

DOI: 10.19650/j.cnki.cjsi.J2108296

卫星拒止环境下基于因子图的智能车可靠定位方法*

胡悦¹, 李旭¹, 徐启敏¹, 袁建华², 孔鑫¹

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 公安部交通管理科学研究所 无锡 214151)

摘要:针对如室内停车场、隧道等卫星拒止环境下智能车的准确可靠定位需求,提出了一种基于因子图的低成本融合定位方法。首先,构建基于因子图的UWB/INS动态融合定位框架;接着,充分利用UWB基站的静止特性,结合因子图输出的位置及位置置信区间计算智能车与基站之间的最大理论距离,并与UWB实测距离比较从而检测非视距信号;最后,制定自适应融合规则来指导不同情况下UWB/INS的融合,输出最终的定位结果,实现卫星拒止环境下智能车的可靠定位。实车试验表明,所提出的融合定位方法可达到0.622 m的精度,相较传统的最小二乘定位方法提升1倍以上,有效抑制了非视距误差的影响,具有成本低、可靠性高、环境适应力强等优点,克服了传统方法的不足。

关键词: 因子图;非视距误差;车辆定位;卫星拒止;置信区间

中图分类号: TH89 TN967.2 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Reliable positioning method of intelligent vehicles based on factor graph in GNSS-denied environment

Hu Yue¹, Li Xu¹, Xu Qimin¹, Yuan Jianhua², Kong Xin¹

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China;

2. Traffic Management Research Institute of the Ministry of Public Security, Wuxi 214151, China)

Abstract: Aiming at the demand for accurate and reliable positioning of intelligent vehicles in GNSS-denied environments such as indoor parking lots and tunnels, a low-cost fusion positioning method based on factor graph is proposed. Firstly, a UWB/INS dynamic fusion positioning framework based on factor graph is established; secondly, through making full use of the static characteristics of the UWB base stations, the maximum theoretical distances between the base stations and the intelligent vehicle are calculated via the position and position confidence interval inferred from the factor graph, and compared with the distance measured by UWB to detect the non-line-of-sight signals; lastly, an adaptive fusion rule is formulated to guide the fusion of UWB/INS under different conditions, the final positioning result is obtained, and the reliable positioning of intelligent vehicles in GNSS-denied environments is achieved. The real vehicle tests show that the proposed fusion positioning method can achieve the positioning accuracy of 0.622 m, which is more than one time improvement compared with that of the traditional least square method. The proposed method effectively suppresses the influence of non-line-of-sight errors, has the advantages of low cost, high reliability, strong environment adaptability, and overcomes the shortcomings of traditional methods.

Keywords: factor graph; error of non line of sight; vehicle positioning; GNSS-denied; confidence interval

0 引言

依托人工智能、传感器、信息融合等前沿技术的智能车相较传统车辆具有更加完善的安全、诱导等服务功能,

被认为是提高交通系统安全和效率的有效手段,近年来得到了充分快速的发展。准确可靠的全局位置信息是智能车实现其各项功能的必要前提,目前全球导航卫星系统(global navigation satellite system, GNSS)和惯性导航系统(inertial navigation system, INS)的融合估计已能够满足

收稿日期:2021-07-24 Received Date: 2021-07-24

* 基金项目:国家自然科学基金(61973079)项目资助

大多数场景下智能车的定位需求^[1]。然而,当智能车处于卫星拒止环境下,GNSS 信号难以到达导致其定位功能失效;INS 虽具有低成本和不受环境影响等优点,但需对陀螺仪和加速度计输出高频的角速度和加速度信号进行两次积分,容易带来随时间增长的累积误差,无法持续提供可靠的位置信息。此外,类似室内停车场、隧道等 GNSS 拒止场景,其静态特征同质化严重,且车辆流动较为频繁,动态要素易变,这都给智能车的准确可靠定位带来了挑战。现有卫星拒止环境下智能车的定位方法主要有:基于地磁^[2],基于超声^[3],基于视觉^[4]和基于激光雷达^[5]等。然而地磁信号定位极度依赖精准的环境先验地磁信息,不同场景适应性差;超声定位易受环境影响,且工作距离较短,精度较低;视觉定位运算量大,受光照影响严重,动态易变场景下易失效;激光雷达定位成本昂贵,运算量大,难以推广应用,且受同质化特征影响较为严重。

以蓝牙、超宽带 (ultra wide band, UWB) 等为代表的无线传感定位方法^[6-7],成本低,精度较高,通过利用无线信号测量基站和接收站之间的距离,并通过已知基站位置信息估计接收站位置。其中,UWB 时间分辨率高、穿透力强、功耗低、抗多径效果好、安全性强,其观测值可以用来抑制并修正 INS 引起的累积误差。因此,UWB/INS 的融合定位成为 GNSS 拒止环境下一种主流的智能车定位解决方案。例如,文献[8]中设计了一种基于自适应鲁棒卡尔曼滤波器的 GPS/UWB/INS 紧耦合集成定位系统,但只在室外的视距环境下进行测试;文献[9]利用 UWB/INS 融合数据对室内机器人进行定位,尽管融合结果在一定程度上提高了定位精度,但只是利用简单的阈值方法删除 UWB 中的异常测量值。

然而,UWB 测量过程中容易出现的非视距 (non-line-of-sight, NLOS) 现象是影响定位结果的重要因素。非视距指基站与接收站之间的传播路径受到动静态障碍物的遮挡影响,从而导致传播时间变长,测量距离相对实际距离变大。非视距效应会导致 UWB 观测信号质量变动频繁,影响定位精度。因此,高效的非视距检测判别及自适应融合方法是 UWB/INS 定位的关键。现有的非视距信号判别方法主要有:

1) 基于数学统计的方法^[10]。由于视距信号和非视距信号的方差、均值等统计信息不同,该方法在信号的统计信息变化超过一定阈值时认为存在非视距信号。然而,该方法依赖的统计信息等先验知识的阈值较难确定,且在纯非视距环境下无法使用,并有一定的滞后性;2) 基于环境的上下文感知方法^[11]。此类方法以射线追踪、3D 地图等为代表,但需事先获取精准的环境先验信息,且占用大量计算资源,实时性较差;3) 基于信号传播路径损耗模型或对信道冲激响应 (channel impulse response, CIR) 的方法^[12]。此类方法认为视距条件下的路径能量明显

大于非视距下的能量并依此来进行判定。然而该类方法的模型很难建立,不具有普遍性,不同环境的适应力较差;4) 基于学习的方法。以支持向量机 (support vector machine, SVM)^[13]为代表的机器学习、以长短期记忆网络 (long short-term memory, LSTM)^[14]为代表的深度学习等,在非视距判别上取得一定成果。然而该类方法需要大量数据进行预训练,实际落地应用存在困难,通用性不强。综上,现有方法主要存在两大问题:一方面,过于依赖统计量/环境等先验信息,当环境或工况变化时,方法的自适应能力差;另一方面,由于复杂的数学模型和大量计算资源的占用,方法实时性差。

此外,现有的数据融合方法多采用卡尔曼滤波 (Kalman filter) 及其变体^[15]。但这类方法依赖于事先建立的固有且准确的数学模型,当观测信号多变时自适应能力较弱。若接收到 UWB 的非视距信号,固有的滤波模型会带来严重的错误。因此,现有的 UWB/INS 融合定位方法仍较难解决 GNSS 拒止环境下 UWB 观测信号质量多变带来的定位不准的问题,难以保证智能车的定位需求。

针对上述不足,本文采用低成本的 UWB/INS 提供传感数据,构建基于因子图的动态融合框架,利用因子图的动态融合特性克服因环境造成的 UWB 观测信号质量易变的难题。除基站位置信息外无需任何先验知识,通过因子图输出的置信度与基站的位置判别 UWB 中的非视距信号;同时制定自适应融合规则,依托因子图的即插即用特性,根据 UWB 的实时观测质量来决定是否将其引入因子图,实现智能车在 GNSS 拒止环境下的准确可靠定位。本文的方法成本低,可靠性高,环境适应力强,可以满足智能车在 GNSS 拒止环境下的定位需求,克服了现有方法的不足。

1 方法概述

本文提出的定位方法如图 1 所示。




图 1 提出的定位方法

Fig. 1 The proposed positioning method

首先,通过 UWB 获取基站与接收站 (即智能车) 之间的距离,通过 INS 获取角速度和加速度,并构建基于因子图的 UWB/INS 动态融合框架;其次,利用融合 INS 数

据后因子图输出的位置及其置信度,配合已知基站位置计算接收站相对于每个基站的理论最大距离,再利用非视距误差总为正这一特性,与 UWB 实际测量值对比来判别非视距信号;最后,基于制定的自适应融合规则,依据 UWB 观测信号的实际情况,配合因子图的即插即用特性,对 UWB/INS 数据进行动态融合,输出最终的定位结果。

2 理论分析

2.1 因子图融合框架

因子图是一种二分图模型,包含变量节点和因子节点两种节点类型^[16]。因子图通过将智能车位置的最大后验估计问题转为最小二乘问题,可以得到优化后的结果:

$$\mathbf{X}^{MAP} = \arg \min_{\mathbf{X}} \sum_i \|e(\mathbf{X}_i, \mathbf{Z}_i)\|_{\Omega_i}^2 \quad (1)$$

式中: $\mathbf{X}_i$ 为估计矩阵; $\mathbf{Z}_i$ 代表观测矩阵,即模型中的约束信息; $e()$ 代表误差函数; Ω_i 是信息矩阵,用来确定优化问题中误差函数的权重。本文构建的因子图模型如图 2 所示。




图 2 基于因子图的多源信息融合框架

Fig. 2 Multi-source information fusion framework based on factor graph

图 2 中,空心大圆圈代表变量节点,实心小圆圈代表因子节点。本文提出的因子图定位模型中包含两种变量节点,一种是智能车状态变量节点 $\mathbf{X}_k$,主要包含 k 时刻智能车的位置信息;另一种是 INS 误差参数状态变量节点 $\mathbf{C}_k$,主要包含 k 时刻 INS 的常值漂移及随机游走。

本方法中的因子节点主要包括 INS 观测因子节点 f_{INS} 、INS 偏置因子节点 f_{bias} 、UWB 观测因子节点 f_{UWB} 和增量平滑因子节点 f_{IS} 。其中,INS 观测因子节点用于连接智能车状态变量节点和 INS 误差参数状态变量节点,其代价函数为:

$$f_{INS}(\mathbf{X}_{k+1}, \mathbf{X}_k, \mathbf{C}_k) = d(\hat{\mathbf{X}}_{k+1} - h(\mathbf{X}_k, \mathbf{C}_k, \mathbf{Z}_k^{INS})) \quad (2)$$

式中:下标代表具体时刻, $\mathbf{Z}_k^{INS}$ 表示 k 时刻 INS 的观测值,即陀螺仪和加速度计的输出, $\hat{\mathbf{X}}_{k+1}$ 是 $k+1$ 时刻的先验状态, $h()$ 为系统的状态转移函数; INS 偏置节点用于连接相邻时刻的 INS 误差参数状态变量节点,其代价函数为:

$$f_{bias}(\mathbf{C}_{k+1}, \mathbf{C}_k) = d(\mathbf{C}_{k+1} - g(\mathbf{C}_k)) \quad (3)$$

其中, $g()$ 为误差状态更新函数;此外,根据 UWB 观测值构建 UWB 观测因子节点,代价函数为:

$$f_{UWB}(\mathbf{X}_k) = d(\mathbf{Z}_k^{UWB} - h^{UWB}(\mathbf{X}_k)) \quad (4)$$

其中, $\mathbf{Z}_k^{UWB}$ 表示 k 时刻 UWB 的观测值,即 UWB 测量的基站与接收站之间的距离。本文中,直接通过 UWB 测量得到的距离以及 UWB 基站的位置信息对智能车位置进行解算,属于紧耦合的融合方法。 $h^{UWB}()$ 为其观测方程:

$$h^{UWB}(\mathbf{Z}_k^{UWB}, \mathbf{X}_k) = \sqrt{(x^i - x_k)^2 + (y^i - y_k)^2 + (z^i - z_k)^2} \quad (5)$$

式中: (x^i, y^i, z^i) 表示第 i 个基站位置坐标,在整个定位过程中数值均不发生变化, (x_k, y_k, z_k) 表示 k 时刻接收站的位置,即智能车的位置;最后,借鉴增量平滑和建图 (incremental smoothing and mapping, iSAM) 的思想^[17],构建增量平滑因子节点对不全是视距信号的区间进行增量优化,减小由于部分视距或完全非视距情况下 UWB 的观测值和 INS 递推带来的误差。该因子为二元因子,代价函数为:

$$f_{IS}(\mathbf{X}_p, \mathbf{X}_q) = d(\mathbf{Z}_k^{IS} - h^{IS}(\mathbf{X}_p, \mathbf{X}_q)) \quad (6)$$

不失一般性,结合图 2,假设 $\mathbf{X}_p$ 和 $\mathbf{X}_q$ 为相邻两个 UWB 信号均为视距情况的变量节点,且中间都是不全为视距情况的变量节点,此时利用增量平滑因子对两者形成的区间进行增量优化。其中, $\mathbf{Z}_k^{IS}$ 表示 k 时刻增量平滑因子节点的观测值, $h^{IS}()$ 为其观测方程。增量平滑因子节点的观测值通过以下方法确定:当全部是视距信号时,可以通过最小二乘的方法处理 UWB 测得的距离得到智能车位置,增量平滑因子节点的观测值即为通过最小二乘确定的两时刻位置之差。

2.2 非视距信号判别

非视距效应指 UWB 测量过程中,出现基站和接收机之间的传播路径受动静障碍物的遮挡,信号传播路径变长,从而导致测量距离大于实际距离的情况。若盲目将 UWB 的非视距信号引入因子图框架中进行融合,会给定位结果带来严重错误。因此,有效识别出 UWB 中的非视距信号尤为重要。

非视距效应最重要的特点就是其误差总为正。此外,定位过程中 UWB 基站的位置也保持不变。结合上述特点,本文依托因子图输出的位置及位置置信度来对非视距信号进行判定,具体方法如下:当因子图中接入 INS 观测因子节点后得到位置及其置信度,记 k 时刻通过 INS 得到的智能车位置为 $(x_k^{INS}, y_k^{INS}, z_k^{INS})$,由因子图输出的协方差矩阵解算其标准差为 $(\sigma_k^x, \sigma_k^y, \sigma_k^z)$,位置坐标服从多维高斯分布,概率密度函数为:

$$p(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^N \det \boldsymbol{\Sigma}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right] \quad (7)$$

式中: Σ 为协方差矩阵, μ 为均值向量, $\det$ 代表行列式, N 是变量维数, 上标 T 和 -1 分别代表转置和求逆。多维高斯分布在坐标轴上的投影为椭圆, 其球心由均值向量决定, 各个轴的长度及方向由协方差矩阵的特征值和特征向量决定。因位置的坐标数值均互不相关, 位置各数值的置信区间可计算为:

$$\begin{cases} x_k^- = x_k^{INS} - \sqrt{s} \sigma_k^x \\ x_k^+ = x_k^{INS} + \sqrt{s} \sigma_k^x \\ y_k^- = y_k^{INS} - \sqrt{s} \sigma_k^y \\ y_k^+ = y_k^{INS} + \sqrt{s} \sigma_k^y \\ z_k^- = z_k^{INS} - \sqrt{s} \sigma_k^z \\ z_k^+ = z_k^{INS} + \sqrt{s} \sigma_k^z \end{cases} \quad (8)$$

其中, s 可通过查询卡方分布表获得。则 k 时刻接收站对第 i 个基站的理论最大距离为:

$$\begin{aligned} \hat{\rho}_k^i &= \max(\sqrt{(\hat{x}_k - x^i)^2 + (\hat{y}_k - y^i)^2 + (\hat{z}_k - z^i)^2}), \\ \hat{x}_k &\in [x_k^-, x_k^+], \hat{y}_k \in [y_k^-, y_k^+], \hat{z}_k \in [z_k^-, z_k^+] \end{aligned} \quad (9)$$

其中, $\hat{x}_k, \hat{y}_k, \hat{z}_k$ 为 k 时刻智能车位置坐标的可能数值, 记 k 时刻测得的接收站与第 i 个 UWB 基站之间距离为 ρ_k^i , 该 UWB 测距误差为 σ_i^{UWB} , 若出现:

$$\rho_k^i > \hat{\rho}_k^i + 3\sigma_i^{UWB} \quad (10)$$

则认为该信号为非视距信号。

2.3 自适应融合规则

为解决 UWB 观测信号多变的影响, 利用因子图即插即用特性, 制定如下的自适应融合规则, 如图 3 所示。




图3 自适应融合规则

Fig. 3 Adaptive fusion rule

- 1) 所有的非视距信号均不接入因子图;
- 2) 当视距信号个数不少于3个时, 构建 UWB 观测因子节点并将视距信号接入因子图;
- 3) 当接收的信号均为视距信号且相邻时刻不全为视距信号时, 寻找上一时刻均为视距信号的时间点, 并对这两个时间点形成的区间进行增量优化。

3 试验验证与分析

为验证本文提出方法的有效性, 进行实车试验。由于试验条件的限制, 在室外开放空间中模拟 GNSS 拒止环境, 并在某些时间段主动的间断性遮挡 UWB 信号以模拟可能发生的非视距情况。本试验用到的传感器包括网络差分 GNSS, INS 和 UWB, 其中, 网络差分 GNSS 的数据不参与智能车的位置估计, 只做真值用来进行比对。UWB 基站共 4 个, 标号为 0~3。试验装置如图 4 所示。试验数据及结果均在东北天坐标系^[18]下。




图4 试验装置

Fig. 4 Experiment setup

试验全程共人为制造 5 次非视距区间, 具体情况如表 1 所示, 试验轨迹及大致非视距区间如图 5 所示。

表1 各区间非视距情况

Table 1 NLOS environment in various intervals

序号	运行工况	遮挡情况
1	短直线	间断性遮挡基站 0, 1
2	大转弯	间断性遮挡基站 0
3	直线+小转向	间断性遮挡基站 1, 2, 3
4	长直线	间断性遮挡基站 3
5	直线+小转向	间断性遮挡接收站 (等同遮挡所有基站)

为验证本文提出的非视距判别+基于因子图的 UWB/INS 紧耦合+区间优化 (NLOS-TFG-IS) 方法的有效性, 将本文方法与其他方法进行对比, 包括:

- 1) UWB 最小二乘解算定位 (LS);
- 2) 基于因子图的 UWB/INS 松耦合, 且不做非视距判别 (LFG);
- 3) 基于因子图的 UWB/INS 紧耦合, 且不做非视距判别 (TFG);
- 4) 非视距判别+基于因子图的 UWB/INS 紧耦合

(NLOS-TFG)。

其中,LS 和 LFG 是较为传统的定位方法,LS 只利用 UWB 进行定位,LFG 加入了 INS 的数据进行简单的松耦合,TFG 方法用来对比验证非视距判别和区间优化的有效性,NLOS-TFG 方法主要用来对比验证区间优化的有效性。




图 5 试验轨迹与非视距区间

Fig. 5 Experiment trajectory and NLOS intervals

为定量分析各方法,表 2 给出了各方法在不同非视距区间以及轨迹全程的均方根误差 (root mean square error, RMSE) 和最大误差 (maximum error, MAX)。

均方根误差计算公式为:

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (\mathbf{X}_i^{ref} - \mathbf{X}_i^{pred})^2} \quad (11)$$

最大误差公式为:

$$MAX = \max(|\mathbf{X}_i^{ref} - \mathbf{X}_i^{pred}|) (i = 1, 2, \dots, M) \quad (12)$$

其中, M 是位置估计的总数目, $\mathbf{X}_i^{pred}$ 为各类方法预测的位置数值, $\mathbf{X}_i^{ref}$ 为差分 GNSS 提供的真值。一般而言,定位方法的精度可以用均方根误差来表示^[18],其鲁棒性和稳定性则在一定程度上由最大误差反映。从表 2 可知,如果只用 UWB 来进行定位,当存在较为严重的非视距信号时(如区间 5,4 个 UWB 全部接收的非视距信号),其最大误差可达 7.94 m,全程的均方根误差可达 1.345 m,难以满足智能车的可靠定位需求。引入 INS 后,即便是最简单的融合方法,其各项误差指标也有所下降。本文提出的方法在几种方法里取得了最好的表现,最大误差降至最小二乘定位的 1/5 左右,均方根误差较最小二乘定位下降 1 倍以上。本文方法的最大误差为 1.804 m,较前述 4 种方法分别降低了 77.28%、73.95%、43.84%、15.50%,鲁棒性得到了大幅提升,均方根误差为 0.622 m,较前述 4 种方法分别降低了 53.75%、49.22%、35.28%、16.29%,精度得到了大幅提升。此外,NLOS-TFG 方法相较于 TFG 方法,全程均方根误差降低约 22.68%,表明本文的非视距判别起到一定效果,但注意到不同区间内的非视距判别对精度提升效果不同。如区间 2 和区间 4,由于只人为制造一个非视距信号,均方根误差只降低约 6.52% 和 2.35%。这是因为在本文提出的自适应融合规则中,对接收到 3 个以上的视距信号都采用紧耦合而不是递推的定位方法,而其他几个区间均有效降低了均方根误差;而本文的方法相较于 NLOS-TFG 方法,其全程均方根误差降低约 16.29%,表明增量平滑对误差抑制也有一定作用。

表 2 各方法定位误差统计结果

Table 2 Statistic result of positioning errors for various methods

m

区间	LS		LFG		TFG		NLOS-TFG		NLOS-TFG-IS	
	MAX	RMSE	MAX	RMSE	MAX	RMSE	MAX	RMSE	MAX	RMSE
1	1.542	1.007	1.409	0.994	0.634	0.891	0.633	0.589	0.619	0.579
2	4.016	2.241	3.254	2.057	0.773	0.598	0.621	0.559	0.338	0.167
3	1.077	0.846	0.988	0.803	0.806	0.704	0.765	0.610	0.389	0.243
4	1.011	0.423	0.781	0.301	0.774	0.298	0.727	0.291	0.799	0.286
5	7.940	3.202	6.926	2.948	3.212	1.072	2.135	0.842	1.804	0.717
全程	7.940	1.345	6.926	1.225	3.212	0.961	2.135	0.743	1.804	0.622

为更好展现不同方法的定位效果,本文选取 2、5 两个有代表性的非视距区间,给出各方法的轨迹。图 6 是区间 2 的轨迹图,图 7 是区间 5 的轨迹图。

区间 2 虽然只人为制造了一个非视距信号,但拐弯曲率较大,智能车运行工况较为复杂;区间 5 直接对接收站进行遮挡,相当于所有的信号都是非视距。这两种情况对 UWB/INS 可靠定位都有较大的挑战。从图 6 可以

看出,受非视距与运行工况影响,该区间内 LS 和 TFG 方法定位出现明显偏差,难以实现有效定位,本文方法和其他两种方法能够较好的解算智能车位置,但以本文方法效果最佳。该区间内,本文方法的最大误差为 0.338 m,相较于前面 4 种方法分别降低了 91.58%、89.61%、56.27%、45.57%,均方根误差为 0.167 m,较前述 4 种方法分别降低 92.55%、91.88%、72.07%、70.13%;从图 7




图6 非视距区间2定位结果

Fig. 6 Positioning result for NLOS interval 2




图7 区间5定位结果

Fig. 7 Positioning result for NLOS interval 5

可以看出,由于该区间内断断续续存在全部都是非视距信号的情况,因此几乎所有方法都出现了不同程度的定位偏差,但本文的方法依然取得了最好的定位效果。该区间内,本文方法的最大误差为 1.804 m,相较于前面 4 种方法分别降低了 77.28%、73.95%、43.84%、15.50%,均方根误差为 0.717 m,较前述 4 种方法分别降低 77.61%、75.68%、33.12%、14.85%。

此外,本文计算了上述方法在各个区间和全程的平均绝对误差(mean absolute error, MAE)及对应的误差标准偏差(standard deviation, STD)。

平均绝对误差计算公式为:

$$MAE = \frac{1}{M} \sum_{i=1}^M |X_i^{ref} - X_i^{pred}| \quad (13)$$

区间的误差标准偏差公式为:

$$STD = \sqrt{\frac{1}{M-1} \sum_{i=1}^M (X_i^{pred} - \bar{X}^{pred})^2} \quad (14)$$

总体的误差标准偏差公式为:

$$STD_{ALL} = \sqrt{\frac{1}{M} \sum_{i=1}^M (X_i^{pred} - \bar{X}^{pred})^2} \quad (15)$$

其中, $\bar{X}_i^{pred}$ 为预测值的平均值。各区间及总体计算结果如图 8 所示。其中,柱状图表示平均绝对误差,误差

棒表示误差平均标准偏差,每个区间及全程从左往右依次表示 LS、LFG、TFG、NLOS-TFG、NLOS-TFG-IS 方法。从图 8 中可以看出,本文的方法在不同区间及全程都取得了最小的平均绝对误差和标准偏差,表明了本文方法定位的有效性和稳定性。此外,各方法的全程标准偏差都比较大,是因为整个试验过程中 UWB 信号质量多变导致的。




图8 平均绝对误差与标准偏差

Fig. 8 Average absolute errors and standard deviations

综上,实车试验结果表明,本文提出的方法能够减小 UWB 的 NLOS 信号对定位带来的影响,保障智能车在 GNSS 拒止环境下的可靠定位,面对不同工况/非视距情况都有较强的适应力。相较于传统的 UWB 最小二乘定位方法,本文方法的全程最大误差、均方根误差等都降低了 1 倍以上;各非视距区间内的最大误差降低了 20% 以上,均方根误差降低了 30% 以上,可以实现准确可靠的定位。

4 结 论

针对 GNSS 拒止环境下智能车的准确可靠定位需求,本文提出了一种基于因子图的 UWB/INS 动态融合定位方法。首先构建基于因子图的 UWB/INS 动态融合框架;同时,根据非视距误差总为正且基站位置信息不变的特点,结合因子图输出的位置及位置置信度来判定 UWB 观测值中的非视距信号;最后,根据自适应融合规则对 UWB/INS 信号进行动态融合,克服质量多变的 UWB 观测信号易带来定位误差甚至错误的缺陷。实车试验证明,该方法成本低,对环境适应力强,鲁棒性好,相较传统的最小二乘定位精度提高 1 倍以上,有效抑制了非视距误差,克服了现有方法精度低、环境适应力弱、鲁棒性差等缺点。

参考文献

- [1] 沈凯, 刘庭欣, 左思琪, 等. 复杂城市环境下 GNSS/INS 组合导航可观测度分析及鲁棒滤波方法[J]. 仪

- 器仪表学报, 2020, 41(9): 254-263.
- SHEN K, LIU T X, ZUO S Q, et al. Observability analysis and robust fusion algorithms of GNSS/INS integrated navigation in complex urban environment[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 254-263.
- [2] 宋苗苗. 一种基于词袋法的地磁指纹室内定位方法[J]. 电子测量与仪器学报, 2019, 33(10): 195-200.
- SONG M M. Bag of words based approach for geomagnetic fingerprinting based indoor positioning[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(10): 195-200.
- [3] COMUNIELLO A, MOSCHITTA A, ANGELIS A D. Ultrasound TDoA positioning using the best linear unbiased estimator and efficient anchor placement[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(5): 2477-2486.
- [4] ZHENG Z, LI X, SUN Z, et al. A novel visual measurement framework for land vehicle positioning based on multi-module cascaded deep neural network[J]. IEEE Transactions on Industrial Informatics, 2021, 17(4): 2347-2356.
- [5] 吕攀, 辛越, 张恒, 等. 基于 MSCKF 的 IMU 与激光雷达紧耦合定位方法[J]. 仪器仪表学报, 2020, 41(8): 15-22.
- LYU P, XIN Y, ZHANG H, et al. Tightly coupled localization of IMU and lidar based on MSCKF[J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 15-22.
- [6] 孙宇嘉, 王晓鸣, 于纪言. 低信标节点密度传感器网络的启发式定位算法[J]. 仪器仪表学报, 2018, 39(1): 225-233.
- SUN Y J, WANG X M, YU J Y. Heuristic localization algorithm for low density of anchor nodes in wireless sensor networks[J]. Chinese Journal of Scientific Instrument, 2018, 39(1): 225-233.
- [7] SONG X, LI X, TANG W, et al. A fusion strategy for reliable vehicle positioning utilizing RFID and in-vehicle sensors[J]. Information Fusion, 2016, 31: 76-86.
- [8] WANG J, GAO Y, LI Z, et al. A tightly-coupled GPS/INS/UWB cooperative positioning sensors system supported by V2I communication[J]. Sensors, 2016, 16(7): 944-959.
- [9] FAN Q, SUN B, SUN Y, et al. Data fusion for indoor mobile robot positioning based on tightly coupled INS/UWB[J]. Journal of Navigation, 2017, 70(5): 1079-1097.
- [10] 李荣冰, 王念曾, 刘建业, 等. 面向相对导航的 UWB 测距误差估计与补偿方法[J]. 仪器仪表学报, 2019, 40(5): 31-38.
- LI R B, WANG N Z, LIU J Y, et al. UWB ranging error estimation and compensation method for relative navigation[J]. Chinese Journal of Scientific Instrument, 2019, 40(5): 31-38.
- [11] NG H F, ZHANG G, HSU L T. A computation effective range-based 3D mapping aided GNSS with NLOS correction method[J]. Journal of Navigation, 2020, 73(6): 1202-1222.
- [12] BARRAL V, ESCUDERO C J, JA G N, et al. NLOS identification and mitigation using low-cost UWB devices[J]. Sensors, 2019, 19(16): 3464-3478.
- [13] WYMEERSCH H. A machine learning approach to ranging error mitigation for UWB localization[J]. IEEE Transactions on Communications, 2012, 60(6): 1719-1728.
- [14] JIANG C, SHEN J, CHEN S, et al. UWB NLOS/LOS classification using deep learning method[J]. IEEE Communications Letters, 2020, 24(10): 2226-2230.
- [15] VARGAS A, MENEGAZ H, ISHIHARA J, et al. Unscented Kalman filters for estimating the position of an automotive electronic throttle valve[J]. IEEE Transactions on Vehicular Technology, 2016, 65(6): 4627-4632.
- [16] ZHANG H, ZHANG Z. AOA-based three-dimensional positioning and tracking using the factor graph technique[J]. Symmetry, 2020, 12(9): 1400-1415.
- [17] KAESSE M, JOHANSSON H, ROBERTS R, et al. iSAM2: Incremental smoothing and mapping using the Bayes tree[J]. Int J Robot Res, 2012, 31(2): 216-235.
- [18] LI X, CHEN W, CHAN C, et al. Multi-sensor fusion methodology for enhanced land vehicle positioning[J]. Information Fusion, 2019, 46: 51-62.

作者简介



胡悦,2015 年于合肥工业大学获得学士学位,2018 年于合肥工业大学获得硕士学位,现为东南大学博士研究生,主要研究方向为车辆多传感融合定位。

E-mail:hyhfut@163.com

Hu Yue received his B. Sc. degree in 2015 and M. Sc. degree in 2018 both from Hefei University of Technology. Now, he is a Ph. D. candidate in Southeast University. His main research interest includes vehicle multi-sensor fusion positioning.



李旭(通信作者),2006 年于东南大学获得博士学位,现为东南大学仪器科学与工程学院教授,主要研究方向为车辆导航定位、环境感知及自主控制。

E-mail:lixu.mail@163.com

Li Xu (Corresponding author) received his Ph. D. degree in 2006 from Southeast University. Now, he is a professor in School of Instrument Science and Engineering, Southeast University. His main research interest includes vehicle navigation and positioning, environment perception and autonomous control.



袁建华,1967 年毕业于重庆大学无线电系,现为公安部交通管理科学研究所研究员,主要研究方向为智能交通系统、自动驾驶汽车测试评价。

E-mail:yjh1308@163.com

Yuan Jianhua graduated from Radio Department, Chongqing University in 1967. Now, he is a research fellow in Traffic Management Research Institute, Ministry of Public Security. His main research interest includes intelligent transportation systems and automatic pilot vehicle testing and evaluation.