

DOI: 10.19650/j.cnki.cjsi.J2311672

复杂交通流下基于卡尔曼滤波的多目标全生命周期状态估计*

刘明杰, 陈俊虎, 刘平, 陈俊生, 朴昌浩
(重庆邮电大学自动化学院 重庆 400065)

摘要:针对复杂行车环境下噪声干扰和车辆行车过程中状态变化导致交通场景中目标状态估计精度低的问题,以毫米波雷达为检测传感器,提出涵盖参数初始化和在线更新的基于卡尔曼滤波的多目标全生命周期状态估计方法。首先,建立交通流下多目标运动状态的卡尔曼滤波状态估计模型;基于此,一方面提出基于数据驱动的卡尔曼滤波观测噪声协方差矩阵初始化的新方法,另一方面采用变分贝叶斯方法对卡尔曼滤波参数进行在线更新,以此提高多目标状态估计精度;最后,在算法实现步骤的基础上,利用实车数据开展测试验证工作。实验结果表明,方法的目标状态估计均方误差为0.153,相较于传统卡尔曼滤波减小了36.2%,证明所提出方法对提升车辆感知精度的有效性。

关键词: 多目标状态估计;卡尔曼滤波;参数初始化;参数在线更新

中图分类号: TH741 TP273 **文献标识码:** A **国家标准学科分类代码:** 580.99

Kalman filter-based multi-object full lifecycle state estimation in complex traffic flow scenario

Liu Mingjie, Chen Junhu, Liu Ping, Chen Junsheng, Piao Changhao

(School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Object state estimation always suffers low accuracy in complex traffic flow scenario due to noise interference and vehicle driving state changing. To solve these problems, a Kalman filter-based multi-object full lifecycle state estimation method is proposed for millimeter-wave radar, which includes both parameter initialization and online updating. Firstly, the Kalman filtering-based model is designed for multi-object full lifecycle state estimation in complex traffic flow scenario. Then, a data-driven approach is innovatively proposed for the observation noise covariance matrix initialization in Kalman filter. Furtherly, a variational Bayesian method is applied to update the Kalman filter parameters online for further enhancing the accuracy of multi-object full lifecycle state estimation. Finally, experimental data collecting from real vehicles are utilized to analyze the proposed method. The results show that the mean square error of this method is 0.153 in multi-object state estimation, which is reduced by 36.2% when compared with that of traditional Kalman filter. The comparison results evaluate the effectiveness of the proposed method on vehicle perception.

Keywords: multi-object state estimation; Kalman filtering; parameters initialization; parameters online updating

0 引言

自动驾驶车辆(self-driving vehicle, SDV)因其行驶过程中的智能性,在军事和民用领域得到了广泛关注。而在自动驾驶相关技术中,复杂交通场景下的多目标运动状态

最优估计是保证自动驾驶行车安全的关键^[1]。车辆可利用自身搭载的摄像头、毫米波雷达、激光雷达等传感器得到自身车辆周围多个目标运动状态的观测值,结合目标运动模型,通过滤波算法^[2-3]可实现目标运动状态的最优估计。卡尔曼滤波(Kalman filter, KF)^[4-5]作为经典的预测算法,被广泛应用于目标运动状态的最优估计中。

行驶车辆可描述为一个包含了运动模型和测量模型的离散运动系统^[6]。其中,运动模型可通过建立车辆运动数学模型描述,测量模型则可通过各类传感器对目标运动状态的感知进行描述^[7]。一方面,目标运动状态建模是影响目标运动状态估计的关键技术之一。卡尔曼滤波是基于模型的建模,状态量不符合系统模型的部分会被当作噪声滤除。因此,建立与实际系统状态变化规律一致的系统模型,可以有效提高估计精度,防止系统发散。另一方面,为真实还原车辆的行驶和感知状态,运动模型和测量模型中分别包含过程噪声 w_k 和观测噪声 v_k ,且两者随系统动态变化。根据中心极限定理,假设 w_k 和 v_k 是相互独立的随机变量,并且分别服从 $w_k \sim N(0, Q_k)$, $v_k \sim N(0, R_k)$ 的高斯分布。其中, Q_k 和 R_k 分别为过程噪声协方差矩阵和观测噪声协方差矩阵,若 Q_k 和 R_k 的值越接近系统的真实值,那么卡尔曼滤波的状态估计也就越接近实际;反之,将会导致卡尔曼滤波估计值发散。因此, Q_k 和 R_k 的值会严重影响卡尔曼滤波对目标运动状态的最优估计。

基于上述分析可知,复杂交通流下基于卡尔曼滤波的目标状态估计性能提升主要涉及两方面:目标运动状态建模和参数优化。目标运动状态建模方面, Li 等^[8] 和 Perrovskaya 等^[9] 分别假设目标相对传感器保持恒定速度和加速度行驶,并分别将相对加速度和加速度变化量看作是均值为 0 的随机干扰,建立基于匀速 (constant velocity, CV) 模型的二阶卡尔曼滤波估计和基于匀加速 (constant acceleration, CA) 模型的三阶卡尔曼滤波估计。侯德藻^[10] 提出目标相对传感器的加速度变化率保持为常数的四阶卡尔曼滤波估计,以提高运动状态估计精度。Singer^[11] 采用均值为 0 的有色噪声模型代替 CA 模型中的高斯白噪声模型来表征目标加速的变化规律,使得模型输出与目标实际加速度变化规律更加接近。Blom 等^[12] 认为使用事先假设的单模型很难准确估计目标状态变化,所以提出交互模型算法 (interactive multiple model, IMM)。IMM 使用多个模型分别表征目标可能出现的各种运动状态,构建一个包含多个滤波器,一个交互作用器和一个估计混合器的模型集合,通过交互作用估计目标运动状态。

参数优化方面, Sage 等^[13] 提出一种方差匹配算法,并将其融入卡尔曼滤波,实现对系统观测噪声和过程噪声较为准确的估计。班朝等^[14] 在 Sage-Husa 自适应滤波算法中引入渐消记忆因子的思想,实时跟踪采样观测噪声,构建二级观测噪声方差阵,实现卡尔曼滤波中参数自适应。杨菊华等^[15] 通过设计滑模观测器将系统误差,状态估计,以及均值方差引入卡尔曼滤波,修正系统输出。吕东辉等^[16] 在传统强跟踪卡尔曼滤波中新息正交原则的基础上,推导了适用处理非高斯观测噪声的强跟踪卡尔曼滤波,并将其嵌入到无迹卡尔曼滤波框架下形成适

用处理非线性系统非高斯观测噪声的强跟踪无迹卡尔曼滤波框架,该框架能够较好应对观测噪声的非高斯性。Xing 等^[17] 将 q -Rényi 核函数引入卡尔曼滤波,通过该类核函数适应不同的噪声分布,纠正系统观测值的误差,进而实现卡尔曼滤波较精确估计结果输出。Zou 等^[18] 提出了基于 Sage-Husa 噪声估计的容积卡尔曼滤波算法,该方法通过 Sage 估计器在线估计噪声的统计特性,提高滤波的实时性。同时,采用 Husa 鲁棒方法对测量协方差矩阵进行校正,抑制测量信息中的异常值。Zhang 等^[19] 在传统卡尔曼滤波算法的推导过程中重新定义了状态估计误差的判据函数。先验估计时,在协方差矩阵中加入关于输入噪声的项,基于此分别得到改进的协方差矩阵和卡尔曼增益,实现系统输出结果的优化。Zhao 等^[20] 提出了一种混合非单态模糊强跟踪卡尔曼滤波算法,该方法分别通过引入单态模糊逻辑系统和非单态模糊逻辑系统以提高在测量噪声变化和速度状态突变的复杂情况下的目标状态估计性能。Yang 等^[21] 通过在卡尔曼滤波预测阶段引入中心误差熵准则抑制粗大噪声,得到粗略的状态估计值,然后在基于贝叶斯的推理修正步骤中将其设置为先验值,进行准确的后验状态估计。

卡尔曼滤波的参数优化应该包括参数初始化和参数在线更新两方面。基于上述研究现状不难发现,现有的卡尔曼滤波参数优化主要针对系统参数的在线更新,即依据目标状态估计,采用一定的优化方法对模型参数和噪声统计特性进行估计和修正。参数的在线更新属于过程控制,需要一定的时间跨度达到目标状态最优估计,最优的参数初始化可以缩短这个时间跨度。复杂交通流下的目标运动状态估计是保证车辆安全的关键因素。因此,融合目标参数初始化和在线更新,实现从目标出现到消失的全生命周期的运动状态最优估计,对提升车辆智能驾驶具有重要意义。基于此,本文在分析了复杂交通流下基于传统卡尔曼滤波的多目标运动状态估计基础上,首次提出基于数据驱动的卡尔曼滤波观测噪声协方差矩阵初始化的新方法,然后,采用变分贝叶斯方法对卡尔曼滤波参数进行自适应在线更新,以此提高多目标全生命周期状态估计精度。

1 复杂交通流下多目标运动状态卡尔曼滤波估计模型

复杂交通场景下,车载毫米波雷达可获得目标车辆距离本车的横向距离 ($c.x$)、纵向距离 ($c.y$)、横向相对速度 ($v.x$)、纵向相对速度 ($v.y$) 等目标状态观测信息,复杂交通流下进行多目标状态观测的示意图如图 1 所示。

由图 1 可知,通过毫米波雷达可以对车辆周围多个目标运动状态进行监测。然而,复杂的交通环境以及传




图1 毫米波雷达观测的多目标状态示意图

Fig. 1 Diagram of multi-object state based on millimeter-wave radar observation

传感器制作工艺会导致基于毫米波雷达的目标观测值存在误差^[22]。为了解决此问题,卡尔曼滤波被广泛采用,其能够依据每个变量所包含的不确定信息,通过融合预测模型(数学模型)输出值和实际测量值(传感器观测值)得到更具信服力的目标状态信息^[23]。

通常,卡尔曼滤波方法针对目标状态估计建立如下离散状态空间模型:

$$\mathbf{X}_k = \mathbf{A}\mathbf{X}_{k-1} + \mathbf{w}_{k-1} \quad (1)$$

$$\mathbf{Y}_k = \mathbf{H}\mathbf{X}_k + \mathbf{v}_k \quad (2)$$

式中: $\mathbf{A}$ 表示状态转移矩阵; $\mathbf{X}_{k-1}$ 表示 $k-1$ 时刻目标真实状态; $\mathbf{w}_{k-1}$ 表示过程噪声,服从 $\mathbf{w}_{k-1} \sim N(0, \mathbf{Q}_{k-1})$; $\mathbf{Y}_k$ 为观测值; $\mathbf{H}$ 表示观测矩阵; $\mathbf{v}_k$ 表示观测噪声,服从 $\mathbf{v}_k \sim N(0, \mathbf{R}_k)$ 分布。式(1)、(2)分别表示目标运动方程和观测方程。 $\mathbf{Q}_{k-1}$ 和 $\mathbf{R}_k$ 分别为过程噪声协方差矩阵和观测噪声协方差矩阵。根据此模型,假设在 k 时刻,车载毫米波雷达感知到 m 个运动目标的状态,则 $\mathbf{Y}_k$ 为:

$$\mathbf{Y}_k = \begin{bmatrix} c, x_{k(o_1)} & c, x_{k(o_2)} & \cdots & c, x_{k(o_m)} \\ c, y_{k(o_1)} & c, y_{k(o_2)} & \cdots & c, y_{k(o_m)} \\ v, x_{k(o_1)} & v, x_{k(o_2)} & \cdots & v, x_{k(o_m)} \\ v, y_{k(o_1)} & v, y_{k(o_2)} & \cdots & v, y_{k(o_m)} \end{bmatrix} \quad (3)$$

卡尔曼滤波是利用目标前一时刻估计状态和当前时刻的观测值,通过“预测”和“修正”两步实现目标当前时刻的最优状态估计^[24]。首先,进行预测过程。通过上一时刻得到的目标状态估计值来预测当前时刻的目标状态和误差协方差。由于当前时刻目标状态估计并未包含目标当前时刻观测信息,因此预测状态被称为先验状态估计。先验状态估计和先验误差协方差分别为:

$$\mathbf{X}_{k|k-1} = \mathbf{A}\mathbf{X}_{k-1} \quad (4)$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q}_{k-1} \quad (5)$$

进一步,根据毫米波雷达感知到的观测信息对目标的先验状态估计进行修正,得到更接近目标真实状态的

目标的后验状态估计值。根据最小误差求解得到卡尔曼增益为:

$$\mathbf{K}_k = \mathbf{P}_{k|k-1}\mathbf{H}^T(\mathbf{H}\mathbf{P}_{k|k-1}\mathbf{H}^T + \mathbf{R}_k)^{-1} \quad (6)$$

利用观测信息对“预测”得到的目标先验状态进行修正,计算后验状态估计为:

$$\mathbf{X}_k = \mathbf{X}_{k|k-1} + \mathbf{K}_k(\mathbf{Y}_k - \mathbf{H}\mathbf{X}_{k|k-1}) \quad (7)$$

后验误差协方差则为:

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_{k|k-1} \quad (8)$$

此时,通过卡尔曼滤波计算便得到了由当前时刻目标的后验状态估计值 $\mathbf{X}_k$ 和误差协方差矩阵 $\mathbf{P}_k$ 计算模型。分析可知,卡尔曼滤波通过“预测”与“修正”两个步骤的交替进行,即可不断实现最新时刻目标的后验状态估计。但是,分析后也发现,卡尔曼滤波的目标状态估计精度受到过程噪声协方差矩阵 $\mathbf{Q}_{k-1}$ 和观测噪声协方差矩阵 $\mathbf{R}_k$ 等参数的影响。精确的参数初始化,以及自适应复杂交通流场景的变化,能够有效保证目标状态的最优估计。

2 多目标全生命周期运动状态最优估计

传统的参数随机初始化方法过分依赖先验经验且不具备泛化能力;同时,参数的在线更新^[25]能够确保卡尔曼滤波适应变化的工况环境,提高其鲁棒性。因此,本文从参数初始化和自适应在线更新两个方面对卡尔曼滤波算法进行优化,保证复杂交通流中目标从出现到消失全生命周期的运动状态最优估计。

2.1 基于 SVR 的目标运动状态真值标定

卡尔曼滤波中,系统观测值一般通过传感器的物理感知得到,若能够获取传感器的真值,即可利用机器学习算法实现观测噪声协方差矩阵初始化。交通流中行驶的车辆系统难以通过传统的静态测量或基于人类认知标注的方式获取目标运动状态的真值。因此,工程实际中多将高精密度测量仪器获取的观测值作为系统的真值处理^[26]。然而,传感器由于制作工艺及其应用场景中复杂环境干扰等因素^[27-29],即使高精密度测量仪器获取的目标运动状态理论值也不可避免地包含噪声和错误信息。为最大程度还原目标真实状态,向后续目标运动状态全生命周期最优估计提供数据支撑,本文采用支持向量回归(support vector regression, SVR)的方法对激光雷达(高精密度测量仪器)感知的目标运动状态数据进行拟合降噪处理,并以此作为毫米波雷达(低精密测量仪器)观测数据的真值系统。

支持向量回归是处理基于时间序列非线性系统的回归建模问题的有效方法。其核心思想是给定的样本集 $\mathbf{D} = \{(\mathbf{x}_i, y_i), i = 1, 2, \dots, l\}$, 其中 $\mathbf{x}_i \in \mathbb{R}^n$ 和 $y_i \in \mathbb{R}$ 分别表示 n 维输入变量与输出变量,通过非线性变换将样

本数据映射到高维特征空,采用函数 $f(\mathbf{x}) = \boldsymbol{\omega}\Phi(\mathbf{x}) + b$ 拟合输入变量和输出变量的关系,使得拟合值 $f(\mathbf{x})$ 和观测值 y 尽可能接近。

假设拟合值 $f(\mathbf{x})$ 与观测值 y 之间的允许最大偏差为 ε ,以 $f(\mathbf{x})$ 为中心构建宽度为 2ε 的间隔带,则问题可转化为求解满足 $f(\mathbf{x}) = \boldsymbol{\omega}\Phi(\mathbf{x}) + b$ 约束的权重 $\boldsymbol{\omega}$ 和截距 b ,构建得到的优化目标如下:

$$\min_{\boldsymbol{\omega}, b} \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^m l_{\varepsilon}(f(\mathbf{x}_i) - y_i) \quad (9)$$

式中: C 表示惩罚因子; l_{ε} 表示损失函数。

引入非负松弛变量 $\xi_i, \hat{\xi}_i$, 即允许少量样本在间隔带外,将函数的回归拟合问题转化为满足 KKT 条件的优化问题:

$$\begin{aligned} \min_{\boldsymbol{\omega}, b} \quad & \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^m l_{\Delta}(\xi_i - \hat{\xi}_i) \\ \text{s. t.} \quad & \begin{cases} \boldsymbol{\omega}\Phi(\mathbf{x}_i) + b - y_i \leq \varepsilon + \xi_i \\ y_i - \boldsymbol{\omega}\Phi(\mathbf{x}_i) - b \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \quad \hat{\xi}_i \geq 0 \end{cases} \end{aligned} \quad (10)$$

为了便于求解式(10),引入拉格朗日乘子 $\mu \geq 0$, $\hat{\mu}_i \geq 0, \alpha_i \geq 0, \hat{\alpha}_i \geq 0$, 将式(10)转化为对偶问题:

$$\begin{aligned} \max_{\alpha, \hat{\alpha}} \quad & \sum_{i=1}^m y_i(\hat{\alpha}_i - \alpha_i) - \Delta(\hat{\alpha}_i - \alpha_i) + \\ & \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\hat{\alpha}_i - \alpha_i)(\hat{\alpha}_j - \alpha_j) K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s. t.} \quad & \begin{cases} \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) = 0 \\ 0 \leq \alpha_i, \quad \hat{\alpha}_i \leq C \end{cases} \end{aligned} \quad (11)$$

式中: $K(\mathbf{x}_i, \mathbf{x}_j)$ 表示核函数,且 $\hat{\alpha}_i - \alpha_i \neq 0$ 时对应的样本 $\mathbf{x}_i$ 为支持向量。

因而,获取支持向量权重 $\boldsymbol{\omega}$ 和偏差 b 的表达式为:

$$\begin{cases} \boldsymbol{\omega} = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \Phi(\mathbf{x}_i) \\ b = \frac{1}{N_{sv}} \left\{ \sum_{0 < \alpha_i < C} [y_i - \sum_{\mathbf{x}_j \in sv} (\hat{\alpha}_j - \alpha_j) K(\mathbf{x}_i, \mathbf{x}_j) - \varepsilon] + \sum_{0 < \alpha_j < C} [y_j - \sum_{\mathbf{x}_i \in sv} (\hat{\alpha}_i - \alpha_i) K(\mathbf{x}_i, \mathbf{x}_j) - \varepsilon] \right\} \end{cases} \quad (12)$$

最终获取非线性拟合函数表达式:

$$f(\mathbf{x}) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) K(\mathbf{x}_i, \mathbf{x}_j) + b \quad (13)$$

结合上述 SVR 过程,以车辆相对横、纵向的速度与加速度为输入,车辆相对横、纵向的距离与速度为输出构建以激光雷达为感知媒介的车辆运动状态真值 SVR 标定模型,其示意图如图2所示。

本文采用网格参数寻优方法对 SVR 模型参数进行优化选取,以式(14)所示的高斯核函数为基础,基于 k 折




图2 支持向量回归结构

Fig. 2 The structure of the support vector regression

交叉验证获取最优惩罚因子 C 和核函数参数 γ 。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (14)$$

式中: $\gamma = \frac{1}{2\sigma^2}$ 表示核函数参数。SVR 真值标定模型的优

劣通过在测试集上计算预测值与目标值之间的均方误差判定,均方误差越趋近于0,模型的拟合精度越高。使用此模型则可以对每一目标的相对横纵向距离与速度进行模型训练拟合,拟合真值分别为 $f_{c,x}(\mathbf{x}_{(v,x,frame)})$ 、 $f_{c,y}(\mathbf{x}_{(v,y,frame)})$ 、 $f_{v,x}(\mathbf{x}_{(c,x,frame)})$ 、 $f_{v,y}(\mathbf{x}_{(c,y,frame)})$ 。该拟合结果即为面向毫米波雷达的卡尔曼滤波参数初始化方法中的真值系统。

2.2 基于均值处理的观测噪声协方差矩阵初始化

通过2.1节理论,将SVR拟合得到的结果作为毫米波雷达观测结果的真值系统,再利用均值处理针对卡尔曼滤波中的观测噪声协方差矩阵 $\mathbf{R}_k$ 进行初始化。

首先,计算目标的观测误差 μ 及观测误差样本方差 s^2 为:

$$\mu = y_{rad} - f(\mathbf{x}) \quad (15)$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (\mu_i - \bar{\mu})^2 \quad (16)$$

式中: y_{rad} 为毫米波雷达的观测值; $f(\mathbf{x})$ 为基于SVR拟合的近似真值,不同需求下分别表示 $f_{c,x}(\mathbf{x}_{(v,x,frame)})$ 、 $f_{c,y}(\mathbf{x}_{(v,y,frame)})$ 、 $f_{v,x}(\mathbf{x}_{(c,x,frame)})$ 、 $f_{v,y}(\mathbf{x}_{(c,y,frame)})$ 。结合车载毫米波雷达的采样信息,每个目标的 c, x, c, y, v, x, v, y 都有对应观测误差样本方差,即:

$$\begin{aligned} s_{c,x}^{2(n)} &= \frac{1}{n-1} \sum_{i=1}^n (\Delta_{c,x}^{(i)} - \bar{\Delta}_{c,x}) \\ s_{c,y}^{2(n)} &= \frac{1}{n-1} \sum_{i=1}^n (\Delta_{c,y}^{(i)} - \bar{\Delta}_{c,y}) \\ s_{v,x}^{2(n)} &= \frac{1}{n-1} \sum_{i=1}^n (\Delta_{v,x}^{(i)} - \bar{\Delta}_{v,x}) \\ s_{v,y}^{2(n)} &= \frac{1}{n-1} \sum_{i=1}^n (\Delta_{v,y}^{(i)} - \bar{\Delta}_{v,y}) \end{aligned} \quad (17)$$

假设每组测试样本数据包含 N 帧,则将多目标的同一物理量的观测误差样本方差求和取平均值,即为:

$$\begin{aligned}\bar{s}_{c,x}^2 &= \frac{1}{m} \left(\sum_{n=1}^N s_{c,x(o_1)}^{2(n)} + \sum_{n=1}^N s_{c,x(o_2)}^{2(n)} + \cdots + \sum_{n=1}^N s_{c,x(o_m)}^{2(n)} \right) \\ \bar{s}_{c,y}^2 &= \frac{1}{m} \left(\sum_{n=1}^N s_{c,y(o_1)}^{2(n)} + \sum_{n=1}^N s_{c,y(o_2)}^{2(n)} + \cdots + \sum_{n=1}^N s_{c,y(o_m)}^{2(n)} \right) \\ \bar{s}_{v,x}^2 &= \frac{1}{m} \left(\sum_{n=1}^N s_{v,x(o_1)}^{2(n)} + \sum_{n=1}^N s_{v,x(o_2)}^{2(n)} + \cdots + \sum_{n=1}^N s_{v,x(o_m)}^{2(n)} \right) \\ \bar{s}_{v,y}^2 &= \frac{1}{m} \left(\sum_{n=1}^N s_{v,y(o_1)}^{2(n)} + \sum_{n=1}^N s_{v,y(o_2)}^{2(n)} + \cdots + \sum_{n=1}^N s_{v,y(o_m)}^{2(n)} \right)\end{aligned}\quad (18)$$

式中: m 为检测目标的个数。进而,利用式(18)构建对角矩阵,则可近似为观测噪声协方差矩阵 $\mathbf{R}_k$:

$$\mathbf{R}_k = \begin{bmatrix} \bar{s}_{c,x}^2 & 0 & 0 & 0 \\ 0 & \bar{s}_{c,y}^2 & 0 & 0 \\ 0 & 0 & \bar{s}_{v,x}^2 & 0 \\ 0 & 0 & 0 & \bar{s}_{v,y}^2 \end{bmatrix} \quad (19)$$

最终,通过 SVR 估计,利用提出的均值处理方法可以得到观测噪声协方差矩阵的初始化方法。此外,由于过程噪声 $\mathbf{Q}_k$ 同样未知,且无法通过数据驱动的方式获得,本文假设过程噪声方差矩阵为 $\mathbf{Q}_k = \mathbf{R}_k$ 。

2.3 基于变分贝叶斯的目标状态估计参数在线更新

复杂交通流下,车辆在行驶过程中的状态将不断变化,观测噪声协方差矩阵 $\mathbf{R}_k$ 随行车状态的改变进行实时调整,可以有效提高目标状态估计精度。诸如最大似然法^[18]、Sage-Husa 自适应滤波^[30]、贝叶斯滤波^[31]等自适应算法可以有效实现该过程。然而,最大似然法在系统阶次较高时,积分项过于复杂,计算困难;Sage-Husa 自适应滤波在系统阶次较高时,极易滤波发散,而且自适应调整的 $\mathbf{R}_k$ 会失去正定性和半正定性,与式(19)相悖,不符合真实场景下的噪声方差;贝叶斯滤波由于在预测阶段,对目标状态与矩阵 $\mathbf{R}_k$ 的联合预测分布使用了查普曼-柯尔莫哥洛夫方程,使得积分不可解析,从而难以有效进行递归。因此,本文采用变分贝叶斯方法对矩阵 $\mathbf{R}_k$ 进行自适应调整,在有效克服上述问题的同时,实现目标状态的最优估计。

假设多目标的状态 $\mathbf{X}_k$ 和观测噪声协方差矩阵 $\mathbf{R}_k$ 相互独立,多目标的观测值为 $\mathbf{Y}_1, \dots, \mathbf{Y}_k$, 根据逆伽马分布为高斯分布方差的共轭先验分布,可以近似 $\mathbf{X}_k$ 和 $\mathbf{R}_k$ 的联合先验分布为:

$$\begin{aligned}p(\mathbf{X}_k, \mathbf{R}_k | \mathbf{Y}_{1:k-1}) &= p(\mathbf{X}_k | \mathbf{Y}_{1:k-1}) p(\mathbf{R}_k | \mathbf{Y}_{1:k-1}) = \\ N(\mathbf{X}_k | \mathbf{X}_{k|k-1}, \mathbf{P}_{k|k-1}) &\times \prod_{i=1}^d \text{Inv} - \\ \text{Gamma}(\delta_{k,i}^2 | \alpha_{k|k-1,i}, \beta_{k|k-1,i}) &\end{aligned}\quad (20)$$

由于多目标状态估计实际场景更为复杂,参数与参数之间并非相互独立,采取较为简单的参数概率分布

$\mathbf{Q}_X(\mathbf{X}_k), \mathbf{Q}_R(\mathbf{R}_k)$ 近似真实后验概率,即联合后验概率为:

$$p(\mathbf{X}_k, \mathbf{R}_k | \mathbf{Y}_{1:k}) \approx \mathbf{Q}_X(\mathbf{X}_k) \mathbf{Q}_R(\mathbf{R}_k) \quad (21)$$

通过 KL (Kullback-Leibler) 散度最小化和 ELOB (evidence lower of bound) 最大化进行变分近似,使得假设的参数概率分布逼近真实概率分布, $\mathbf{Q}_X(\mathbf{X}_k), \mathbf{Q}_R(\mathbf{R}_k)$ 为:

$$\begin{aligned}\mathbf{Q}_X(\mathbf{X}_k) &\propto \exp E_{\mathbf{Q}_R(\mathbf{R}_k)}([\ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1})]) = \\ \exp \left(\int \ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1}) \mathbf{Q}_R(\mathbf{R}_k) d\mathbf{R}_k \right) \\ \mathbf{Q}_R(\mathbf{R}_k) &\propto \exp(E_{\mathbf{Q}_X(\mathbf{X}_k)}[\ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1})]) = \\ \exp \left(\int \ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1}) \mathbf{Q}_X(\mathbf{X}_k) d\mathbf{X}_k \right)\end{aligned}\quad (22)$$

式中: $\mathbf{Q}_X(\mathbf{X}_k)$ 和 $\mathbf{Q}_R(\mathbf{R}_k)$ 分别服从 $N(\mathbf{X}_k | \mathbf{X}_k, \mathbf{P}_k)$ 和 $\prod_{i=1}^d \text{Inv_Gamma}(\delta_{k,i}^2 | \alpha_{k,i}, \beta_{k,i})$, 联合概率分布 $p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1})$ 可视作 3 个独立分布的乘积。根据高斯分布和逆伽马分布的概率密度函数,对式(22)的积分项计算和参数匹配,可得:

$$\begin{aligned}&\int \ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1}) \mathbf{Q}_R(\mathbf{R}_k) d\mathbf{R}_k = \\ & - \frac{1}{2} (\mathbf{Y}_k - \mathbf{H}_k \mathbf{X}_k) \langle \mathbf{R}_k^{-1} \rangle_R (\mathbf{Y}_k - \mathbf{H}_k \mathbf{X}_k) - \\ & \frac{1}{2} (\mathbf{X}_k - \mathbf{X}_{k|k-1})^T (\mathbf{P}_{k|k-1})^{-1} (\mathbf{X}_k - \mathbf{X}_{k|k-1}) + C_1 \\ & \int \ln p(\mathbf{X}_k, \mathbf{R}_k, \mathbf{Y}_k | \mathbf{Y}_{1:k-1}) \mathbf{Q}_X(\mathbf{X}_k) d\mathbf{X}_k = \\ & - \sum_{i=1}^d \left(\frac{3}{2} + \alpha_{k,i} \right) \ln(\delta_{k,i}^2) - \sum_{i=1}^d \frac{\beta_{k,i}}{\delta_{k,i}^2} - \\ & \frac{1}{2} \sum \frac{1}{\delta_{k,i}^2} \langle (\mathbf{Y}_k - \mathbf{H}_k \mathbf{X}_k)_i^2 \rangle_X + C_2\end{aligned}\quad (23)$$

设定启发式因子 $\rho, \rho \in (0, 1]$, 平稳观测噪声方差,使变分贝叶斯自适应卡尔曼滤波更稳定,变分贝叶斯自适应卡尔曼滤波的预测和修正构成如下。

1) 预测过程,多目标的先验状态估计和先验误差协方差和标准卡尔曼滤波一致,然后通过启动因子 ρ 和 $k-1$ 时刻的逆伽马参数 $\alpha_{k-1,i}$ 和 $\beta_{k-1,i}$ 预测 k 时刻的逆伽马分布参数 $\alpha_{k|k-1,i}$ 和 $\beta_{k|k-1,i}$ 。

$$\alpha_{k|k-1,i} = \rho_i \alpha_{k-1,i} \quad (24)$$

$$\beta_{k|k-1,i} = \rho_i \beta_{k-1,i}$$

式中: $i = 1, \dots, d$

2) 修正过程,对 k 时刻的逆伽马参数的预测值进行更新,从而更新矩阵 $\mathbf{R}_k$ 和卡尔曼增益 $\mathbf{K}_k$, 计算多目标的状态后验估计和后验误差协方差。

$$\alpha_{k,i} = \frac{1}{2} + \alpha_{k|k-1,i}$$

$$\beta_{k,i} = \beta_{k|k-1,i}$$

$$\mathbf{R}_k = \text{diag}\left(\frac{\beta_{k,1}}{\alpha_{k,1}}, \dots, \frac{\beta_{k,d}}{\alpha_{k,d}}\right)$$

$$\beta_{k,i} = \beta_{k-1,i} + \frac{1}{2}[(\mathbf{Y}_k - \mathbf{H}_k \mathbf{X}_k)_i^2 + (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T)_{ii}]$$
(25)

式中: $i = 1, \dots, d$

本文将 $\alpha_{k,i}$ 初始化为 $\left[\frac{1}{2\rho}, \frac{1}{2\rho}, \frac{1}{2\rho}, \frac{1}{2\rho}\right]$, $\beta_{k,i}$ 初始化为 $\left[\frac{s_{c,x}^2}{\rho}, \frac{s_{c,y}^2}{\rho}, \frac{s_{v,x}^2}{\rho}, \frac{s_{v,y}^2}{\rho}\right]$, 旨在均值初始化矩阵 $\mathbf{R}_k$ 。

3 算法实现

结合上述算法推导, 本文给出面向复杂交通流的基于卡尔曼滤波的多目标全生命周期状态估计策略, 其算法流程如图3所示。




图3 复杂交通流下基于卡尔曼滤波的多目标全生命周期状态估计流程图

Fig. 3 Flowchart of Kalman filter-based multi-object full lifecycle state estimation in complex traffic flow scenario

步骤1) 建立拟合真值 $f(\mathbf{x})$ 和激光雷达观测值 y 之间的映射关系, 以 $f(\mathbf{x})$ 为中心构建宽度为允许最大偏差 ε 两倍的间隔带, 将 $f(\mathbf{x})$ 的求解问题转化为目标优化。进一步, 结合式(10)~(13)求解 $f(\mathbf{x})$, 实现针对毫米波雷达的目标运动状态(包括横向距离 $c.x$, 纵向距离 $c.y$, 横向速度 $v.x$, 纵向速度 $v.y$)真值标定。

步骤2) 设置目标个数 m 及出现帧数 N , 计算目标运动状态观测误差 μ 及观测误差样本方差 s^2 。并结合目标个数及出现帧数求解观测误差样本方差的平均值 $\bar{s}^2$, 以此构建观测噪声协方差矩阵 $\mathbf{R}_k$ 。

步骤3) 设置噪声方差启动因子 ρ , $\rho \in (0, 1]$ 。

步骤4) 依据噪声方差启动因子 ρ 和观测误差样本方差的均值 $\bar{s}^2$, 分别初始化逆伽马分布的形状参数 α 和比例参数 β 。

步骤5) 通过 ρ 和 $k-1$ 时刻的逆伽马参数 $\alpha_{k-1,i}$ 和 $\beta_{k-1,i}$ 预测 k 时刻逆伽马分布参数 $\alpha_{k|k-1,i}$ 和 $\beta_{k|k-1,i}$, 多目标的先验状态估计及先验误差协方差与标准卡尔曼滤波一致。

步骤6) 对 k 时刻的逆伽马参数的预测值进行更新, 从而更新矩阵 $\mathbf{R}_k$ 和卡尔曼增益 $\mathbf{K}_k$, 计算输出多目标的状态后验估计和后验误差协方差。返回步骤5), 计算下一时刻的多目标的先验状态估计。

4 实验测试

将本文提出的算法在实车采集的数据上进行测试。实验数据来源于某车企试验车辆车载激光雷达和毫米波雷达同步采集的目标状态, 主要包含目标车辆前方多目标相对本车的纵向距离、横向距离、纵向速度、横向速度、以及目标ID等。目标数据采集频率为10 fps, 共计3 072帧, 其中前2 072帧进行模型训练, 后1 000帧进行模型测试。激光雷达实现的是多目标运动状态感知, 在不同时间区间内, 目标的数量及ID会发生变化, 即旧目标的消失及新目标的出现。因此, 本文将数据按照时间顺序分为20组样本(20个目标)进行处理, 每一组样本目标运动状态均持续50帧。其中2组样本(ID 31和ID 63)完全用于模型测试。此外, 实验数据均在实际交通场景中采集, 采集数据存在复杂行车环境中噪声干扰, 充分满足本文研究需求。

4.1 基于SVR的真值拟合测试

本文基于SVR算法分别对数据的 $c.x$ 、 $c.y$ 、 $v.x$ 、 $v.y$ 进行真值拟合, 并与基于匀加速运动模型得到的系统真值进行对比, 随机选取目标ID为10、26和完全未用于模型训练的目标ID 31、ID 63, 4组数据进行结果展示分析。匀加速运动模型得到的系统真值与SVR算法拟合的真值结果对比如表1所示。基于SVR算法的拟合真值与匀加速运动模型输出的真值对比结果, 以及激光雷达观测值分别与基于SVR拟合真值、匀加速模型输出真值的相对误差分别如图4、5所示。

分析可知, 匀加速运动模型真值相较于观测值误差较大, 4组目标仅有 $c.x$ 的匀加速运动模型真值与观测值较为接近; SVR拟合的真值整体上与观测值接近, 且观测值在拟合真值上下两侧波动。基于激光雷达采集的数据存在复杂行车环境中噪声干扰, 因此本文SVR拟合的真值相较于激光雷达观测值更平滑, 具有理论上的合理性。此外, 分析图5也可以直观看出相较于SVR拟合真值, 匀加速模型输出真值与激光雷达观测值之间的相对误差更大。

4.2 参数初始化测试

SVR拟合真值后, 计算观测误差和观测误差样本方差用于均值初始化观测噪声协方差矩阵 $\mathbf{R}_k^{mean}$ 。本文2.2




图4 目标ID10、26、31、63的状态观测值、匀加速运动模型真值、SVR拟合真值

Fig.4 Comparison of observation value, true value obtaining by CA, and true value obtaining by SVR for ID 10, 26, 31, 63




图5 目标ID10、26、31、63的状态观测值分别与CA、SVR拟合真值的相对误差

Fig.5 Relative error between observation value and true value respectively getting by CA and SVR for ID 10, 26, 31, 63

表 1 状态观测值与匀加速运动模型真值、SVR 拟合真值的相对误差均值

Table 1 Mean error between state observation value and true value respectively getting by CA and SVR %					
目标	方法	横向距离 $c. x$	纵向距离 $c. y$	横向速度 $v. x$	纵向速度 $v. y$
ID 10	匀加速模型	0. 413	23. 223	4. 325	56. 822
	SVR	0. 049	0. 390	0. 265	3. 189
ID26	匀加速模型	1. 238	3. 111	4. 934	126. 853
	SVR	0. 091	0. 257	0. 021	29. 776
ID31	匀加速模型	1. 985	9. 508	4. 997	266. 329
	SVR	0. 080	0. 029	0. 090	22. 427
ID63	匀加速模型	1. 979	0. 779	5. 677	325. 439
	SVR	0. 052	0. 011	0. 345	4. 182

节中提到过程噪声协方差矩阵 $\boldsymbol{Q}_k$ 也难以求解, 因此令 $\boldsymbol{Q}_k = \boldsymbol{R}_k$ 代入到卡尔曼滤波公式中, 进行“预测”和“修正”步骤迭代, 对样本数据进行多目标状态估计。为证明本文提出的参数初始化方法的有效性, 另外使用经验初始化 $\boldsymbol{R}_k$ 后的卡尔曼滤波对数据样本进行状态估计, 进行对比实验。由于观测值与 SVR 拟合的真值误差较小, 所以设置 3 种 $\boldsymbol{R}_k$ 矩阵进行测试, 如式 (26) 所示。

$$\begin{aligned} \boldsymbol{R}_k^{(exp1)} &= \begin{bmatrix} 0.5 & 0 & 0 & 0 \\ 0 & 0.5 & 0 & 0 \\ 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 0.5 \end{bmatrix} \\ \boldsymbol{R}_k^{(exp2)} &= \begin{bmatrix} 0.1 & 0 & 0 & 0 \\ 0 & 0.1 & 0 & 0 \\ 0 & 0 & 0.1 & 0 \\ 0 & 0 & 0 & 0.1 \end{bmatrix} \\ \boldsymbol{R}_k^{(exp3)} &= \begin{bmatrix} 0.05 & 0 & 0 & 0 \\ 0 & 0.05 & 0 & 0 \\ 0 & 0 & 0.05 & 0 \\ 0 & 0 & 0 & 0.05 \end{bmatrix} \end{aligned} \tag{26}$$

测试中, 实验对比的评估指标则使用均方误差 (mean-square error, MSE), MSE 可以反应估计值和被估计值的差异程度, 均方误差公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \tag{27}$$

式中: n 为样本数据个数; $\boldsymbol{Y}$ 为真实值; $\hat{\boldsymbol{Y}}$ 为估计值, MSE 越小, 估计效果越好。

测试中, 针对目标 ID 为 10、26、31、63 的 4 组数据进行测试分析, 通过数据驱动初始化 $\boldsymbol{R}_k^{mean}$ 和经验初始化 $\boldsymbol{R}_k^{(exp)}$ 后的卡尔曼滤波估计值与真值的均方误差如表 2 所示, 结果曲线如图 6~9 所示。其中 $nestCenter. x$ 、 $nestCenter. y$ 、 $velocity. x$ 、 $velocity. y$ 分别与 $c. x$ 、 $c. y$ 、 $v. x$ 、 $v. y$ 对应。

从表 2 以及图 6~9 可以看出, 采用本文提出的数据

驱动初始化观测噪声协方差矩阵后的卡尔曼滤波多目标状态状态估计要比经验初始化的效果好。此外, 基于经验初始化则需要多次调整才可以改善卡尔曼滤波的估计效果, 这样就需要进行不断调整参数, 不仅增加了工作量, 还严重依赖人为经验, 进一步验证了本文工作的有效性。

4.3 多目标全生命周期状态估计测试

多目标全生命周期状态的最优估计融合了基于数据驱动的观测噪声协方差矩阵 $\boldsymbol{R}_k$ 初始化和基于变分贝叶斯的目标状态估计参数在线更新。针对目标 ID 为 10、26、31、63 的 4 组数据进行验证分析。此外, 为从量化的角度验证基于卡尔曼滤波的多目标全生命周期状态估计方法的有效性, 本文分别对比依据经验初始化的观测噪声协方差矩阵 $\boldsymbol{R}_k^{(exp1)}$ 、 $\boldsymbol{R}_k^{(exp2)}$ 、 $\boldsymbol{R}_k^{(exp3)}$, 依据数据驱动初始化的观测噪声协方差矩阵 $\boldsymbol{R}_k^{mean}$, 以及融合了变分贝叶斯参数自适应多目标全生命周期状态估计方法的 20 组多目标状态估计的均方误差均值, 如表 3 所示。从表 3 可以看出, 相较于最好的经验初始化的观测噪声协方差矩阵 $\boldsymbol{R}_k^{(exp3)}$, 数据驱动初始化的观测噪声协方差矩阵 $\boldsymbol{R}_k^{mean}$ 的多目标状态估计的均方误差均值减小了 0.076, 多目标全生命周期状态估计方法减小了 0.088, 证明了本文提出方法的有效性。目标 ID10、26、31、63 的状态估计结果如图 10 所示。从图 10 可以看出, 全生命周期的多目标状态估计效果较为理想, 均方误差均值相较于仅采用数据驱动的 $\boldsymbol{R}_k$ 初始化要小, 状态估计精度和滤波收敛速度有所提升。

4.4 算法执行时间测试

为了验证本文方法的工程可用性, 采用个人电脑训练, 车载嵌入式系统推理的方式, 测试本文方法的执行时间。实验模型训练在配置为 3.7 GHz Intel Core i5-9600 处理器和 16 GB 2666 MHz DDR4 内存的个人电脑上进行。推理过程在如图 11 所示, 配置为 forlinux FETMX6Q-C ARM

表 2 数据驱动初始化 R_k^{mean} 和经验初始化 R_k^{exp} 后的卡尔曼滤波估计值与真值的均方误差

Table 2 MSE between estimated value and true value using different R_k in Kalman filter

目标	方法	横向距离 $c. x$	纵向距离 $c. y$	横向速度 $v. x$	纵向速度 $v. y$
ID10	数据驱动初始化 R_k^{mean}	0.170 644	0.097 997	0.005 642	0.002 227
	经验初始化 $R_k^{(exp1)}$	0.183 546	0.407 995	0.121 041	0.013 302
	经验初始化 $R_k^{(exp2)}$	0.175 722	0.135 692	0.039 717	0.015 014
	经验初始化 $R_k^{(exp3)}$	0.173 434	0.106 843	0.022 948	0.011 166
ID26	数据驱动初始化 R_k^{mean}	0.226 426	0.009 371	0.000 621	0.001 038
	经验初始化 $R_k^{(exp1)}$	0.192 203	0.112 758	0.053 843	0.017 213
	经验初始化 $R_k^{(exp2)}$	0.224 905	0.026 022	0.020 203	0.010 746
	经验初始化 $R_k^{(exp3)}$	0.232 968	0.015 095	0.012 579	0.007 185
ID31	R_k^{mean}	0.205 412	0.001 449	0.001 259	0.000 882
	经验初始化 $R_k^{(exp1)}$	0.205 763	0.025 882	0.157 672	0.026 889
	经验初始化 $R_k^{(exp2)}$	0.211 280	0.005 016	0.060 449	0.011 789
	经验初始化 $R_k^{(exp3)}$	0.211 900	0.002 609	0.037 612	0.007 120
ID63	数据驱动初始化 R_k^{mean}	0.221 884	0.000 559	0.001 142	0.000 529
	经验初始化 $R_k^{(exp1)}$	0.229 043	0.019 913	0.173 939	0.018 800
	经验初始化 $R_k^{(exp2)}$	0.230 084	0.003 457	0.065 786	0.008 752
	经验初始化 $R_k^{(exp3)}$	0.228 462	0.001 532	0.039 901	0.005 448






图 6 不同 R_k 初始化方式下 ID10 的状态估计对比

Fig. 6 State estimation results with different R_k initialization ways for ID 10

图7 不同 R_k 初始化方式下 ID26 的状态估计对比Fig. 7 State estimation results with different R_k initialization ways for ID 26图8 不同 R_k 初始化方式下 ID31 的状态估计对比Fig. 8 State estimation results with different R_k initialization ways for ID 31



图9 不同 R_k 初始化方式下 ID63 的状态估计对比Fig. 9 State estimation results with different R_k initialization ways for ID 63

图10 全生命周期的多目标的状态估计结果

Fig. 10 Multi-object full lifecycle state estimation results for ID 10, 26, 31, 63

表 3 不同参数初始化下 20 组多目标全生命周期状态估计均方误差均值

Table 3 Average of MSE for 20 sets of multi-object full lifecycle state estimation with different parameter initialization

评价指标	$R_k^{(exp1)}$	$R_k^{(exp2)}$	$R_k^{(exp3)}$	R_k^{mean}	全生命周期
MSE	0.664	0.292	0.241	0.165	0.153




图 11 多目标状态估计运行环境

Fig. 11 Experimental device for multi-object full lifecycle state estimation

核心板,1.0 GHz NXP 四核 iMX6Q 处理器和 1 GB 内存的车载 TBox 上进行。本文提出方法在参数初始化和状态估计两阶段的算法时间复杂度和执行时间如表 4 所示。

表 4 本文方法的时间复杂度及执行时间
Table 4 Time complexity and processing time of the proposed method

实验阶段	步骤	时间复杂度	执行时间/s
参数初始化	模型训练	$O(N^2)$	2.1
	模型推理	$O(N_w d)$	0.000 6
目标状态估计	预测步骤	$O(N^2)$	0.000 5
	更新步骤	$O(N^2)$	

在参数初始化阶段,主要涉及 SVR 模型的训练及推理。模型训练阶段,本文采用的基于高斯核函数的非线性 SVR 模型主要涉及样本之间的相似度计算,时间复杂度为 $O(N^2)$;在实际训练过程中,测试每个目标的每组样本训练时间约为 2.1 s。模型推理阶段,时间复杂度主要取决于支持向量的个数,因此推理阶段的时间复杂度为 $O(N_w d)$,其中 N_w 为支持向量的个数, d 为特征维度;在实际推理过程中,测试推理时间为 0.000 6 s。

目标状态估计阶段,主要考虑卡尔曼滤波的时间复杂度,分为预测和修正两个步骤。预测步骤的时间复杂度为 $O(N^2)$,其中 N 为状态向量的维度,主要涉及状态协方差矩阵的乘法,时间复杂度与状态向量维度的平方有关;修正步骤的时间复杂度为 $O(N^2)$,主要涉及卡尔曼增益的乘法,时间复杂度同样与状态向量维度的平方相关。此外,经过车载嵌入式系统 TBox 的实际测试,在

实际的状态迭代过程中,每次迭代的时间成本为 0.000 5 s,满足多目标状态估计的实时性要求。

5 结 论

在充分考虑复杂行车环境以及传感器观测误差的情况下,提出基于卡尔曼滤波的全生命周期多目标状态最优估计方法。在设计基于 SVR 目标运动状态真值标定基础之上,首次提出了以数据驱动的卡尔曼滤波中的观测噪声协方差矩阵初始化方法。同时,为保证卡尔曼滤波参数能够适应车辆行驶过程中状态的变化,采用变分贝叶斯对参数进行自适应调节,最终实现车辆行驶过程中感知目标的全生命周期状态估计。实验结果表明,本文方法能够有效减小目标状态估计的均方误差,实现了目标状态估计精度的提升。本文提出的多目标全生命周期状态估计为提升车辆感知精度提供了新思路,有利于提升智能驾驶的安全性。

参考文献

[1] CAO M X, SUN Z H, HAN G, et al. A target tracking system based on multi-camera information fusion [C]. 2022 China Automation Congress (CAC). IEEE, 2022: 4225-4229.

[2] 孙伟,刘经洲. 基于 Huber 鲁棒容积裂变粒子滤波的协同导航方法 [J]. 仪器仪表学报, 2022, 43 (2): 166-175.

SUN W, LIU J ZH. Cooperative navigation method based on the Huber robust cubature fission particle filter [J]. Chinese Journal of Scientific Instrument, 2022, 43 (2): 166-175.

[3] 江涛,钱富才,杨恒占,等. 具有双重不确定性系统的联合滤波算法 [J]. 自动化学报, 2016, 42 (4): 535-544.

JIANG T, QIAN F C, YANG H ZH, et al. A new combined filtering algorithm for systems with dual uncertainties [J]. Acta Automatica Sinica, 2016, 42 (4): 535-544.

[4] 余志鹏,熊剑,衷卫声,等. 基于秩卡尔曼滤波的室内行人航位推算算法 [J]. 仪器仪表学报, 2020, 41 (5): 214-220.

YU ZH P, XIONG J, ZHONG W SH, et al. Indoor pedestrian dead reckoning algorithm based on rank Kalman filter [J]. Chinese Journal of Scientific Instrument, 2020, 41 (5): 214-220.

[5] CHEN Y M, LI W, WANG Y Q. Online adaptive

- Kalman filter for target tracking with unknown noise statistics[J]. *IEEE Sensors Letters*, 2021, 5(3): 1-4.
- [6] 张一鸣, 周兵, 吴晓建, 等. 基于前车轨迹预测的高速智能车运动规划[J]. *汽车工程*, 2020, 42(5): 574-580.
- HANG Y M, ZHOU B, WU X J, et al. Motion planning of high speed intelligent vehicle based on front vehicle trajectory prediction[J]. *Automotive Engineering*, 2020, 42(5): 574-580.
- [7] LI Y F, BIAN C J, CHEN H Z. Object tracking in satellite videos: Correlation particle filter tracking method with motion estimation by Kalman filter [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.
- [8] LI X R, VESSELIN V P. A survey of maneuvering target tracking. Part I. Dynamic models [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1333-1364.
- [9] PETROVSKAYA A, THRUN S. Efficient techniques for dynamic vehicle detection[C]. 2008 Springer Tracts in Advanced Robotics, Springer, 2008: 340-356.
- [10] 侯德藻. 汽车纵向主动防撞系统的研究[D]. 北京: 清华大学, 2004.
- HOU D Z. Study on vehicle forward collision avoidance system[D]. Beijing: Tsinghua University, 2004.
- [11] SINGER R A. Estimating optimal tracking filter performance for manned maneuvering targets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1970, 6(4): 473-482.
- [12] BLOM H, BAR-SHALOM Y. The interacting multiple model algorithm for system switching Markovian switch coefficients [J]. *IEEE Transactions on Automatic Control*, 1988, 33(8): 780-783.
- [13] SAGA A P, HUSA G W. Adaptive filtering with unknown prior statistics[C] 10th Joint Automatic Control Conference. IEEE, 1969: 760-769.
- [14] 班朝, 任国营, 王斌锐, 等. 基于IMU的机器人姿态自适应EKF测量算法研究[J]. *仪器仪表学报*, 2020, 41(2): 184-194.
- BAN ZH, REN G Y, WANG B R, et al. Research on self-adaptive EKF algorithm for robot attitude measurement based IMU [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(2): 184-194.
- [15] 杨菊花, 李文元, 陈光武, 等. 引入滑模观测器的GPS/INS组合导航滤波方法[J]. *仪器仪表学报*, 2019, 40(9): 78-86.
- YANG J H, LI W Y, CHEN G W, et al. GPS/INS integrated navigation filter method based on sliding mode observer[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(9): 78-86.
- [16] 吕东辉, 王炯琦, 熊凯, 等. 适用处理非高斯观测噪声的强跟踪卡尔曼滤波器[J]. *控制理论与应用*, 2019, 36(12): 1997-2004.
- LYU D H, WANG J Q, XIONG K, et al. Strong tracking Kalman filter for non-Gaussian observation[J]. *Control Theory and Technology*, 2019, 36(12): 1997-2004.
- [17] XING J, JIANG T, LI Y, et al. q -Rényi kernel functioned Kalman filter for land vehicle navigation[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2022, 69(11): 4598-4602.
- [18] ZOU T, ZENG W, YANG W, et al. An adaptive robust cubature Kalman filter based on Sage-Husa estimator for improving ship heave measurement accuracy[J]. *IEEE Sensors Journal*, 2023 23(9): 10089-10099.
- [19] ZHANG X, FAN K, MA W, et al. A novel fractional Kalman filter algorithm with noisy input [J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2023, 20(3): 1239-1243.
- [20] ZHAO T, TONG W, MAO Y. Hybrid nonsingleton fuzzy strong tracking Kalman filtering for high precision photoelectric tracking system[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(3): 2395-2408.
- [21] YANG B, DU B, LI N, et al. Centered error entropy-based variational Bayesian adaptive and robust Kalman filter[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2022, 69(12): 5179-5183.
- [22] 高振海, 温文昊, 唐明弘, 等. 基于混合神经网络的汽车运动状态估计[J]. *汽车工程*, 2022, 44(10): 1527-1536.
- GAO ZH H, WEN W H, TANG M H. Estimation of vehicle motion state based on hybrid neural network[J]. *Automotive Engineering*, 2022, 44(10): 1527-1536.
- [23] TERRENCE L O, DALE BLAIR W, BENJAMIN J S, et al. Assessment of hierarchical multi-Sensor multi-target track fusion in the presence of large sensor biases[C]. 22nd International Conference on Information

- Fusion. IEEE, 2019: 1-7.
- [24] HUANG Y L, ZHU F S, JIA G L, et al. A slide window variational adaptive Kalman filter[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2020, 67(12): 3552-3556.
- [25] SIMO S, AAPPO N. Recursive noise adaptive Kalman filtering by variational Bayesian approximations [J]. IEEE Transactions on Automatic Control, 2009, 50(3): 596-600.
- [26] 吴军, 袁少博, 祝玉恒, 等. 采用自适应背景聚类的激光雷达与相机外参标定优化方法[J]. 仪器仪表学报, 2023, 44(2): 230-237.
- WU J, YUAN SH B, ZHU Y H, et al. Optimization method for external parameters calibration of lidar and camera using adaptive background clustering [J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 230-237.
- [27] SONG W J, LOU S X, ZHANG T, et al. Action-state joint learning-based vehicle taillight recognition in diverse actual traffic scenes[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18088-18099.
- [28] ZHANG T, FU M Y, SONG W J, et al. Trajectory planning based on spatio-temporal map with collision avoidance guaranteed by safety strip [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(2): 1030-1043.
- [29] XU F Y, XU F, XIE J C, et al. Action recognition framework in traffic scene for autonomous driving system[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 22301-22311.
- [30] 王君逸, 王志, 李华雄, 等. 基于自适应噪声的最大熵进化强化学习方法[J]. 自动化学报, 2023, 49(1): 54-66.
- WANG J Y, WANG ZH, LI H X, et al. Adaptive noise-based evolutionary reinforcement learning with maximum entropy[J]. Acta Automatica Sinica, 2023, 49(1): 54-66.

- [31] LI K, JOSE C P. Functional Bayesian filter[J]. IEEE Transactions on Signal Processing, 2022, 70: 57-71.

作者简介



E-mail: liumj@cqupt.edu.cn

Liu Mingjie received his M.Sc. degree from Chongqing University of Posts and Telecommunications in 2015, and Ph.D. degree from Inha University in 2019. He is currently an associate professor at Chongqing University of Posts and Telecommunications. His main research interests include environment perception & control for internet of vehicles, multi-information fusion, and machine learning.



Chen Junhu received his B.Sc. degree from Luoyang Institute of Science and Technology in 2021. He is currently a M.Sc. candidate at Chongqing University of Posts and Telecommunications. His main research interest is multi-information fusion.



Piao Changhao (Corresponding author) received his B.Sc. degree from Xi'an Jiaotong University in 2001, and Ph.D. degree from Inha University in 2006. He is currently a professor at Chongqing University of Posts and Telecommunications. His main research interests include autonomous driving and internet of vehicles.

刘明杰, 2015 年于重庆邮电大学获得硕士学位, 2019 年于韩国仁荷大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为智能网联汽车环境智能感知及控制、多源信息融合、机器学习。

陈俊虎, 2021 年于洛阳理工学院获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为多源信息融合。

朴昌浩 (通信作者), 2001 年于西安交通大学获得学士学位, 2006 年于韩国仁荷大学获得博士学位, 现为重庆邮电大学教授, 主要研究方向为自动驾驶、智能网联汽车。

E-mail: piaoch@cqupt.edu.cn