敌意驾驶占比按下限阈值（0.5）和上限阈值（1.0）缩放，将驾驶行为分类为平静、理性和激进。长期分类则通过测量敌意驾驶占比的移动平均值（包括此前所有行程），并将测量结果与三组（即平静、理性、激进）的敌意驾驶界限（<0.5：平静，0.5-1.0：理性， >1.0：激进）进行匹配来完成。图8展示了特定道路类型及总行程的两种测试行程分类结果。每个蓝点代表

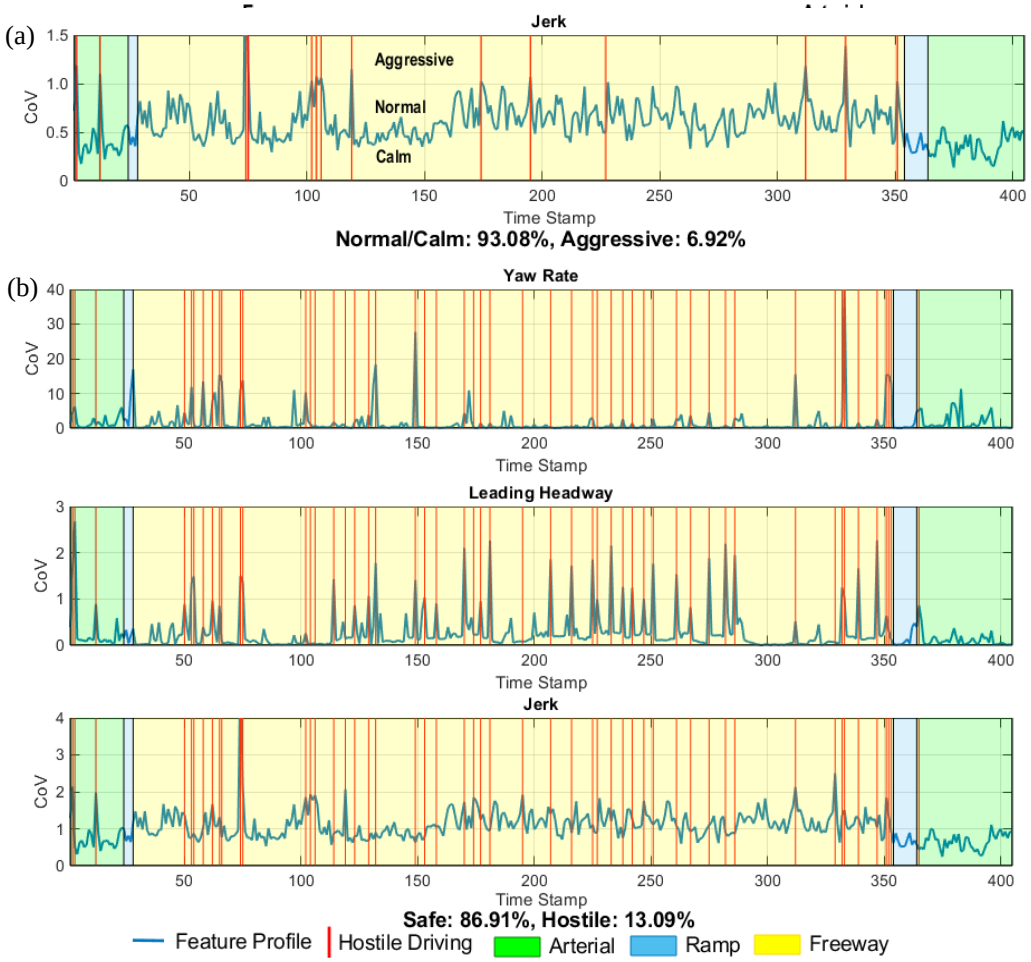

图 7. 通过 (a) 分析加加速度特征和 (b) 分析多个驾驶特征，对样本行程进行行为分类。

图8中的各图展示了每次行程的敌意比例，可用于进行短期分类。图中的红色曲线描绘了驾驶员行为的变化趋势，其计算考虑了此前的所有行程（蓝点的移动平均值）。图中不同颜色的区域（即黄色、绿色、红色）展示了特定行为类别（即平静型驾驶员、理性型驾驶员、激进型驾驶员）的边界范围。尽管单次行程的敌意比例频繁波动，但长期驾驶行为变化相对稳定，并随时间逐渐改变。

所提出的长期分类方法能够识别总行程数及特定道路类型的驾驶习惯变化模式。在图8中，累计行程的总行程敌意值主要集中在高速公路敌意上，这表明大部分行程是在高速公路上行驶的。此外，对比高速公路与主干道的敌意占比发现，主干道上的长期行为变异性（标准差 = 1.48%）高于高速公路（标准差 = 0.84%）。对长期高速公路敌意和主干道敌意进行的配对样本t检验显示，在95%置信区间内，高速公路上的敌意显著较低（t值 = 29.557，p值 < 0.001）。所得比较结果并不一定意味着驾驶员在主干道上比在高速公路上更激进，因为高速公路的分类阈值有所不同。因此，即使主干道上的敌意高于高速公路，其长期行为仍从“激进”逐渐转为“理性”。由于匝道道路类型在测试行程总数中的占比较低（平均为2.5%），因此比较时未考虑长期匝道敌意对总行程敌意的影响。

我们进一步分析了110次测试行程中识别出的敌意，以揭示不同道路类型上的短期行为分布。如图9所示，不同道路类型上的敌意行为各不相同。例如，高速公路敌意呈向低值偏斜的分布，其中占比最高的区间为2.5-5.0%。这种偏向较低敌意值的偏度，或可解释为驾驶员通常在高速公路上驾驶时，控制操作的变化较少（图1(c)）。而主干道敌意的概率分布则相对均衡，覆盖了更大的敌意范围（0-27.5%）。驾驶员在主干道上行驶时，由于道路几何条件、交通管制措施等因素，不得不应对更频繁的干扰，这可能

导致主干道上出现如此多样的敌意模式。同样，匝道敌意呈现出向中位数集中的趋势。由于匝道连接高速公路和主干道，我们预计这一过渡阶段的敌意模式会受到这两种道路类型分布的共同影响。我们对测得的敌意范围进行了配对双样本t检验，以识别不同道路类型上的行为是否存在显著差异。t检验结果表明，在99%的置信水平下，特定道路类型上的敌意行为与其他道路类型上的敌意行为存在显著差异。

V. 未UTURE 来XTENSIONS

行为分类的主要动机在于促使驾驶员保持安全的驾驶模式，因此，提供有关驾驶风格的实时反馈至关重要，这样才能发挥其效益。在计算机视觉技术和智能手机的协助下，驾驶行为信息可以通过用户友好的高级驾驶辅助系统界面传达给驾驶员，该界面旨在轻松传达短期和长期行为分类信息（图 10）。高级驾驶辅助系统界面上的语音和视觉警告可以通过短期分类通报检测到的敌意行为。图 10(a) 展示了为此设计的界面。黄色圆圈

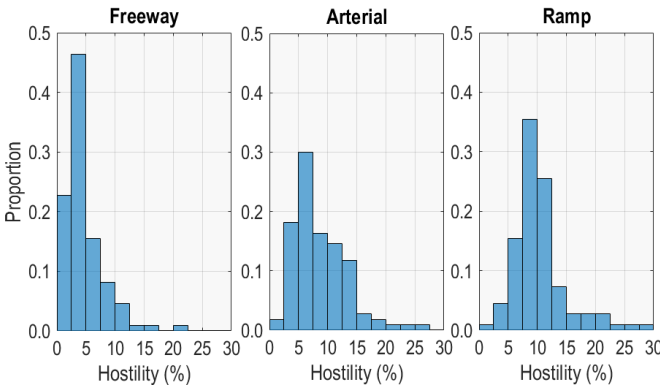

图9. 不同道路类型测试行程的敌意分布

中间的黄色圆圈在检测到敌意驾驶行为后开始闪烁，从而向驾驶员发出视觉警告。系统还可以同时发出声音警告（图中以警报符号表示）。此外，根据系统设计，同一界面还可以提供其他信息。我们认为，这种实时警告系统能够促使驾驶员提高谨慎意识，进而促进安全驾驶行为。同时，开发的应用程序可提供选项，让用户针对不同道路类型和整个行程设置个性化的敌意阈值，使用户能够自行定义对敌意的感知。

除了实时响应之外，还可以通过长期分类跟踪个别驾驶员的驾驶习惯，方法是将已分类的行程特征存储在数据库中。通过长期分类器分析以往已分类的行程历史，并在便捷的界面上显示，以识别特定道路类型和整体驾驶习惯（图 10(b)）。图 10(b) 最左侧的刻度盘显示了该时间范围内各行程的整体长期行为分类，其中黄色区域表示“平静”，绿色表示“理性”，红色表示“激进”。刻度盘仪表的指针位于黄色和绿色区域内，表明驾驶员行为介于平静和理性驾驶行为之间。图 10(b) 中的另外三个仪表显示了特定道路类型的长期驾驶行为，以及各类道路上的行程占比（每个仪表右下角的数值）。

检测到的长期驾驶行为有助于道路交通运营与安全管理部门、保险公司及其他相关组织奖励“理性驾驶者”，并处罚“激进驾驶者”，从而促进道路安全驾驶。作为这项持续研究的一部分，我们计划开发一款智能手机应用程序，实时检测驾驶行为信息并将其传达给驾驶员。此外，该应用程序将存储短期和长期驾驶历史，并分析高级驾驶辅助系统对驾驶员行为与习惯的影响。分析的目标是确定高级驾驶辅助系统能否推动驾驶行为发生范式转变。

VI. 结ONCLUDING 论EMARKS

本文提出了一种简单、高效且适应性强的驾驶行为分类技术，通过分析利用计算机视觉技术从真实道路行程中采集的纵向和横向驾驶特征而开发。所提出的分类方法的阈值可以修改，以



Fig. 10. 用于向驾驶员传达 (a) 实时警告和 (b) 长期行为信息的抽象高级驾驶辅助系统界面 rs

满足交通运输、机动车驾驶及道路管理部门的目的和要求。通过考虑驾驶的双向特征，与仅基于单一特征的分类方法相比，所提出的方法在识别不安全驾驶行为方面更具优势。本文采用了一种独特的方法，区分驾驶行为与驾驶习惯，并从行为和习惯两个层面分类驾驶员的行为。我们采用即时行为分类的概念，并利用相关信息对驾驶员的驾驶习惯进行分类。考虑采用行为分类的管理部门不仅关注驾驶员当前的反应，也关注其驾驶风格，旨在识别这些驾驶员造成的安全隐患，以及允许他们驾驶所带来的安全风险程度。鉴于研究范围，本研究有助于管理部门就驾驶行为的奖励和处罚作出决策。

虽然我们的研究仅限于以连续变量形式呈现的三个不同特征，以说明纵向和横向决策，但其他特征也可以区分特征标识符。此外，我们分析了较大SPMD数据库中的部分数据集，以展示分类技术。由于本研究的主要目的在于提出并介绍一种简化的分类技术，因此我们暂不考虑所分析数据集可能存在的偏差。简而言之，本研究试图通过考虑双向控制决策的简单分类过程，深入了解驾驶行为和习惯。此外，我们的研究还为进一步扩展提供了可能，包括开发高级驾驶辅助系统（ADAS），以及识别其对改变驾驶行为和习惯所产生的影响。

Acknowledgment

本研究得到加拿大自然科学与工程研究委员会（NSERC）、埃德蒙顿市和加拿大交通部的支持。本文内容反映了作者的观点，作者对本文所 प्रस्तुत事实及数据的准确率负责。本研究发现所依据的数据可根据合理请求向通讯作者获取。本文内容不一定反映埃德蒙顿市

或加拿大交通部的官方观点或政策。本文不构成标准、规范或法规。作者声明，就本文发表而言不存在利益冲突。

References

[1] Y. L. Murphey、R. Milton 和 L. Kiliaris，《基于加加速度分析的驾驶员风格分类》，2009年 IEEE 车辆与车辆系统计算智能研讨会（CIVVS 2009）论文集，第23–28页，2009年，doi：10.1109/CIVVS.2009.4938719。

[2] N. Karginova、S. Byttner 和 M. Svensson，《公共汽车驾驶风格分类的数据驱动方法》，载于 SAE 2012世界大会暨展览会，2012年，doi: 10.4271/2012-01-0744。[3] D. Filev、J. Lu、K. Prakah-Asante 和 F. Tseng，《基于驾驶员在环车辆动力学与控制的实时驾驶行为识别》，《IEEE国际系统、人类与控制论会议论文集》，第2020–2025页，2009年，doi: 10.1109/ICSMC.2009.5346735。[4] W. Wang、J. Xi 和 H. Chen，《基于驾驶数据的驾驶员行为建模与识别：综述》，《数学问题工程》，第2014卷，2014年，doi：10.1155/2014/245641。[5] A. Doshi 和 M. M. Trivedi，《考察驾驶风格对驾驶员可预测性和响应能力的影响：真实世界与模拟器分析》，《IEEE智能车辆研讨会论文集》，第232–237页，2010年，doi: 10.1109/IVS.2010.5547969。[6] A. Bolovinou、A. Amditis、F. Bellotti 和 M. Tarkiainen，《协同驾驶的驾驶风格识别：综述》，《适应性2014：第六届适应性与自适应系统及应用国际会议》，第73–78页，2014年。[7] E. Ericsson，《独立驾驶模式因素及其对燃料使用和尾气排放因素的影响》，《交通研究D辑：交通与环境》，第6卷第5期，第325–345页，2001年，doi：10.1016/S1361-9209(01)00003-7。[8] R. Wang 和 S. M. Lukic，《混合动力电动汽车驾驶条件预测与基于驾驶风格识别的控制算法综述》，《2011 IEEE车辆动力与推进会议（VPPC 2011）》，2011年，doi: 10.1109/VPPC.2011.6043061。[9] V. Manzoni、A. Corti、P. De Luca 和 S. M. Savaresi，《通过惯性测量估计驾驶风格》，《IEEE智能交通系统会议论文集》（ITSC），第777–782页，2010年，doi: 10.1109/ITSC.2010.5625113。[10] L. Kleisen，《思维风格与驾驶风格之间的关系及其对年轻驾驶员道路安全的贡献》。堪培拉大学，布鲁斯，澳大利亚，2011年。[11] S. De Groot、F. Centeno Ricote 和 J. C. F. De Winter，《轮胎抓地力对驾驶技能学习和驾驶风格的影响：驾驶模拟器研究》，《交通研究F辑：交通心理学与行为》，第15卷第4期，第413–426页，2012年，doi：10.1016/j.trf.2012.02.005。[12] M. Ishibashi、M. Okuwa、S. Doi 和 M. Akamatsu，《驾驶风格表征指标及其与跟车行为的关联》，《SICE年度会议论文集》，第1132–1137页，2007年，doi: 10.1109/SICE.2007.4421155。[13] T. Lajunen 和 H. Summala，《驾驶员自我评估中的驾驶经验、人格、技能与安全动机维度》，《人格与个体差异》，第19卷第3期，第307–318页，1995年，doi: 10.1016/0191-8869(95)00068-H。[14] J. J. Gibson 和 L. E. Crooks，《汽车驾驶的理论场分析》，《美国心理学杂志》，第51卷，471，1938年3月，453号，第–页。[15] D. Shinar，《交通安全与人类行为》。翡翠出版有限公司，2017年。[16] D. L. Wiesenthal、D. Hennessy 和 P. M. Gibson，《驾驶报复问卷（DVQ）：用于测量违规驾驶员态度的量表开发》，《暴力与受害者》，第15卷第2期，第115–136页，2000年。[17] E. R. Dahlen 和 K. M. Ragan，《愤怒驾驶倾向量表的验证》，《安全研究杂志》，第35卷，563，2004年，第5期，第557–页，doi：10.1016/j.jsr.2004.09.002。[18] N. Sümer、T. Özkan 和 T. Lajunen，《驾驶技能与安全技能之间的非对称关系》，《Accid. Anal. Prev.》，第38卷第4期，第703–711页，2006年，doi：10.1016/j.aap.2005.12.016。

[19] O. Taubman-Ben-Ari、M. Mikulincer 和 O. Gillath，《多维驾驶风格量表——量表构建与验证》，《Accid. Anal. Prev.》，第36卷第3期，第323–332页，2004年，doi：https://doi.org/10.1109/TSMC.2015.2417837。

[20] C. S. Dula 和 M. E. Ballard，“危险、激进、负面情绪及风险驾驶测量工具的开发与评估”，J. Appl. Soc. Psychol.，第 33 卷，第 2 期，第 263–282 页，2003，doi: 10.1111/j.1559-1816.2003.tb01896.x。

[21] I. Richer 和 J. Bergeron，“大麻影响下驾驶：与危险驾驶、心理预测因素及事故涉入的关联”，Accid. Anal. Prev.，第 41 卷，第 2 期，第 299– 307 页，2009，doi: 10.1016/j.aap.2008.12.004。

[22] H. R. Eftekhari 和 M. Ghatee，“离散小波变换与自适应神经模糊推理系统相结合，用于整体驾驶行为识别”，Transp. Res. Part F Psychol. Behav.，第 58 卷，第 782–796 页，2018，doi: 10.1016/j.trf.2018.06.044。

[23] J. W. Joubert、D. De Beer 和 N. De Koker，“结合加速度计数据和情境变量评估驾驶员行为风险”，《交通研究：F 部分：交通心理与行为》，第 41 卷，页 80–96，2016，doi：10.1016/j.trf.2016.06.006。

[24] L. Eboli、G. Mazzulla 和 G. Pungillo，“如何结合驾驶风格的客观与主观测量来界定汽车驾驶员的事故风险等级”，《交通研究：F 部分：交通心理与行为》，第 49 卷，页 29–38，2017，doi：10.1016/j.trf.2017.06.004。

[25] J. Paefgen、F. Kehr、Y. Zhai 和 F. Michahelles，“利用智能手机进行驾驶行为分析：受控实地研究的见解”，第 11 届国际移动与普适多媒体会议论文集，第 36:1–36:8 页，2012，doi：10.1145/2406367.2406412。

[26] A. Aljaafreh, N. Alshabatat 和 M. S. Najim Al-Din，“使用模糊逻辑进行驾驶风格识别”，2012年IEEE国际车辆电子与安全会议，ICVES 2012，第460–463页，2012年，doi：10.1109/ICVES.2012.6294318。

[27] H. Eren、S. Makinist、E. Akin 和 A. Yilmaz，“通过智能手机估计驾驶行为”，载于2012年IEEE智能车辆研讨会，2012年，第254号，doi：https://doi.org/10.1109/IVS.2012.6232298。

[28] D. A. Johnson 和 M. M. Trivedi，“将智能手机用作传感器平台进行驾驶风格识别”，IEEE智能交通系统会议论文集（ITSC），第1609–1615页，2011年，doi：10.1109/ITSC.2011.6083078。

[29] J. Lee 和 K. Jang，“基于车内驾驶记录评估攻击性驾驶行为的框架”，Transp. Res. Part F Psychol. Behav., 2017，doi: 10.1016/j.trf.2017.11.021。

[30] N. Abuali 和 H. Abou-zeid，“驾驶员行为建模：进展与未来方向”，Int. J. Veh. Techology, vol. 2016，2016，doi: 10.1155/2016/6952791。

[31] A. B. Ellison、S. P. Greaves 和 M. C. J. Bliemer，“用于道路安全分析的驾驶员行为特征”，Accid. Anal. Prev., vol. 76, pp. 118–132，2015，doi: 10.1016/j.aap.2015.01.009。

[32] O. Bagdadi 和 A. Várhelyi，“颠簸驾驶——事故易发性的指标？”，Accid. Anal. Prev., vol. 43, no. 4, pp. 1359– 1363，2011，doi: 10.1016/j.aap.2011.02.009。

[33] A. V. Desai 和 M. A. Haque，“操作员安全的警觉性监测：一项关于高速公路驾驶的模拟研究”，J. Safety Res.，第 37 卷，第 2 期，第 139–147 页，2006 年，doi：10.1016/j.jsr.2005.11.003。

[34] H. H. Van Huysduynen、J. Terken 和 B. Eggen，“自我报告的驾驶风格与驾驶行为之间的关系：一项模拟器研究”，Transp. Res. Part F Psychol. Behav.，第 56 卷，第 245–255 页，2018 年，doi: 10.1016/j.trf.2018.04.017。

[35] G. Underwood，“年轻与年长新手驾驶员在驾驶初始六个月期间的道路驾驶行为”，Accid. Anal. Prev.，第 58 卷，第 235–243 页，2013 年，doi: 10.1016/j.aap.2012.03.019。

[36] H. Xiong、L. N. Boyle、J. Moeckli、B. R. Dow 和 T. L. Brown，“自适应巡航控制早期采用者的使用模式”，Hum. Factors，第 54 卷，第 5 期，第 722–733 页，2012 年，doi：10.1177/0018720811434512。

[37] B. Reimer、B. Donmez、M. Lavallière、B. Mehler、J. F. Coughlin 和 N. Teasdale，“年龄和认知需求对实际高速公路路况下车道选择与变换的影响”，Accid. Anal. Prev.，第 52 卷，第 125–132 页，2013 年，doi: 10.1016/j.aap.2012.12.008。

[38] N. Zhao, B. Mehler, B. Reimer, L. A. D. Ambrosio, A. Mehler 和 J. F. Coughlin，“驾驶行为问卷与高速公路驾驶行为客观测量之间关系的研究”

，”Transp. Res. PART F，第 15 卷，第 6 期，第 676–685 页，2012，doi：10.1016/j.trf.2012.08.001。[39] A. Y. Ungoren 和 H. Peng，“自适应横向预瞄驾驶员模型”，Veh. Syst. Dyn.，第 43 卷，第 4 期，第 245–259 页，2005，doi：10.1080/00423110412331290419。[40] H. Farah、S. Bekhor、A. Polus 和 T. Toledo，“双车道乡村公路的超车间隙接受模型”，Transportmetrica，第 5 卷，第 3 期，第 159–172 页，2009，doi：10.1080/18128600902721899。[41] F. Y. Wang，“智能交通系统的平行控制与管理：概念、架构和应用”，IEEE Trans. Intell. Transp. Syst.，第 11 卷，第 3 期，第 630–638 页，2010，doi：10.1109/TITS.2010.2060218。[42] L. Li、D. Wen、N. N. Zheng 和 L. C. Shen，“认知汽车：ADAS 研究的新前沿”，IEEE Trans. Intell. Transp. Syst.，第 13 卷，第 1 期，第 395–407 页，2012，doi：10.1109/TITS.2011.2159493。[43] T. Inagaki，“基于相互理解的人机智能协作”，Annu. Rev. Control，第 32 卷，第 2 期，第 253–261 页，2008，doi：10.1016/j.arcontrol.2008.07.003。[44] Y. Dong、Z. Hu、K. Uchimura 和 N. Murayama，“智能车辆驾驶员注意力不集中监测系统：综述”，IEEE Trans. Intell. Transp. Syst.，第 12 卷，第 2 期，第 596–614 页，2011，doi：10.1109/TITS.2010.2092770。[45] J. Son、M. Park 和 B. B. Park，“年龄、性别和道路环境对高级驾驶辅助系统接受度和有效性的影响”，Transp. Res. Part F Traffic Psychol. Behav.，第 31 卷，第 12–24 页，2015，doi：10.1016/j.trf.2015.03.009。[46] C. Guo 等，“驾驶员与自动驾驶系统之间的协作：实施与评估”，Transp. Res. Part F Traffic Psychol. Behav.，第 1–12 页，2016，doi：10.1016/j.trf.2017.04.006。[47] M. Staubach，“与交通事故相关的因素评估高级驾驶辅助系统的依据”，Accid. Anal. Prev.，第 41 卷，第 5 期，第 1025–1033 页，2009，doi：10.1016/j.aap.2009.06.014。[48] F. Syed、A. Dobryden、F. M. Co、R. Mcgee、D. Filev 和 F. M. Co，“为提高混合动力电动汽车的真实道路燃油经济性而设计和分析自适应实时建议系统”，载于 SAE 2010 世界大会暨展览会，2010，doi：https://doi.org/10.4271/2010-01-0835。[49] H. Jiang、J. Hu、S. An、M. Wang 和 B. B. Park，“部分网联自动驾驶车辆环境下孤立信号交叉口的生态化接近”，Transp. Res. Part C Emerg. Technol.，第 79 卷，第 290–307 页，2017，doi：10.1016/j.trc.2017.04.001。[50] B. Ryder、B. Gahr、P. Egolf、A. Dahlinger 和 F. Wortmann，“利用车载决策支持系统预防交通事故——事故高发地点警告对驾驶员行为的影响”，Decis. Support Syst.，第 99 卷，第 64–74 页，2017，doi：10.1016/j.dss.2017.05.004。[51] C. Diakaki、M. Papageorgiou、I. Papamichail 和 I. Nikolos，“从高速公路交通管理角度概述和分析车辆自动化与通信系统”，Transp. Res. Part A Policy Pract.，第 75 卷，第 147–165 页，2015，doi：10.1016/j.tra.2015.03.015。[52] U. Fugiglando、P. Santi、S. Milardo、K. Abida 和 C. Ratti，“通过 CAN 总线数据分析表征‘驾驶员 DNA’”，载于第二届 ACM 智能、自主与网联车辆系统及服务国际研讨会，2017，第 37–41 页，doi：10.1145/3131944.3133939。[53] T. Lee 和 J. Son，“驾驶风格与燃料

《高速公路驾驶中的燃料消耗》，载于第16届亚太汽车工程会议，2011年，doi: 10.4271/2011-28-0051。[54] A. Corti、C. Ongini、M. Tanelli和S. M. Savaresi，《道路车辆能源导向型应用的定量驾驶风格估计》，《2013 IEEE系统、人类与控制论国际会议》（SMC 2013）会议录，第3710–3715页，2013年，doi: 10.1109/SMC.2013.632。[55] D. Dörr、D. Grabengiesser和F. Gauterin，《使用模糊逻辑进行在线驾驶风格识别》，2014年第17届IEEE智能交通系统国际会议（ITSC 2014），第1021–1026页，2014年，doi: 10.1109/ITSC.2014.6957822。[56] F. U. Syed、D. Filev和H. Ying，《基于模糊规则的驾驶员咨询系统：改善混合动力电动汽车的燃油经济性》，北美模糊信息处理学会年度会议（NAFIPS），第178–183页，2007年，doi: 10.1109/NAFIPS.2007.383833。[57] J. Kim、H. Sim和J. Oh，《与驾驶模式、驾驶员驾驶风格和环境状况相对应的灵活电动汽车／混合动力电动汽车及SOC区间控制》，载于《SAE 2012世界大会暨展览会》，2012年，doi: 10.4271/2012-01-1016。[58] Z. Constantinescu、C. Marinoiu、M. Vladoiu、C. Marinoiu和M. Vladoiu，《使用数据挖掘技术进行驾驶风格分析》，《国际计算机、通信与控制期刊》，第V卷，第5期，第1841–9836页，2010年，doi: 10.15837/ijccc.2010.5.2221。[59] U. Fugiglando等，《通过非受控环境中的CAN总线数据进行驾驶行为分析》，《IEEE智能交通系统汇刊》，第20卷，第2期，第737–748页，2019年2月，doi: 10.1109/TITS.2018.2836308。[60] 美国交通部和密歇根大学交通研究所，《安全试点模型部署项目》。[在线]。可访问：http://safetypilot.umtri.umich.edu/。[61] 《安全试点模型部署数据》，美国交通部。[在线]。可访问：https://catalog.data.gov/dataset/safety-pilot-model- deployment-data。[62] 《弗吉尼亚理工交通研究所》，弗吉尼亚理工大学。[在线]。可访问：https://www.vtti.vt.edu/。[访问日期：05-Nov-2020]。[63] 美国交通部，《智能交通系统数据中心》。[在线]。可访问：https://www.its.dot.gov/data/。[64] I. Mohamad、M. A. M. Ali和M. Ismail，《使用实时全球定位系统数据进行异常驾驶检测》，载于《2011 IEEE空间科学与通信国际会议》（IconSpace）会议录，2011年，第1–6页，doi: 10.1109/IConSpace.2011.6015840。[65] C. Ma、X. Dai、J. Zhu、N. Liu、H. Sun和M. Liu，《DrivingSense：基于智能手机自动校准的危险驾驶行为识别》，《移动信息系统》，2017年，第1–15页，2017年，doi: 10.1155/2017/9075653。[66] T. Toledo、O. Musicant和T. Lotan，《用于监测驾驶员行为并提供反馈的车载数据记录仪》，《交通运输研究C辑：新兴技术》，第16卷，第3期，第320–331页，2008年6月，doi: 10.1016/j.trc.2008.01.001。[67] J. Dai、J. Teng、X. Bai、Z. Shen和D. Xuan，《基于移动电话的酒后驾驶检测》，载于《第4届国际ICST医疗保健普适计算技术会议》会议录，2010年，第1–8页，doi: 10.4108/ICST.PERVASIVEHEALTH2010.8901。[68] K. C. Baldwin、D. D. Duncan和S. K. West，《驾驶员监测系统：评估驾驶员表现的一种手段》，《约翰斯·霍普金斯大学应用物理实验室技术文摘》，第25卷，第3期，第269–277页，2004年。[69] E. M. Carboni和V. Bogorny，《通过轨迹分析推断驾驶员行为》，载于《智能系统*2014*》，Springer，2015年，第837–848页。