

# 场景复杂度评估在轨迹预测和驾驶决策中的应用\*

李道飞, 潘豪

(浙江大学动力机械及车辆工程研究所, 杭州 310027)

**[摘要]** 场景复杂度的评估对于提升自动驾驶车辆应对多变环境的能力以及增强算法的适用性至关重要。本文中设计了基于图模型的复杂度评估算法, 充分考虑场景中的交互拓扑, 将场景划分为3类不同复杂度。在匝道汇流场景下, 验证了该算法的合理性与有效性。为说明复杂度评估算法的拓展性, 将其应用于自动驾驶的轨迹预测与决策算法开发中。通过结合自然驾驶数据集和实车在环试验, 对提出算法进行测试, 结果表明: 场景复杂度评估可预先估计预测的不确定性, 显著提升自动驾驶决策算法的实时性与最优性。在数据回放测试中, 复杂度评估模块可帮助降低并道失败率、并道剐蹭率分别为38%、92%, 具有潜在的应用前景。

**关键词:** 场景复杂度; 自动驾驶决策; 轨迹预测; 图模型; 实车在环试验

## Application of Scenario Complexity Evaluation in Trajectory Prediction and Automated Driving Decision-Making

Li Daofei & Pan Hao

Institute of Power Machinery and Vehicular Engineering, Zhejiang University, Hangzhou 310027

**[Abstract]** The evaluation of scenario complexity is crucial for improving adaptability and flexibility of autonomous vehicles in coping with complex environments and enhancing the applicability of the algorithms. A graph-based algorithm for evaluating scenario complexity is developed in this paper, which fully considers interactive topology and categorizes traffic scenarios into three complexity levels. The reasonability and effectiveness are validated in ramp merging scenarios. To demonstrate its scalability, the evaluation algorithm is applied in the development of the trajectory prediction and decision-making algorithms of automated driving. The proposed algorithms are then tested using natural driving datasets and vehicle-in-the-loop experiments. The results indicate that scenario complexity evaluation enables early estimation of prediction uncertainty, enhances the real-time and optimality of decision-making algorithms. In data replay tests, the complexity assessment module can reduce the failure rate and collision rate during lane merging by approximately 38% and 92%, respectively, indicating promising application prospects.

**Keywords:** scenario complexity; autonomous driving decision making; trajectory prediction; graph model; vehicle-in-the-loop experiment

### 前言

自动驾驶的安全决策, 关键在于如何基于多维感知信息, 深入理解驾驶场景态势演变和潜在不确定性。特别是在复杂环境下决策解空间有限时, 更

须量化驾驶场景复杂度, 实现交通态势的准确预测和评估。

复杂环境的构成要素通常被描述为存在较多随机分布的静态/动态障碍物<sup>[1-2]</sup>、感知/其他交通参与者不确定性造成的约束动态变化<sup>[3-4]</sup>。驾驶场景复杂度对人类驾驶行为有显著影响: 任务复杂度的增

\* 国家自然科学基金面上项目(52372421)和浙江省科技厅领雁研发攻关计划项目(2023C01238, 2022C01241)资助。

原稿收到日期为2024年03月03日, 修改稿收到日期为2024年04月19日。

通信作者: 李道飞, 副教授, 工学博士, E-mail: dfl@zju.edu.cn。

加,会增加认知负荷<sup>[5]</sup>。目前,任务复杂度的量化方法包括主观和客观评估两类,其中主观法根据人的主观感受或评分来评估复杂度<sup>[6-7]</sup>,如层次分析法、信息熵理论等,其缺点在于易受个体差异和主观价值倾向的影响。客观法则通过数学模型或统计方法来计算场景复杂度,如碰撞时间、人工势能场模型<sup>[8-9]</sup>。Yu等<sup>[10]</sup>基于要素数量、多样性及要素间相关性提出一个客观量化框架,但仅考虑主体车辆与单一车辆构成的相对关系(遭遇角、相对速度、相对距离)。客观法更具科学性可与重复性,但现有量化模型在考虑车辆间的交互耦合关系方面仍存在不足。

复杂交互场景下,自动驾驶决策规划须综合考虑自车状态、周围环境态势及行驶目标等因素。博弈论是一种交互式决策理论,能有效建模参与者间的相互影响,得到了广泛关注<sup>[11-17]</sup>。然而,在交通参与者较多、低速拥堵路况下,传统的博弈决策难以保证安全性,而用显性碰撞约束的广义纳什均衡问题面临实时性挑战。本质上,交互拓扑是各主体间耦合关系的描述,忽视交互拓扑的影响,必会妨碍准确、可靠的态势预测与评估。

为此,本文以灵活的自动驾驶决策算法开发为目标,提出了一种基于图模型与谱聚类的驾驶场景复杂度客观评估算法,用于量化轨迹预测的不确定性、有助于决策中冲突对象的筛选。最后,利用自然驾驶数据集和实车测试对算法的有效性、合理性进行验证。

## 1 驾驶场景复杂度评估算法

### 1.1 驾驶场景特征的抽象与提取

自动驾驶车辆结合自身的行驶任务,在复杂多变的交通环境下做出合理、正确的决策,就须通过量化场景复杂度的方式实现对交通场景的准确认知。为此,须重点关注动态交通元素。然而,动态交通元素数目不固定、导致特征维度不断变化,传统的基于特征向量描述的方法难以处理。另一方面,交通参与者须共享道路使用权,还须直接描述其交互关系。本文采用图模型描述复杂场景中元素及元素间的关系。下面从图节点、图边以及图节点标签定义3方面,阐述如何将车辆所处驾驶场景抽象为一个无向节点标签图 $G = (\mathcal{V}, \mathcal{E}, \mathcal{L})$ 。

(1)图节点 $V_i \in \mathcal{V}$ :场景抽象过程如图1所示,以主车(“蓝车”)为基准,横向考虑本车道、相邻左道、相邻右道3段;纵向考虑前、后与中间3段区域,共有

9块区域(0~8)。主车是区域0对应的节点,将每区距离主车最近的车辆作为图模型中的对应节点;当区域中没有车辆时,对应节点即不存在。




图1 驾驶场景抽象示意图

(2)图边 $E_{ij} \in \mathcal{E}$ :在交互图中,两节点车辆间的冲突或交互,即建模为边。冲突程度用车辆间距表示,间距越小、冲突程度越高。考虑到车辆与间隔一个车道及以上的他车冲突较少,仅当纵向距离小于阈值、中间并不存在其他车辆,且横向距离小于车道宽时,两节点才会形成一条无向边。如图1中,节点 $V_4$ 与 $V_6$ 横向间隔一车道,且节点 $V_5$ 位于两者间,并不存在一条边连接两节点;节点 $V_6$ 与 $V_8$ 间并不存在其他节点,但两者距离大于临界距离,两者间也不存在连接关系。

(3)图节点的标签值 $l(V_i) \in \mathcal{L}$ :节点与边是图模型最为基础的两个元素,描述了车辆间交互拓扑关系,而为利用场景信息,须基于可观测的车辆状态信息为节点添加标签或者属性。其中标签大多定义为整数,而属性定义为实数向量。此处采用节点标签图,即包含节点标签 $l(V_i)$ ,其数学定义如下:

$$l(V_i) = x_i + fac_{label} \cdot y_i + fac_{label}^2 \cdot v_i \quad (1)$$

式中: $x_i, y_i, v_i$ 分别为节点 $V_i$ 对应的离散化纵向坐标、横向坐标、速度,取值范围皆为 $0, 1, \dots, fac_{label} - 1$ ;  $fac_{label}$ 为特定状态对应离散取值的集合大小。以 $x_i$ 为例,将连续的车辆纵向位置信息离散化:

$$x_i = \begin{cases} 0, & x_{c,i} < x_{\min} \\ \text{floor} \left( \frac{fac_{label} (x_{c,i} - x_{\min})}{x_{\max} - x_{\min}} \right), & x_{\min} \leq x_{c,i} \leq x_{\max} \\ fac_{label} - 1, & x_{c,i} > x_{\max} \end{cases} \quad (2)$$

式中: $x_{c,i}$ 为节点 $V_i$ 对应的连续纵向坐标,为泛化模型,在此采用以节点 $V_0$ 为原点、行驶方向为 $x$ 轴正、车辆左侧为 $y$ 轴正的相对坐标系; $x_{\min}$ 与 $x_{\max}$ 表示 $x_{c,i}$ 的最小与最大值; $\text{floor}(\cdot)$ 表示对自变量进行向下取整。

### 1.2 驾驶场景复杂度评估

基于上述场景抽象建模,采用无监督聚类对驾驶场景复杂度进行分类与识别。

(1) 基于 Weisfeiler-Lehman (WL) 图核的驾驶场景特征提取: 为分析复杂度, 须衡量两个驾驶场景  $G_1$  与  $G_2$  间的相似性。相较于基于特征向量的方法, 图相似度的计算复杂度更高。在此, 采用图核, 一个定义在图集合  $\mathcal{G}$  上的对称、半正定的函数, 可表示为  $k_{\text{graph}}: \mathcal{G} \times \mathcal{G} \rightarrow R$ 。类似于典型核方法, 图核首先须将两个输入的交互图映射至特征空间中的向量特征, 然后再在特征空间中度量两者的相似度, 将图空间中复杂的非线性算法转为特征空间中的线性算法, 使基于特性向量表达的标准算法也能应用于图模型上。图核计算公式为

$$k_{\text{graph}}(G_1, G_2) = \langle \phi(G_1), \phi(G_2) \rangle_{\mathcal{H}} \quad (3)$$

式中:  $G_1, G_2 \in \mathcal{G}$ ;  $\langle \cdot, \cdot \rangle_{\mathcal{H}}$  为希尔伯特空间  $\mathcal{H}$  中的内积。

基于 Weisfeiler-Lehman 算法的 WL 图核, 主要思想是将节点标签信息与结构信息映射为节点的新标签, 将图模型相似度问题转换为图节点对应标签的相似度问题。先将邻域节点 ( $\{V_j | j \in \mathcal{N}(V_i)\}$ ) 的标签排序后增广至中心节点  $V_i$  的标签, 然后将增广得到的标签信息压缩形成全新的、短的标签信息。在 WL 同构检测中, 上述步骤须重复、直至最大迭代步数, 或者两个图  $G_1$  与  $G_2$  所对应的节点标签存在不同。经过最大迭代后, 图  $G_1$  与  $G_2$  的节点标签仍然一致时, 即可认为两图同构。

基于同构检测算法, 可获得将原始图  $G = (\mathcal{V}, \mathcal{E}, \mathcal{L})$  经过  $i$  次迭代运算的 WL 图  $G^i = (\mathcal{V}, \mathcal{E}, \mathcal{L}^i)$ , 其中  $G^0 = G, \mathcal{L}^0 = \mathcal{L}$ , 因此迭代过程中得到的 WL 图序列可表示为

$$\{G^0, G^1, \dots, G^h\} = \{(\mathcal{V}, \mathcal{E}, \mathcal{L}^0), \dots, (\mathcal{V}, \mathcal{E}, \mathcal{L}^h)\} \quad (4)$$

结合式(3)与式(4), 可将基于 WL 的图核定义为

$$k_{\text{WL}}^h(G_1, G_2) = k_{\text{base}}(G_1^0, G_2^0) + \dots + k_{\text{base}}(G_1^h, G_2^h) \quad (5)$$

式中:  $h$  表示 WL 算法的最大迭代次数;  $\{G_1^0, G_1^1, \dots, G_1^h\}$  和  $\{G_2^0, G_2^1, \dots, G_2^h\}$  分别是输入图  $G_1$  和  $G_2$  的 WL 图序列;  $k_{\text{base}}$  为基函数, 典型的有子树图核、最短路径图核。本文采用子树图核, 在比较两图时对匹配的节点进行计数:

$$\begin{cases} k_{\text{st}}(G_1^i, G_2^i) = \sum_{V_1 \in \mathcal{V}_1^i} \sum_{V_2 \in \mathcal{V}_2^i} \delta(l(V_1), l(V_2)) \\ \delta(l(V_1), l(V_2)) = \begin{cases} 1, l(V_1) = l(V_2) \\ 0, l(V_1) \neq l(V_2) \end{cases} \end{cases} \quad (6)$$

(2) 基于谱聚类的驾驶场景推测: 实现对驾驶场景的特征提取, 并基于 WL 图核度量图相似度, 即可采用无监督聚类, 实现对驾驶场景复杂度的推测。

谱聚类是从图论演化得到的无监督聚类算法, 对数据分布具有较强的适应性。其将每个样本(如交互图  $G$ ) 看作相似图的节点, 而节点间相似度(即式(5)得到的  $k_{\text{WL}}^h(G_1, G_2)$ ) 构成相似图的边权重。应用时, 须计算相似图的拉普拉斯矩阵, 求解对应特征值与特征向量, 实现对高维数据的降维, 然后用无监督聚类赋予样本复杂度标签(此处用  $k$ -均值聚类)。聚类目标是将构造的相似图切分为若干簇, 使得去除的边对应的权重和最小。

聚类评价指标选择 Calinski-Harbasz (CH), 即

$$\begin{cases} CH = \frac{BGSS}{k-1} / \frac{WGSS}{N-k} \\ BGSS = \sum_{i=1}^k n_i (\bar{\mathbf{x}}_i - \bar{\mathbf{x}})^T (\bar{\mathbf{x}}_i - \bar{\mathbf{x}}) \\ WGSS = \sum_{i=1}^k \sum_{j=1}^{n_i} (\mathbf{x}_i - \mathbf{x}_{ij})^T (\mathbf{x}_i - \mathbf{x}_{ij}) \end{cases} \quad (7)$$

式中:  $k$  为聚类簇数;  $N$  为输入样本总数;  $BGSS$  为簇间总偏差平方和 (between groups sum of squares), 描述簇间相似度;  $WGSS$  表示簇内总偏差平方和 (within groups sum of squares), 描述簇内相似度;  $n_i$  表示第  $i$  簇的样本总数;  $\bar{\mathbf{x}}$  表示所有样本的均值向量;  $\bar{\mathbf{x}}_i$  表示第  $i$  簇样本的均值向量;  $\mathbf{x}_{ij}$  表示第  $i$  簇的第  $j$  个样本的特征向量。

INTERACTION 自然驾驶数据集包含多种交通参与者间的交互行为, 且涵盖常规操作到危险的、乃至临近碰撞的各类行为。此处, 基于其中匝道汇流场景的数据, 使用图模型实现特征提取。代表复杂度数目的超参数  $k$  对聚类结果的影响如表 1 所示: 当  $k=3$  时, 指标  $CH$  最大, 簇内紧密度与簇间分离程度最高。

表 1 聚类簇数对  $CH$  指标的影响

簇数 $k$	2	3	4	5
$CH$	2 670.4	2 851.5	2 709.5	2 767.5

## 2 考虑场景复杂度的轨迹预测算法

### 2.1 轨迹预测算法

传统上基于物理模型的轨迹预测算法往往忽略其他交通参与者以及道路拓扑对目标车轨迹的影响, 无法满足长时域的预测需求。为建模车间交互,

本文提出了基于神经网络与物理模型的车辆轨迹预测方法。

图2为算法的神经网络框架,输入包括目标车辆及其周围8个可观测范围内车辆的过去 $t_{in} = 2\text{ s}$ 历史状态信息,输出为目标车辆未来 $t_{out} = 4\text{ s}$ 的位置序列。进一步地,将此输出作为观测值,利用物理模型对状态进行滤波,获取目标车辆的速度和加速度序列。

为处理车辆间的空间依赖关系与时序序列特征,算法采用时间卷积(temporal convolutional network, TCN)与图注意力网络(graph attention network, GAT)。

(1) 时间卷积TCN:从时间维度来看,车辆未来位姿状态与历史信息强相关。采用TCN网络对输入特征向量 $\mathbf{In}(t)$ 中每车历史轨迹信息进行编码,具有6层隐藏层,每层神经元数目均为100。隐藏层有膨胀因子,设为与层数呈2的指数增长,卷积核大小设为 $3 \times 6$ 。

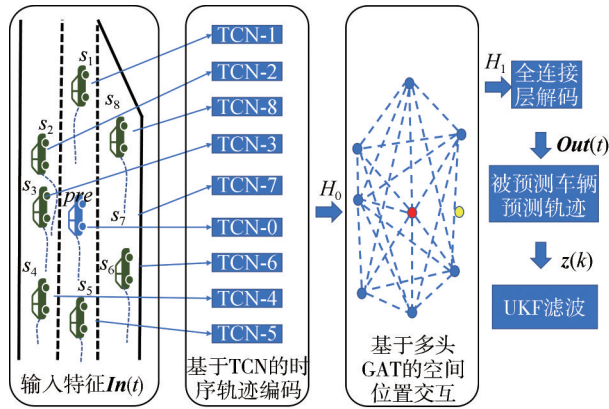


图2 轨迹预测算法架构图

(2) 图注意力网络GAT:从空间维度来看,车辆间存在行为依赖关系,此处用多头GAT建模。以关注的交通参与者 $s_i$ 与 $pre$ 作为图的节点,使用图上的边来建模节点间交互关系;以TCN所得时序特征为对应节点的特征向量,构成一个交互图;用GAT学习图节点间的交互关系,实现对不同相邻节点的自适应权重分配。

图注意力网络是基于图注意力层实现的,其接受的特征输入为 $\mathbf{H}_0 = [\vec{h}_{pre}, \vec{h}_{s_1}, \dots, \vec{h}_{s_8}]$ ,其中 $\vec{h}_{pre}$ 与 $\vec{h}_{s_i}$ 是TCN网络输出的特征向量,即节点特征。首先,引入待训练的共享参数矩阵 $\mathbf{W}$ 对节点特征进行增维,并通过共享的注意力机制 $\alpha$ 将拼接的高维特征

映射为一个实数,即节点 $m$ 与 $n$ 对应的归一化注意力系数 $\alpha_{mn}$ :

$$\begin{cases} e_{mn} = \mathbf{a}([\mathbf{W} \vec{h}_m \| \mathbf{W} \vec{h}_n]) \\ \alpha_{mn} = \frac{\exp(\text{LeakyReLU}(e_{mn}))}{\sum_k \exp(\text{LeakyReLU}(e_{mk}))} \end{cases} \quad (8)$$

式中: $[\cdot \| \cdot]$ 操作符表示拼接两个特征向量; $\text{LeakyReLU}(\cdot)$ 表示LeakyReLU激活函数。进一步,结合注意力系数可得每个节点最终的输出特征 $\vec{h}_m'$ :

$$\vec{h}_m' = \sigma\left(\frac{1}{K_{\text{head}}} \sum_{k=1}^{K_{\text{head}}} \sum_n \alpha_{mn}^k \mathbf{W}^k \vec{h}_n\right) \quad (9)$$

式中: $\sigma(\cdot)$ 为激活函数; $K_{\text{head}}$ 为注意力机制头数,设为8; $\alpha_{mn}^k$ 表示第 $k$ 个注意力机制( $\alpha^k$ )对应的归一化注意力系数; $\mathbf{W}^k$ 是对应的线性变化权重矩阵。

## 2.2 数据集验证

以匝道汇流为例,使用INTERACTION数据集的CHN\_Merging\_ZS数据,时长为94.62 min,共提取67 248组数据,其中训练集与测试集比例为3:1。每组数据输入目标车辆与周围车辆过去2 s的历史数据 $\mathbf{In}(t)$ ,输出未来4 s的轨迹 $\mathbf{Out}(t)$ 。匝道汇流时,车辆横向运动比纵向更值得关注,其预测精度需求也更高,网络训练损失函数设为

$$\text{Loss} = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K \left( (\hat{x}(i, k) - x(i, k))^2 + fa_{\text{lat}} (\hat{y}(i, k) - y(i, k))^2 \right) \quad (10)$$

式中: $N$ 表示待预测轨迹的数量; $K = 40$ 表示预测轨迹长度; $\hat{x}(i, k)$ 与 $\hat{y}(i, k)$ 分别表示第 $i$ 个测试案例中,第 $k$ 个预测点算法输出的纵、横向位置; $x(i, k)$ 与 $y(i, k)$ 分别表示对应的车辆真实纵、横向位置; $fa_{\text{lat}} = 4$ 表示横向误差的权重。预测结果如表2所示,总体误差较小。

表2 轨迹预测误差对比分析

误差/m	预测 1 s	预测 2 s	预测 3 s	预测 4 s
预测算法	0.052	0.181	0.470	0.873

## 2.3 不同场景复杂度对应的预测误差分布

为度量聚类效果,分析不同复杂度标签的样本对应轨迹预测误差的分布情况,如图3所示。其中“★”为预测误差最大/最小的两类标签在1.0与4.0 s处的预测误差及取值情况;图例“0-20.866%”表示复杂度标签为0,其在所有样本中的占比为20.866%。

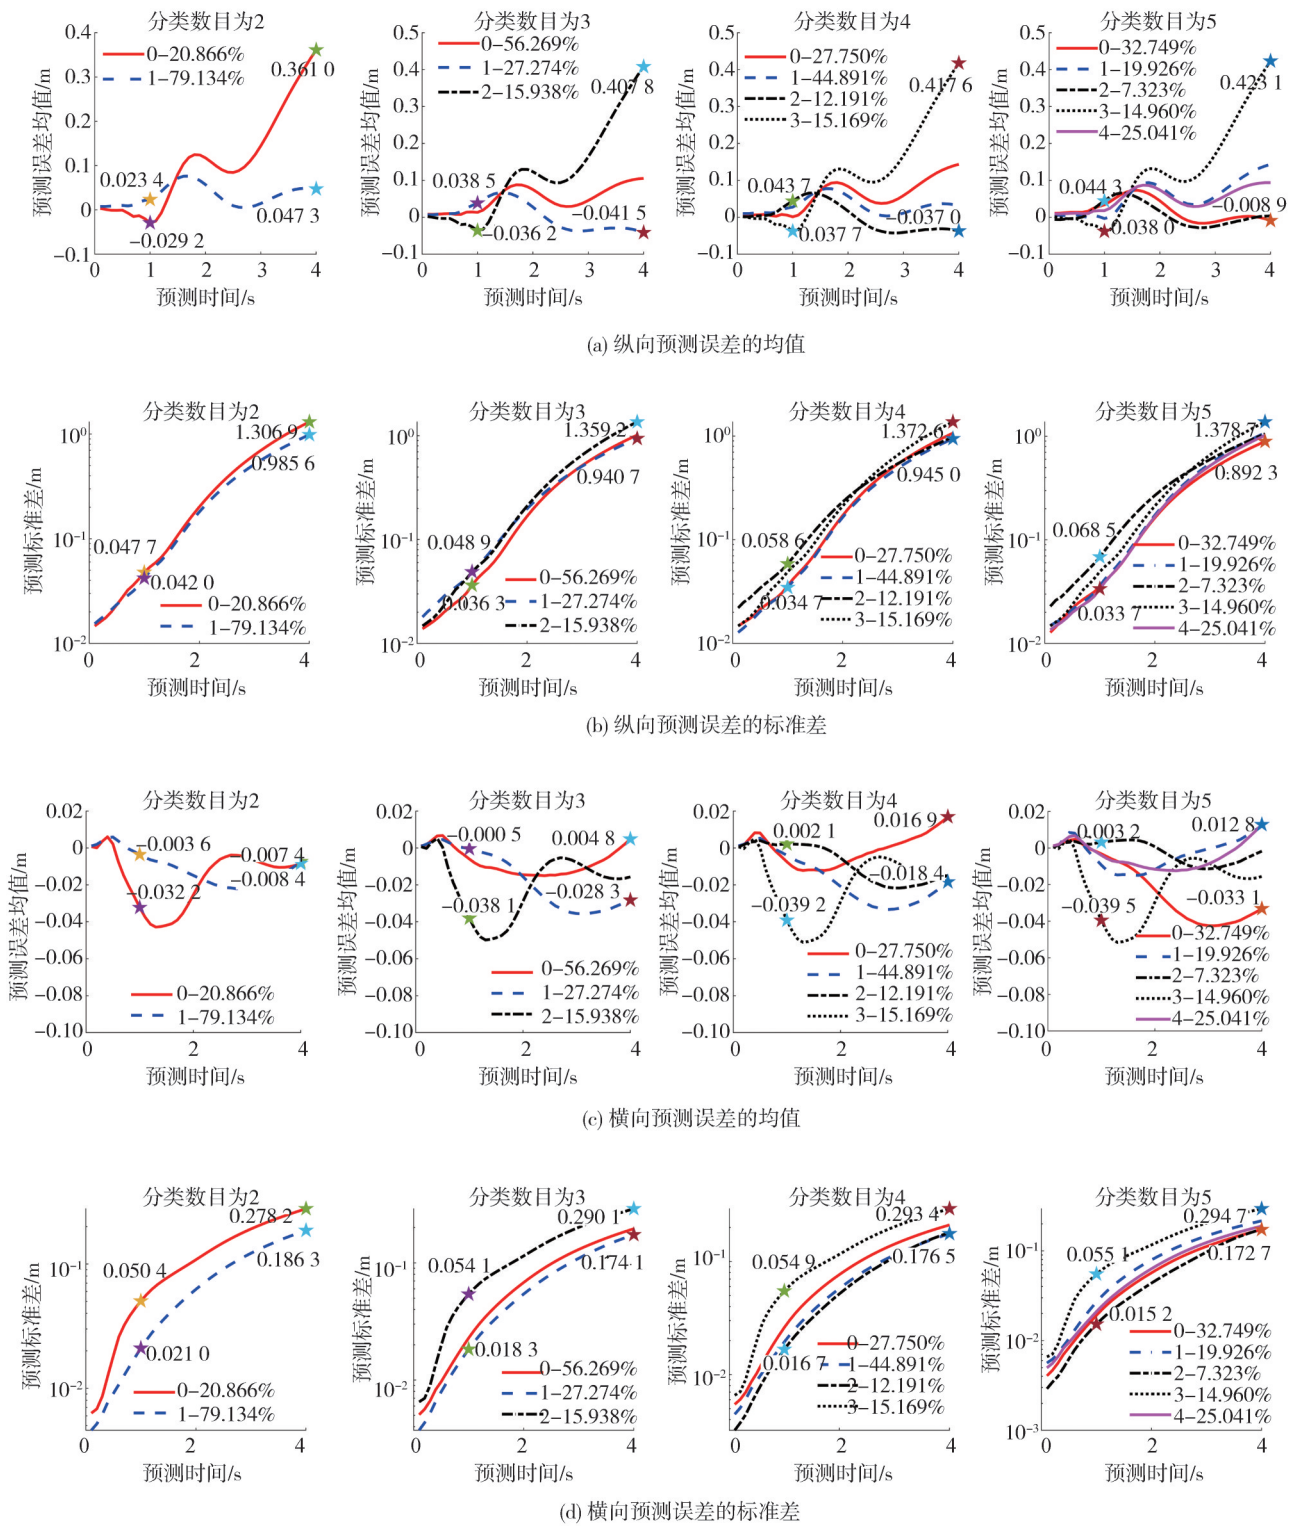


图3 不同簇对应的轨迹预测误差

图3(a)给出了纵向预测误差均值随着预测时间的变化,可见无论聚类簇数 $k$ 的取值如何,始终存在一簇其预测误差均值偏离0值较远,其占比约为

15%左右,表明该簇对应的样本对预测算法具有较大挑战。图3(b)给出了纵向预测误差标准差随预测时间的变化,与图3(a)一致的是,以聚类簇数 $k =$

3为例,类别2的预测误差标准差取值最大,相较于类别0,在4.0 s增加44.45%,表明算法在面对复杂度标签为2的样本时,性能均劣于其他类别。因此,聚类模型可一定程度上描述驾驶场景的纵向复杂度,并反映在轨迹预测算法的精度上。

由图3(c)可见,算法的横向预测误差均值与预测时间、聚类的类别关联性小,且维持在较小范围( $< 0.05$  m)。图3(d)与图3(b)一致的是,随预测时间增加,因驾驶员、交通态势等差异性,横向预测误差标准差也随之增加。对比不同聚类类别的误差标准差分布,当聚类簇数 $k=2$ 或 $k=3$ 时,类别之间差异较大,而当 $k=4$ 或 $k=5$ 时,类别间的差异减小。这佐证了当选择 $k=3$ (表1确定的最优聚类簇数),本文聚类模型能表征驾驶场景的横向复杂度,并反映在轨迹预测算法上。

图4给出了将驾驶场景复杂度分为3类后每类数据在4 s的轨迹预测误差分布及其正态分布拟合结果。相较于拟合分布,原始误差分布的中间区域的密度/占比更高,即:正态分布拟合结果会略微放大预测误差的存在,认为碰撞概率会偏大,用于决策时也可接受。

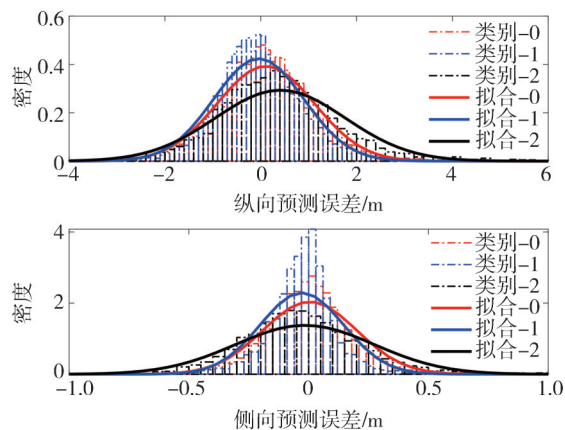


图4 不同类别在第4 s预测的误差分布

另一方面,考虑到不同类别间的样本数目存在差异,使用威尔克森秩和检验对两两类别对应预测误差之间的差异性进行检验,显著性 $P$ 值取0.05,结果如表3所示。可看到3个类别在纵向预测误差上两两之间都存在显著差异( $P < 0.05$ ),在横向预测误差上类别0与类别1、类别2分别呈现了显著性差异,但类别1与类别2之间并无显著差异( $P$ 值为0.106),即不能拒绝原假设“两个类别具有相同的分布、具有相同的中位数”。事实上,在计算碰撞概率

时除预测误差均值外,还须考虑标准差、扁平程度。类别1与2对应的4.0 s横向预测误差的标准差取值分别为0.174与0.290 m,后者比前者大66.63%,因此两者在对象状态相同时算得的碰撞概率也有差异。

表3 不同类别预测误差的显著性分析

纵向预测误差	类别0-类别1	类别0-类别2	类别1-类别2
Z值	-12.907	-2.693	-11.569
P值	< 0.001	0.007	< 0.001
横向预测误差	类别0-类别1	类别0-类别2	类别1-类别2
Z值	-9.313	-7.949	-0.781
P值	< 0.001	< 0.001	0.106

综上,不同驾驶复杂度标签类别对应轨迹预测精度存在显著性差异,证明了驾驶场景分类的有效性。

### 3 考虑场景复杂度的自动驾驶决策

#### 3.1 基于博弈的自动驾驶决策算法

场景复杂度评估可实时获取车辆轨迹预测的不确定性,确立预测轨迹的分布,计算碰撞风险、根据风险阈值筛选潜在的冲突对象,辅助对交互决策问题的灵活定义。以匝道汇流场景为例,本文将决策建模为广义纳什均衡问题<sup>[18]</sup>,并从前述CHN-Merging-ZS数据集提取汇流成功的1 100组数据用于测试。下面对比了所提算法PAs和对照算法CAs,其中PAs考虑3类场景复杂度并评估预测算法不确定性,而CAs不同之处在于认为所有驾驶场景同属于一个复杂度类别。

#### 3.2 结果对比

如表4所示,PAs算法实时性能优于CAs,在第50百分位及以后尤为明显。PAs求解耗时的第99百分位数相较于CAs,改善约80%,即该算法能显著降低复杂环境下的求解耗时、提升实时性。这是由于复杂度评估模块通过图模型实现场景特征抽象,获得态势复杂度标签,赋予决策算法对态势更加准确的理解。

进一步地,采用3个指标评估决策效果。其中:并道刚蹭定义为车辆在汇流过程中与他车碰撞;并道失败定义为车辆虽未与他车碰撞,但未在匝道终点前成功并入主道。如表5所示,加入复杂度评估可降低并道失败率、并道刚蹭率各约38.56%、92.65%,提升并道成功率。

表4 算法实时性对比( $P_i$ 表示第*i*百分位)

算法	求解耗时/ms				
	$P_1$	$P_{10}$	$P_{50}$	$P_{90}$	$P_{99}$
PAs	11.66	14.14	32.87	165.22	209.29
CAs	12.60	14.56	56.56	218.64	1055.5

表5 算法汇流决策性能对比 %

算法	并道成功率	并道失败率	并道刚蹭率
PAs	98.37	1.45	0.18
CAs	95.18	2.36	2.45

### 3.3 案例分析

图5对比了人类驾驶员(HVs)、PAs、CAs在面对同一场景时的决策及运动轨迹。可发现,相较于CAs与HVs,PAs考虑了复杂度评估,能实时把握所处交通态势变化,更快完成汇流任务,成功并入主车道。

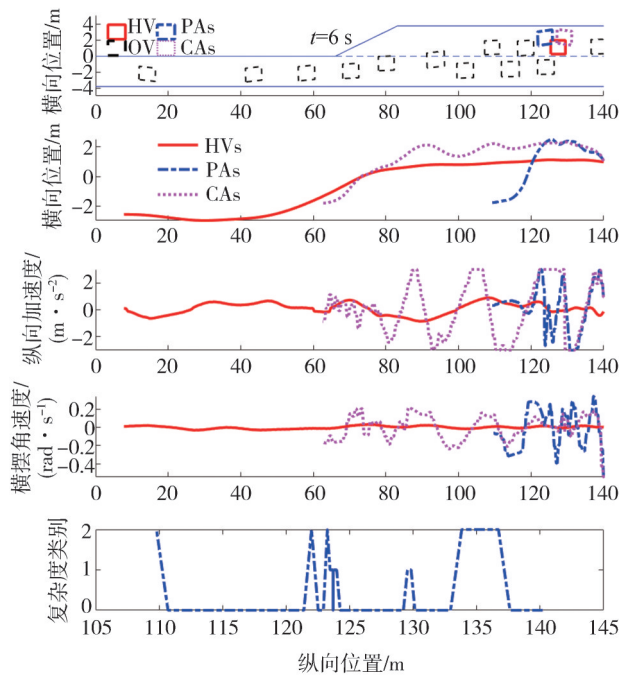


图5 场景复杂度应用于自动驾驶决策

### 3.4 实车在环试验

基于数字孪生方式,将上述算法部署于试验车,车辆状态实时同步至孪生空间、接受虚拟交通流信息注入,实现安全性与真实性的权衡。测试车辆为魏牌VV6,轴距2.68 m、质心距前轴1.13 m、整车质量2 030 kg,采用2.0T发动机和7DCT变速器。如图6所示,车辆接收规控算法输出的前轮转角与纵向加速度指令,通过车载传感器(包括华测CGI610

组合惯导)实时读取车辆位姿信号,实现实车闭环试验。下层控制器为考虑时滞特性的非线性模型预测控制算法<sup>[17]</sup>,其跟踪的目标轨迹序列由本文算法输出。

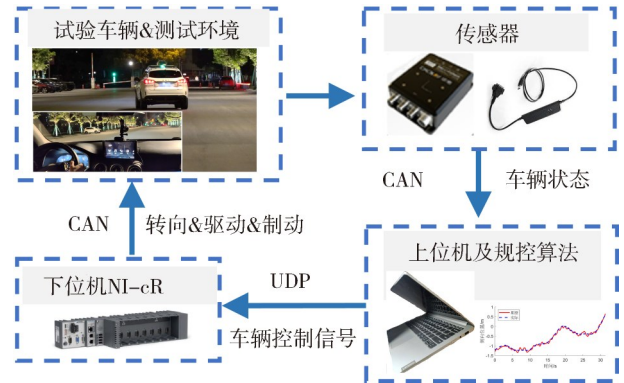


图6 实车试验示意图

匝道汇流测试的车辆状态和控制输入如图7所示。控制输入方面,由于动力和底盘系统限制,纵向加速度、前轮转角均表现出明显时滞。结果方面,全过程横向误差最大为0.23 m,速度误差最大为0.13 m/s,通过减速换道可成功并入主道,并道成功时横向移动1.9 m。因此,决策算法能实时运行,满足实际使用需求。

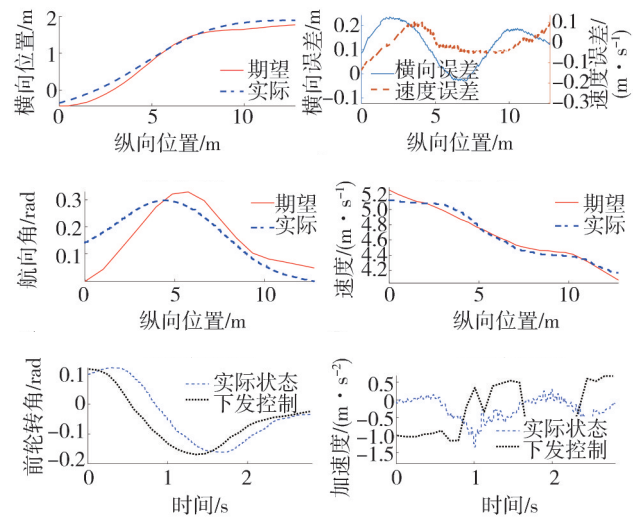


图7 实车试验结果

## 4 结论

(1) 采用无向节点标签图对动态交通元素状态和元素间交互关系进行建模,并利用无监督学习赋

予场景复杂度的标签,能有效评估复杂态势,而无需额外驾驶任务信息。

(2) 提出了基于TCN和GAT的轨迹预测算法,增加场景复杂度评估模块,提前推理预测算法不确定性,实现对复杂态势更准确可靠的预测。

(3) 将复杂度评估应用于驾驶决策,仿真表明可提升交通态势认知能力、改善决策算法的实时性与最优性。实车测试验证了决策算法的实时性和可跟踪性能,展示了应用潜力。

本文尚未考虑场景复杂度评估精度对决策性能的具体影响程度。未来可针对交叉口、机非混行等挑战场景,细化场景复杂度评估对局部态势认知的影响,继而扩展在复杂交互驾驶决策算法的有效应用。

### 参考文献

- [1] SEMNANI S H, LIU H, EVERETT M, et al. Multi-agent motion planning for dense and dynamic environments via deep reinforcement learning[J]. *IEEE Robotics and Automation Letters*, 2020, 5(2): 3221-3226.
- [2] 肖婷. 智能车在复杂环境下的路径规划与跟随控制算法研究[D]. 长春: 吉林大学, 2019.  
XIAO T. Research on the path planning and the tracking control algorithm of the intelligent vehicle in complex environment [D]. Changchun: Jilin University, 2019.
- [3] 陆敏敏. 复杂环境动态约束下多智能体编队预测控制[D]. 上海: 上海交通大学, 2020.  
LU M M. Predictive control of multi-agent formation with dynamic constraints in complex environment [D]. Shanghai: Shanghai Jiao Tong University, 2020.
- [4] 陈尧. 基于强化学习的复杂环境自动驾驶运动规划[D]. 哈尔滨: 哈尔滨工业大学, 2020.  
CHEN Y. Motion planning of autonomous vehicles in complex environment based on reinforcement learning [D]. Harbin: Harbin Institute of Technology, 2020.
- [5] CANTIN V, LAVALLIÈRE M, SIMONEAU M, et al. Mental workload when driving in a simulator: effects of age and driving complexity[J]. *Accident Analysis & Prevention*, 2009, 41(4): 763-771.
- [6] DUAN J, GAO F, HE Y. Test scenario generation and optimization technology for intelligent driving systems[J]. *IEEE Intelligent Transportation Systems Magazine*, 2022, 14(1): 115-127.
- [7] LIU Y, HANSEN J H L. Towards complexity level classification of driving scenarios using environmental information[C]. 2019 IEEE Intelligent Transportation Systems Conference (ITSC). 2019: 810-815.
- [8] 张海潮. 基于引力模型的道路交通环境复杂度研究[D]. 北京: 北京理工大学, 2016.  
ZHANG H C. Research on complexity of road traffic environment based on gravity model [D]. Beijing: Beijing Institute of Technology, 2016.
- [9] CHENG Y, LIU Z, GAO L, et al. Traffic risk environment impact analysis and complexity assessment of autonomous vehicles based on the potential field method[J]. *International Journal of Environmental Research and Public Health*, 2022, 19(16): 10337.
- [10] YU R, ZHENG Y, QU X. Dynamic driving environment complexity quantification method and its verification[J]. *Transportation Research Part C: Emerging Technologies*, 2021, 127: 103051.
- [11] FISAC J F, BRONSTEIN E, STEFANSSON E, et al. Hierarchical game-theoretic planning for autonomous vehicles[C]. 2019 International Conference on Robotics and Automation (ICRA), 2019: 9590-9596.
- [12] FRIDOVICH-KEIL D, RATNER E, PETERS L, et al. Efficient iterative linear-quadratic approximations for nonlinear multi-player general-sum differential games[C]. 2020 IEEE International Conference on Robotics and Automation (ICRA), 2020: 1475-1481.
- [13] LE CLEAC' H S, SCHWAGER M, MANCHESTER Z. ALGAMES: a fast augmented Lagrangian solver for constrained dynamic games[J]. *Autonomous Robots*, 2022, 46(1): 201-215.
- [14] 刘天明. 多车冲突风险下自动驾驶交互策略[D]. 杭州: 浙江大学, 2022.  
LIU G M. Interaction strategy for automated driving considering the risk of multi-vehicle conflict [D]. Hangzhou: Zhejiang University, 2022.
- [15] LI D, PAN H, XIAO Y, et al. Social-aware decision algorithm for on-ramp merging based on level-k gaming[C]. 2022 IEEE 18th International Conference on Automation Science and Engineering (CASE), 2022: 1753-1758.
- [16] EVENS B, SCHUURMANS M, PATRINOS P. Learning MPC for interaction-aware autonomous driving: a game-theoretic approach[C]. 2022 European Control Conference (ECC), 2022: 34-39.
- [17] PAN H, XIAO B, CHEN L, et al. A safe and efficient decision algorithm for ramp merging based on a hierarchical planner and model predictive control[J]. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2023: 09544070231182192.
- [18] 潘豪. 复杂环境下面向灵活决策的自动驾驶算法研究[D]. 杭州: 浙江大学, 2024.  
PAN H. Research on autonomous driving algorithm for flexible decision-making in complex environment [D]. Hangzhou: Zhejiang University, 2024.