

# 基于高斯混合-隐马尔可夫模型的驾驶意图识别\*

沈瑜<sup>1,2</sup> 刘广辉<sup>2</sup> 马翔鹏<sup>1</sup> 许佳文<sup>2</sup> 严源<sup>2</sup>

(1. 甘肃民族师范学院信息工程学院, 合作 747000; 2. 兰州交通大学电子与信息工程学院, 兰州 730070)

**【摘要】**为了实现高速公路场景下车辆驾驶意图的精准识别,提出一种Frenet坐标系下双参考线高斯混合与隐马尔可夫融合的驾驶意图识别模型。根据车辆位置选取Frenet坐标系下不同参考线的行驶数据作为模型观测变量,将前、后时刻高斯混合模型输出的观测概率联合隐马尔可夫模型,识别当前时刻车辆驾驶意图。采用NGSIM中US-101数据集验证模型效果,结果表明:双参考线的高斯混合-隐马尔可夫模型对车道保持、车辆变道识别准确率分别达到93.33%、92.24%,具有良好的识别效果。

**主题词:** 自动驾驶 驾驶意图识别 高斯混合模型 隐马尔可夫模型 Frenet坐标系

**中图分类号:** U463.6 **文献标志码:** A **DOI:** 10.19620/j.cnki.1000-3703.20231201

## Driving Intention Recognition Based on Gaussian Mixture-Hidden Markov Model

Shen Yu<sup>1,2</sup>, Liu Guanghui<sup>2</sup>, Ma Xuanpeng<sup>1</sup>, Xu Jiawen<sup>2</sup>, Yan Yuan<sup>2</sup>

(1. School of Information Engineering, Gansu Minzu Normal University, Hezuo 747000; 2. School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070)

**【Abstract】**To achieve accurate recognition of vehicle driving intentions in highway scenarios, this paper proposes a driving intention recognition model that combines dual reference lines in the Frenet coordinate with Gaussian Mixture Models (GMMs) and Hidden Markov Models (HMMs). The model selects driving data from different reference lines in the Frenet coordinate based on vehicle position as observed variables. By integrating the observation probabilities output by the GMM at previous and subsequent time steps with the HMM, the model identifies the vehicles' driving intention at the current moment. The effectiveness of the model is validated using the US-101 dataset from NGSIM. The results show that the dual-reference-line GMM-HMM model achieves recognition accuracies of 93.33% for lane keeping and 92.24% for lane changing, indicating excellent recognition performance.

**Key words:** Autonomous driving, Driving intention recognition, Gaussian Mixture Model (GMM), Hidden Markov Model (HMM), Frenet coordinate

**【引用格式】** 沈瑜, 刘广辉, 马翔鹏, 等. 基于高斯混合-隐马尔可夫模型的驾驶意图识别[J]. 汽车技术, 2025(5): 22-28.

SHEN Y, LIU G H, MA X P, et al. Driving Intention Recognition Based on Gaussian Mixture-Hidden Markov Model[J]. Automobile Technology, 2025(5): 22-28.

## 1 前言

道路交通事故原因分析表明,约四分之一的安全事故源于驾驶意图传达不明确<sup>[1]</sup>。因此,准确识别驾驶意图,提高车辆行驶安全性,已成为当前自动驾驶技术领域关注的焦点。

目前,驾驶意图识别方法主要分为基于规则(Rule-

Based)和基于深度学习的方法。基于规则的识别方法将驾驶经验转化为知识,并将提取出相应规则,应用于驾驶意图识别<sup>[2]</sup>。Bouchard等<sup>[3]</sup>基于双层规则理论,根据设计规则和环境状态感知识别驾驶意图,模型在可解释性和安全性方面表现良好,但受限于规则引擎的固有缺陷,泛化能力不足。Bhattacharyya等<sup>[4]</sup>提出了基于规则与数据驱动协同识别驾驶意图的方法,结合车辆行驶

\*基金项目:国家自然科学基金项目(62241106,61861025);甘肃省重点研发计划(24YFGA037);甘肃省科技专员专项(23CXGA0008);“智慧天路”建设重大专项(2023QZzht1102);兰州局集团公司科技研究开发计划(LZJKY2024079-1);中国国家铁路集团有限公司重点课题(N2023X050);兰州交通大学重点研发项目(LZJTU-ZDYF2305)。

参数,通过规则确定基本驾驶意图,同时优化参数以匹配真实驾驶行为。该方法提升了驾驶意图识别的可解释性和真实性,但在实时性和泛化性方面仍有改进空间。基于规则的方法适用于简单交通场景,其效率和可靠性较高,但因面对复杂或未知场景的覆盖率较低,识别的准确性与适应性存在一定局限性<sup>[5]</sup>。

基于深度学习的方法已成为主流的驾驶意图识别方法,Zyner<sup>[6]</sup>基于递归神经网络(Recursive Neural Network, RNN)预测方法,从激光雷达的跟踪系统中获取数据,用于变道行为的驾驶意图识别。Fang等<sup>[7]</sup>基于深度神经网络(Deep Neural Networks, DNN)的驾驶意图识别模型,融合目标车辆与周围车辆的交互信息、道路信息和车辆状态,识别混合交通流中的驾驶意图,并通过NGSIM(Next Generation Simulation)数据集验证提出方法的有效性。张新锋等<sup>[8]</sup>提出了融合注意力机制和残差卷积的双向长短时记忆(Bi-directional Long Short-Term Memory, Bi-LSTM)识别模型,该模型在特征自动提取和时序依赖建模中优势显著,但其鲁棒性较低。Liu等<sup>[9]</sup>提出基于隐马尔可夫模型(Hidden Markov Model, HMM)的车辆驾驶意图识别方法,并使用自建天桥环境数据训练和测试驾驶意图识别模型。赵建东等<sup>[10]</sup>结合卷积神经网络(Convolutional Neural Networks, CNN)和门控循环单元(Gated Recurrent Unit, GRU),并利用注意力机制构建变道意图识别模型,综合考虑了车辆行驶中的时序特征和空间特征。基于深度学习方法能够提升模型识别的准确率,但缺乏可解释性和扩展性,对于数据波动无法及时处理,性能会有所下降。

因此,本文采用双参考线高斯混合-隐马尔可夫模型(GMM-HMM)模型,通过Frenet坐标系下两条参考线的动态切换,更精确地捕捉车辆在不同车道位置下的驾驶意图特征。利用高斯混合(Gaussian Mixture Model, GMM)模型对驾驶行为空间分布的多模态特性,结合HMM的时间序列分析能力,提升变道意图的早期识别率。同时,通过引入双参考线机制,在保持强可解释性的基础上,增强模型对不同道路场景的泛化性。

## 2 数据处理

### 2.1 NGSIM数据集

本文基于NGSIM数据集的多维度驾驶行为特征,构建驾驶意图识别数据集。该数据集由目标路段顶部的高性能摄像机拍摄,提取车辆水平坐标、垂直坐标、速度、加速度等特征,采样频率为10 Hz。选择高速公路场

景下的US-101路段,道路拓扑结构如图1所示。其中,1~5号车道为道路主要车道,6号车道为集散车道,7号、8号车道分别为匝道的入口和出口。




图1 US-101道路拓扑结构

### 2.2 数据预处理

由于NGSIM数据集由多个摄像机拍摄视频获取车辆轨迹信息,在数据拼接、融合过程中容易出现较大误差,因而需要对数据进行预处理。数据集中部分特征参数说明如表1所示。

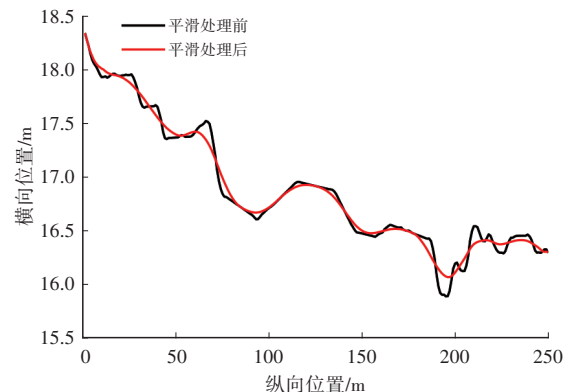
表1 NGSIM数据集参数

参数	含义	参数	含义
Vehicle_ID	车辆序号	Global_X,Y	全局坐标
Frame_ID	时间帧序号	Local_X,Y	局部坐标
Global_Time	全局时间	v_Vel,Acc	速度和加速度
Lane_ID	车道序号	v_Length,Width	长度和宽度


驾驶意图样本数据提取与处理过程如下:

a. 筛选数据:本文暂不考虑存在强制性变道的第6~8号车道,仅考虑1~5号车道的数据。在US-101场景中主要包括3种类型车辆,分别为摩托车、大型车辆和中小型汽车,其中,汽车占比为96.1%。鉴于不同车型的驾驶习惯差距较大,剔除大型车辆和摩托车数据,仅保留汽车类样本数据,并进行平滑处理。

b. 平滑数据:由于原始数据存在误差和噪声,需对训练数据进行平滑处理,本文采用对称指数移动平均(symmetrical Exponential Moving Average, sEMA)滤波算法对原始数据的横向位置 $Y$ 、速度 $v$ 进行处理。以数据集中一个车辆轨迹为例,平滑处理结果如图2所示。



(a)位置平滑



(b)速度平滑

图2 车辆数据平滑结果

### 2.3 Frenet坐标系下特征提取

Frenet坐标系<sup>[11]</sup>以车道左、右边缘线为参考线 $r(s)$ ,通过将车辆位置向参考线投影,定义投影距离和沿参考线累积弧长,将车辆笛卡尔坐标转换为Frenet坐标。假设在笛卡尔坐标系中,车辆位置为 $N(x,y)$ ,从点 $N$ 向参考线 $r(s)$ 投影,投影点为 $M$ ,则投影点 $M$ 到点 $N$ 的距离为车辆相对于参考线的横向位移 $l$ ,从参考线的起始点 $F$ 到投影点 $M$ 的曲线距离为车辆相对于参考线的纵向位移 $d$ 。在Frenet坐标系下,使用横向位移和纵向位移描述车辆位置 $(l,d)$ 。两坐标系的映射关系为 $r(s),(x,y) \leftrightarrow (l,d)$ 。

由于车辆的行驶轨迹无法与参考线完全重合,需要利用参考线描述车辆的运动状态。本文以车道的左、右边缘线为参考线,根据车辆位置选择所需的参考线。当车辆位于车道左侧时,选择车道左边缘线为参考线,车辆的运动状态为 $[l_{Left}, v_{l,Left}, d_{Left}, v_{d,Left}]$ 。其中, $l_{Left}, d_{Left}$ 分别为参考方向的纵向位移和垂直参考方向的横向位移, $v_{l,Left}, v_{d,Left}$ 分别为车辆纵向和横向速度。同理,当车辆位于车道右侧时,选择车道右边缘线为参考线,如图3所示,车辆运动状态为 $[l_{Right}, v_{l,Right}, d_{Right}, v_{d,Right}]$ ,车辆运动状态可作为观测变量计算驾驶意图观测概率。




图3 Frenet坐标系下车辆状态

将NGSIM数据集中车辆驾驶意图分为车道保持、左变道和右变道3类。其中,车道保持为车辆在行驶过

程中未跨越车道边缘线,车辆变道为横跨车道边缘线两侧的过程。为了确定各类驾驶意图的样本数量,通过Vehicle\_ID获取车辆行驶数据,并根据行驶数据中Lane\_ID的变化确定变道时刻。从变道时刻的Frame\_ID向前回溯纵向位移 $l_{Left}$ 和纵向速度 $v_{l,Left}$ ,如果连续3帧数据的 $l_{Left}$ 递减且 $v_{l,Left} \neq 0$ ,则下一帧数据作为左变道的起始帧 $F_{start}$ ,从变道时刻Frame\_ID向后回溯 $l_{Left}, v_{l,Left}$ ;如果连续3帧数据的 $l_{Left}$ 不变,则下一帧数据作为左变道终止帧 $F_{end}$ 。位于 $[F_{start}, F_{end}]$ 的数据为左变道过程的样本,同理可标注右变道样本,剩余数据则标注为车道保持样本。

结合驾驶意图的提取情况,由于大多数车辆在行驶过程中未发生变道行为,所以车道保持样本数量相对较多。筛除6~8号车道数据后,结合道路行驶方向,右变道样本数量较少。最终,本文样本共6154组,其中,车道保持、左变道和右变道的样本数量分别为5344组、559组和256组。

### 3 高斯混合-隐马尔可夫模型构建

高斯混合模型具有较好的计算特性,通过GMM拟合车辆横向位置、横向速度等连续观测变量,计算驾驶意图的概率分布,可作为HMM的输入。而驾驶行为具有连续时序性,隐马尔可夫模型通过状态转移概率与历史观测序列的动态关联,可有效建模并识别驾驶意图的概率分布<sup>[12]</sup>。因此,本文使用GMM-HMM驾驶意图识别模型,其结构如图4所示。

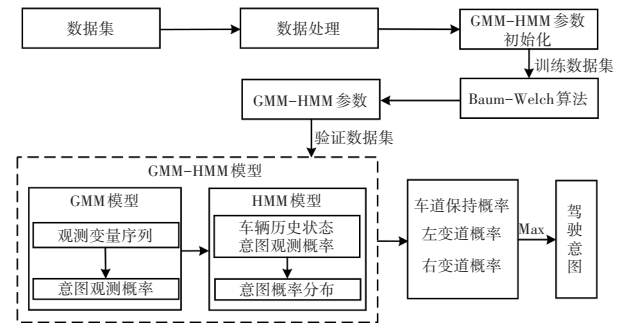


图4 GMM-HMM模型框架

#### 3.1 高斯混合模型

当样本数据 $x$ 为多维数据时,多变量高斯分布的概率密度函数为:

$$g(x; \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{(x - \mu)^T \Sigma^{-1} (x - \mu)}{2}\right) \quad (1)$$

式中: $x$ 为 $D$ 维列向量, $\mu, \Sigma$ 分别为样本的均值矩阵和协方差矩阵。

高斯混合模型是由多个单高斯模型组合而成的概  
汽车技术

率模型<sup>[13]</sup>,各模型均符合单高斯分布,因此,高斯混合模型可表示为:

$$\begin{cases} G(\mathbf{x}) = \sum_{k=1}^K \alpha_k g(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \\ \sum_{k=1}^K \alpha_k = 1 \end{cases} \quad (2)$$

式中: $K$ 为混合模型中单高斯模型的数量, $\alpha_k$ 为第 $k$ 个单高斯模型的权重, $g(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ 为第 $k$ 个单高斯分布, $\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k$ 分别为第 $k$ 个单高斯模型中观测变量数据的均值和协方差矩阵。

### 3.2 隐马尔可夫模型

隐马尔可夫模型由状态变量 $s$ 和观测变量 $\mathbf{o}$ 构成。状态序列 $S = \{s_1, s_2, \dots, s_T\}$ ,状态变量的值域为驾驶意图的有限集合,即 $Q = \{q_1, q_2, \dots, q_M\}$ , $M$ 为状态变量的数量;观测序列 $O = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_T\}$ ,其中, $T$ 为总时间帧数,取决于时间窗的长度;状态转移矩阵为 $A = (a_{ij} = P(s_{t+1} = q_j | s_t = q_i))$ ,其中, $a_{ij}$ 为 $t$ 时刻车辆驾驶意图 $q_i$ 在 $(t+1)$ 时刻转移至 $q_j$ 的概率;发射概率矩阵为 $B = (b_j(\mathbf{o}_t) = P(\mathbf{o}_t = v_k | s_t = q_j))$ ,其中, $b_j(\mathbf{o}_t)$ 为当驾驶意图处于 $q_j$ 时,观测到驾驶行为 $v_k$ 的概率;初始状态概率矩阵为 $\boldsymbol{\pi} = (\boldsymbol{\pi}_1, \boldsymbol{\pi}_2, \dots, \boldsymbol{\pi}_M)$ ,且满足 $\sum_{i=1}^M \boldsymbol{\pi}_i = 1$ 。因此,HMM模型由矩阵 $\boldsymbol{\pi}$ 、 $A$ 和 $B$ 构成,即 $\boldsymbol{\lambda} = [\boldsymbol{\pi}, A, B]$ 。

考虑到驾驶意图无法通过直接观测,本文将驾驶意图作为HMM的隐藏状态变量,通过观测变量获取的车辆运动状态数据,反映驾驶员的驾驶行为特征,区分不同驾驶意图。本文在Frenet坐标系下,将车道左、右边缘线作为参考线,描述车辆运动状态。以车道左边缘线为参考线时,选取车辆的 $l_{Left}$ 和 $v_{1,Left}$ 作为观测变量;以车道右边缘线为参考线时,选取 $l_{Right}$ 和 $v_{1,Right}$ 作为观测变量。因此,观测变量可表示为 $\mathbf{o} = [l_{Left} \ v_{1,Left} \ l_{Right} \ v_{1,Right}]^T$ 。

各时刻车辆隐藏状态变量为3种驾驶意图的概率分布,不同时刻的隐藏状态变量间可相互转移。 $a_{ii}$ 为任一状态保持不变的概率, $a_{ij}$ 为任两个状态相互转移的概率,则车辆驾驶意图状态转移矩阵为:

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \quad (3)$$

通过GMM拟合车辆位置、速度等连续变量的概率分布,作为驾驶意图识别HMM的观测概率。则高斯混合模型输出观测值的概率为:

$$b_j(\mathbf{o}) = \sum_{k=1}^K \alpha_{jk} g(\mathbf{o}; \boldsymbol{\mu}_{jk}, \boldsymbol{\Sigma}_{jk}), 1 \leq j \leq N \quad (4)$$

式中: $g(\mathbf{o}; \boldsymbol{\mu}_{jk}, \boldsymbol{\Sigma}_{jk})$ 为二维高斯分布概率密度函数, $\alpha_{jk}$ 为第 $j$ 个高斯分布的权重系数, $\boldsymbol{\mu}_{jk}, \boldsymbol{\Sigma}_{jk}$ 分别为第 $j$ 个高斯分

布的数据均值矩阵和协方差矩阵。

### 3.3 GMM-HMM模型

#### 3.3.1 参数学习

结合高斯混合模型,GMM-HMM模型可表示为 $\boldsymbol{\lambda} = [\boldsymbol{\pi}, A, \boldsymbol{\alpha}, \boldsymbol{\mu}, \boldsymbol{\Sigma}]$ 。已知驾驶行为序列 $O = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_T\}$ ,求解 $\boldsymbol{\lambda} = [\boldsymbol{\pi}, A, B]$ ,使 $P(O|\boldsymbol{\lambda})$ 最大。由于状态变量序列未知,可采用Baum-Welch算法<sup>[13]</sup>进行参数估计。

首先,定义 $Q$ 函数为:

$$\begin{cases} Q(\boldsymbol{\lambda}, \boldsymbol{\lambda}^{(t)}) = \sum_t \ln P(O, S | \boldsymbol{\lambda}) \cdot P(O, S | \boldsymbol{\lambda}^{(t)}) \\ \boldsymbol{\lambda}^{(t)} = (\boldsymbol{\pi}^{(t)}, A^{(t)}, B^{(t)}) \\ O = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_T\} \\ S = \{s_1, s_2, \dots, s_T\} \end{cases} \quad (5)$$

对 $Q$ 函数展开可得:

$$Q(\boldsymbol{\lambda}, \boldsymbol{\lambda}^{(t)}) = \sum_S \left[ \left( \ln \boldsymbol{\pi}(s_1) + \sum_{t=2}^T \ln a_{s_{t-1}, s_t} + \sum_{t=1}^T b_{s_t}(\mathbf{o}_t) \right) \cdot P(O, S | \boldsymbol{\lambda}^{(t)}) \right] \quad (6)$$

以参数 $\boldsymbol{\pi}$ 为例,推导求解过程得到:

$$\begin{aligned} \boldsymbol{\pi} &= \arg_{\boldsymbol{\pi}} \max \sum_S \log \boldsymbol{\pi}_{s_1} \cdot P(O, S | \boldsymbol{\lambda}^{(t)}) \\ &= \arg_{\boldsymbol{\pi}} \max \sum_{s=1}^N \log \boldsymbol{\pi}_s \cdot P(O, s_1 = s | \boldsymbol{\lambda}^{(t)}), \sum_{s=1}^N \boldsymbol{\pi}_s = 1 \end{aligned} \quad (7)$$

采用拉格朗日乘子法计算极值:

$$L(\boldsymbol{\pi}, \gamma) = \sum_{s=1}^N \left[ \ln \boldsymbol{\pi}_s \cdot P(O, s_1 = s | \boldsymbol{\lambda}^{(t)}) \right] + \gamma \left( \sum_{s=1}^N \boldsymbol{\pi}_s - 1 \right) \quad (8)$$

令 $\partial f / \partial \boldsymbol{\pi}_s = 0$ ,将 $\gamma$ 代入偏导公式,得到:

$$\boldsymbol{\pi}_s = \frac{P(O, s_1 = s | \boldsymbol{\lambda}^{(t)})}{P(O | \boldsymbol{\lambda}^{(t)})} \quad (9)$$

$P(O | \boldsymbol{\lambda}^{(t)})$ 和 $P(O, s_1 = s | \boldsymbol{\lambda}^{(t)})$ 可通过前向变量 $\alpha_t(s)$ 表示,参数 $A, B$ 求解过程同样符合上述原理。

#### 3.3.2 参数训练

模型参数学习具体步骤如下:

a. 初始化一组参数 $\boldsymbol{\lambda} = [\boldsymbol{\pi}, A, \boldsymbol{\alpha}, \boldsymbol{\mu}, \boldsymbol{\Sigma}]$ ,状态转移矩阵 $A$ 可根据经验进行初始化, $\boldsymbol{\pi}, A, \boldsymbol{\alpha}, \boldsymbol{\mu}, \boldsymbol{\Sigma}$ 根据数据分布特征进行初始化。

b. 确定模型训练所需的样本数据,即观测变量序列 $O$ 。使用Holdout验证方法,随机选择总样本的70%作为训练样本。

c. 编写MATLAB程序,初始化参数后,根据Baum-Welch算法进行参数学习。

d. 输出训练结果。

根据上述方法,得到模型的训练结果为4个二维单高斯模型,GMM-HMM模型参数为:

$$\begin{aligned}
 A &= \begin{pmatrix} 0.999 & 0.005 & 0.005 \\ 0.100 & 0.900 & 0 \\ 0.100 & 0 & 0.900 \end{pmatrix} \\
 \pi &= (0.8775 \quad 0.0899 \quad 0.0326) \\
 \mu(:, :, 1) &= \begin{pmatrix} -1.6937 \\ 0.0072 \end{pmatrix}, \Sigma(:, :, 1, 1) = \begin{pmatrix} 0.1149 & 0.0006 \\ 0.0006 & 0.0029 \end{pmatrix} \\
 \mu(:, :, 2) &= \begin{pmatrix} 1.7495 \\ 0.0083 \end{pmatrix}, \Sigma(:, :, 1, 2) = \begin{pmatrix} 0.1043 & 0.0003 \\ 0.0003 & 0.0030 \end{pmatrix} \\
 \mu(:, :, 3) &= \begin{pmatrix} -0.5816 \\ 0.0028 \end{pmatrix}, \Sigma(:, :, 1, 3) = \begin{pmatrix} 0.5817 & -0.1411 \\ -0.1411 & 0.6742 \end{pmatrix} \\
 \mu(:, :, 4) &= \begin{pmatrix} 0.9943 \\ 0.0112 \end{pmatrix}, \Sigma(:, :, 1, 4) = \begin{pmatrix} 0.0742 & -0.0005 \\ -0.0005 & 0.0006 \end{pmatrix}
 \end{aligned} \quad (10)$$

式中:  $\mu(:, :, 1)$ 、 $\Sigma(:, :, 1, 1)$  分别为以车道左边缘线为参考线, 驾驶意图为左变道特征的均值和协方差矩阵;  $\mu(:, :, 2)$  和  $\Sigma(:, :, 1, 2)$  分别为以车道右边缘线为参考线, 驾驶意图为右变道特征的均值和协方差矩阵;  $\mu(:, :, 3)$ 、 $\mu(:, :, 4)$ 、 $\Sigma(:, :, 1, 3)$ 、 $\Sigma(:, :, 1, 4)$  分别为以车道两侧(左侧和右侧)边缘线为参考线, 驾驶意图为车道保持特征的均值和协方差矩阵。

GMM-HMM 模型输出观测概率如图 5 所示。其中, 左侧 2 个椭圆表示以车道左边缘线为参考线的观测变量分布特征; 右侧 2 个椭圆表示以车道右边缘线为参考线的观测变量分布特征; 椭圆的长、短半轴表示对应方向观测变量的标准差; 椭圆的中心位置表示每个单高斯分布的观测变量均值。




图5 GMM-HMM模型输出观测概率结果

#### 4 驾驶意图识别

单独时刻驾驶车辆观测值无法体现驾驶意图, 可通过连续驾驶动作进行推理, 根据过去连续  $T$  时间段内的驾驶动作, 识别当前时刻车辆的驾驶意图。本文使用滑动时间窗, 时间窗长度为  $T$ , 如图 6 所示。驾驶意图识别问题可描述为: 已知 GMM-HMM 参数  $\lambda = [\pi, A, \alpha, \mu, \Sigma]$ , 滑动时间窗内的驾驶动作序列为  $O = \{o_1, o_2, \dots, o_T\}$ ,

求解  $T$  时段内最有可能的状态序列  $S^* = \{s_1^*, s_2^*, \dots, s_T^*\}$ , 使  $P(O, S^* | \lambda)$  最大。通过维特比(Viterbi)算法<sup>[14]</sup>递推求解最优的状态序列  $S^*$ , 从而确定车辆的驾驶意图。






图6 滑动时间窗示意


使用总样本的 30% 数据进行模型验证, 即车道保持样本、左变道样本和右变道样本分别为 1 604 组、168 组和 77 组。以车道右边缘线为 Frenet 坐标系的参考线, 左、右变道识别过程分别如图 7、图 8 所示。



(a) 车辆横向位移变化



(b) 意图观测概率



(c) 意图识别结果

图7 左变道识别过程

以车道右边缘线为 Frenet 坐标系的参考线为例, 由图 7 可知, 第 4 s 时车辆横向位移发生改变, 逐渐靠近左车道边缘线, 同时, 车道保持意图识别概率下降, 左变道意图概率上升, 可通过比较意图概率确定最终识别结果。当左变道概率大于车道保持概率时, 识别结果将从车道保持转换成左变道。当 2.5 s 后完成左变道时, 车辆距离车道右边缘线的横向位移为 0。

本文将精确率(Precision) $P$ 、召回率(Recall) $R$ 、F1 分数和准确率(Accuracy) $A$  作为模型性能评价指标。相

关公式为:

$$\begin{aligned}
 P &= \frac{TP}{TP + FP} \\
 R &= \frac{TP}{TP + FN} \\
 F1 &= \frac{2PR}{P + R} \\
 A &= \frac{TP + TN}{TP + TN + FP + FN}
 \end{aligned}
 \quad (11)$$

式中:  $TP$  为正确识别目标驾驶意图的数量,  $FP$  为将非目标意图误判为目标意图的数量,  $TN$  为正确识别非目标意图的数量,  $FN$  为未能识别目标驾驶意图的数量。




图8 右变道识别过程

为了进一步验证本文模型的有效性,将本文模型与 RuleBased、DNN 等双参考线模型及单参考线模型 GMM-HMM\* 进行对比,结果如表 2 所示。

由表 2 可知,相比单参考线,双参考线通过提供更全面的横向位置信息,增强了 GMM-HMM 模型对车辆动态的感知,同时捕捉车辆与两侧车道的相对偏移量及变化趋势:车道保持时,两侧偏移量稳定;变道时,一侧偏移持续减小而另一侧增大,形成明显特征差异。多维观测数据提高了模型对车辆横向运动的敏感性。相较于使用单参考线的 GMM-HMM\* 模型,本文模型由于使用双参考线,车道保持准确率和变道准确率分别提高 2.19 个百分点和 3.07 个百分点,识别准确率均高于其他双参考线模型,且在精确度、召回率和 F1 分数评

价指标上优于其他模型。因此,所提出的双参考线 GMM-HMM 模型在识别实际驾驶员的驾驶意图中更具优势。

表 2 模型对比结果 %

模型	驾驶意图	评价指标				
		精确度	召回率	F1 分数	车道保持准确率	变道准确率
RuleBased	车道保持	81.00	90.33	85.41	90.33	85.83
	左变道	96.92	86.41	91.36		
	右变道	78.55	83.28	80.84		
DNN	车道保持	84.03	88.56	86.24	88.56	81.69
	左变道	92.41	78.85	85.09		
	右变道	77.34	88.06	82.35		
RNN	车道保持	82.37	87.43	84.82	87.43	80.31
	左变道	92.95	78.47	85.10		
	右变道	74.53	84.24	79.09		
GRU	车道保持	75.78	84.91	80.09	84.91	73.86
	左变道	92.49	71.60	80.71		
	右变道	69.82	78.93	74.09		
LSTM	车道保持	84.56	90.11	87.25	90.11	81.98
	左变道	99.45	80.86	89.20		
	右变道	71.82	84.39	77.60		
DNN-HMM	车道保持	87.67	91.77	89.67	91.77	88.91
	左变道	96.00	90.58	93.21		
	右变道	85.75	85.32	85.53		
GMM-HMM*	车道保持	90.74	91.14	90.94	91.14	89.57
	左变道	93.47	92.13	92.79		
	右变道	82.69	83.98	83.33		
本文	车道保持	93.43	93.33	93.38	93.33	92.24
	左变道	95.11	93.92	94.51		
	右变道	87.12	89.84	88.46		

## 5 结束语

本文提出的双参考线 GMM-HMM 模型充分考虑了车辆行驶过程中时间的连续性,能够根据观测变量准确识别驾驶意图。该模型可应用于智能驾驶领域,通过识别危险换道行为,优化自主换道过程,提前预警可能的危险情况,对提高驾驶主动安全性、改善车辆的智能决策和交互能力有重要意义。

由于试验样本数量有限,且仅考虑车辆变道和车道保持的相关信息,后续将综合考虑道路环境、周围车辆等因素对意图识别的影响。同时,探究复杂道路(如交叉路口、坡道等)条件下,超车、转向等驾驶意图识别。

## 参 考 文 献

- [1] WANG Z C, FENG Q, LUO M, et al. Efficient FSS-Based Private Statistics for Traffic Monitoring[C]// 2024 IEEE 23rd International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom). Sanya, China: IEEE, 2024: 1361-1370.
- [2] KHELFA B, BA I, TORDEUX A. Predicting Highway Lane-Changing Maneuvers: A Benchmark Analysis of Machine and Ensemble Learning Algorithms[J]. *Physica A: Statistical Mechanics and its Applications*, 2023, 612.
- [3] BOUCHARD F, SEDWARDS S, CZARNECKI K. A Rule-Based Behaviour Planner for Autonomous Driving[C]// International Joint Conference on Rules and Reasoning. Berlin, Germany: Springer, 2022: 263-279.
- [4] BHATTACHARYYA R, JUNG S, KRUSE L A, et al. A Hybrid Rule-Based and Data-Driven Approach to Driver Modeling Through Particle Filtering[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(8): 13055-13068.
- [5] 方华珍, 刘立, 顾青, 等. 自动驾驶车辆换道意图识别研究现状[J]. *工程科学学报*, 2024, 46(10): 1845-1855.  
FANG H Z, LIU L, GU Q, et al. Research Status of Lane-Changing Intention Recognition for Autonomous Vehicles[J]. *Chinese Journal of Engineering*, 2024, 46(10): 1845-1855.
- [6] ZYNER A, WORRALL S, NEBOT E. A Recurrent Neural Network Solution for Predicting Driver Intention at Unsignalized Intersections[J]. *IEEE Robotics and Automation Letters*, 2018, 3(3): 1759-1764.
- [7] FANG H Z, LIU L, GU Q, et al. Driving Intention Recognition of Human Drivers in Mixed Traffic Flow[C]// 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). Macau, China: IEEE, 2022: 153-157.
- [8] 张新锋, 王万宝, 柳欢, 等. 高速动态交通场景下自动驾驶车辆换道意图识别模型研究[J]. *汽车技术*, 2023(4): 8-15.  
ZHANG X F, WANAG W B, LIU H, et al. Research on Lane Change Intention Recognition Model of Automated Vehicle in High-Speed Dynamic Traffic Scenario[J]. *Automobile Technology*, 2023(4): 8-15.
- [9] LIU S W, ZHENG K, ZHAO L, et al. A Driving Intention Prediction Method Based on Hidden Markov Model for Autonomous Driving[J]. *Computer Communications*, 2020, 157: 143-149.
- [10] 赵建东, 赵志敏, 屈云超, 等. 轨迹数据驱动的车辆换道意图识别研究[J]. *交通运输系统工程与信息*, 2022, 22(4): 63-71.  
ZHAO J D, ZHAO Z M, QU Y C, et al. Vehicle Lane Change Intention Recognition Driven by Trajectory Data[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2022, 22(4): 63-71.
- [11] DO J Y, HAN K, CHOI S B. Lane Change-Intention Inference and Trajectory Prediction of Surrounding Vehicles on Highways[J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(7): 3813-3825.
- [12] FANG J W, WANG F, XUE J R, et al. Behavioral Intention Prediction in Driving Scenes: A Survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(8): 8334-8355.
- [13] LUO Y Q, ZHANG J Y, WANG S F, et al. A Driving Intention Prediction Method for Mixed Traffic Scenarios[C]// 2022 IEEE 7th International Conference on Intelligent Transportation Engineering (ICITE). Beijing, China: IEEE, 2022.
- [14] LV Y Z, WEI C. Multi-Objective Optimal Decision Making for Autonomous Driving Based on Multi-Modal Predicted Trajectories[C]// International Conference on Mechatronic Engineering and Artificial Intelligence (MEAI 2023). Shenyang, China: AIP Publishing, 2024.

(责任编辑 瑞 秋)

修改稿收到日期为2025年1月26日。