

DOI: 10.13382/j.jemi.B2407961

面向非视距环境的智能车多传感鲁棒融合定位*

胡悦¹ 范建华¹ 胡永扬¹ 魏祥麟¹ 李旭²

(1. 国防科技大学第六十三研究所 南京 210007; 2. 东南大学仪器科学与工程学院 南京 210096)

摘要:针对智能车无线定位易受非视距信号影响从而导致定位误差增大的问题,提出了一种基于非视距信号可靠判别的超宽带/惯性测量单元(UWB/IMU)鲁棒融合定位方法。首先,分别基于支持向量机(SVM)学习模型和多传感器一致性数学模型对非视距信号进行粗判别;接着,设计了基于D-S证据理论的非视距信号精判别模型,在决策级对上述模型的结果进行有效融合;最后,提出了一种基于因子图的多传感自适应融合定位方法,根据非视距判别结果动态调节融合模型,以实现非视距环境下的智能车鲁棒定位。实车试验结果表明,在非视距判别效果方面,相较于常规的SVM模型,所提方法非视距判别的精度、召回率和准确率分别提高了6.97%、5.37%和6.36%;在定位性能方面,与现有常规的最小二乘定位方法相比,所提出方法的均方根误差、最大误差和标准差分别减少了12.55%、63.40%以及13.23%,有效提升了非视距环境下智能车的定位精度和鲁棒性,克服了传统方法在非视距环境下定位精度低、可靠性差的缺陷。

关键词:智能车;融合定位;非视距判别;两级模型;因子图

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

Robust multi-sensor fusion positioning for intelligent vehicles in non-line-of-sight environments

Hu Yue¹ Fan Jianhua¹ Hu Yongyang¹ Wei Xianglin¹ Li Xu²

(1. The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China;

2. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: To address the problem that the increased positioning errors in wireless positioning for intelligent vehicles caused by non-line-of-sight (NLOS) signals, a robust UWB/IMU fusion positioning methodology based on reliable identification of NLOS signals is proposed. Firstly, the coarse NLOS identification is conducted based on a support vector machine (SVM) learning model and a multi-sensor consistency mathematical model respectively. Subsequently, the fine NLOS identification model based on D-S evidence theory is designed to effectively integrate the results of the aforementioned models at the decision level. Finally, a multi-sensor adaptive fusion positioning method based on factor graph is proposed to dynamically adjust the fusion model according to the results of NLOS identification, in order to achieve robust positioning for intelligent vehicles in NLOS environments. The results of real vehicle experiments indicate that, in terms of NLOS identification performance, compared with the conventional SVM model, the proposed method improves the precision, recall and accuracy by 6.97%, 5.37% and 6.36% respectively. In terms of positioning performance, compared with the existing conventional least squares positioning method, the proposed method reduces the root mean square error, the maximum error, and the standard deviation by 12.55%, 63.40%, and 13.23%, respectively, effectively improving the positioning accuracy and robustness of intelligent vehicles in NLOS environments, and overcoming the shortcomings of traditional methods in low positioning accuracy and poor reliability in NLOS environments.

Keywords: intelligent vehicles; fusion positioning; non-line-of-sight identification; two-stage model; factor graph

0 引言

作为传统车辆与电子信息、传感器、人工智能等前沿技术结合的新形态,智能车具备更为信息化智能化的功能及应用,在提升安全、提高效率、减少能耗等方面都有着广阔的应用前景^[1],已逐渐应用于智慧交通、无人探测、物流配送等领域,其中,精准可靠的位置信息是智能车实现其智能化功能及应用的前提与基础^[2]。以我国北斗卫星导航系统(Beidou navigation satellite system, BDS)为代表的全球导航卫星系统(global navigation satellite system, GNSS),结合惯性测量单元(inertial measurement unit, IMU)形成的卫星/惯导组合导航系统,已经可以在大多数场景为智能车提供可靠的位置信息^[3-4]。然而,卫星定位易因信号受到部分或完全遮挡而失效,而仅依赖 IMU 定位,也会由于其传感器特性与增量式定位方法,带来随时间增长的累积误差^[5]。因此,如何提升卫星失效环境下的智能车定位性能仍然亟待解决。

随着无线通信技术的发展,基于无线信号的无线定位技术也得到了进步与应用,尤其在卫星失效的情况下,无线信号可以作为卫星信号的一种有效补充为智能车提供位置信息,已有学者对此展开了相关研究^[6-8],且相较于视觉、激光雷达等其他卫星失效时的定位解决方案,无线定位成本更低、更易于部署,可实施性更强。其中,超宽带(ultra-wide band, UWB)具备测距精度高、成本低、抗干扰能力强等优点,已逐渐成为无线定位中使用的主流传感器^[9-10]。例如,文献[11]面向卫星失效环境,提出了一种两阶段三边测量方法对无人机进行定位,成功降低了卫星失效时的定位误差。文献[12]提出了一种 GNSS/IMU/UWB 紧耦合的多传感无缝定位方法,可以在卫星信号干扰和中断严重的区域实现位置估计的平稳过渡。

现有常用的无线定位方法主要包括到达时间(time of arrival, TOA)、到达时间差(time difference of arrival, TDOA)、到达角(angle of arrival, AOA)和信号强度(radio signal strength, RSS)^[13]等,其中 AOA 方法对硬件要求较高,价格昂贵,RSS 方法误差较大,因此更多使用的是 TOA 或 TDOA 方法,即通过测量信号传播时间进而测得发射站(Anchor)和接收站(Tag)之间的距离。因此,在进行无线定位的时候,发射站和接收站之间需要是视距的,如果在无线信号的传播路径上存在障碍物或遮挡等影响,形成了非视距(non-line-of-sight, NLOS)传播,就会造成传播时间变长,导致无线信号的测量值偏大,最终造成无线定位失准甚至失效。考虑到智能车的实际行驶环境,接收站与发射站之间不可避免的会出现非视距情况,因此,能够有效判别出非视距信号,是保障无线定位精度和鲁棒性的关键前提,有利于推动智能车无线定位在实

际中的进一步应用。许多学者从多个方面对无线信号非视距判别的问题进行了研究。1)基于无线信号的数学统计信息^[14],此类方法一般认为视距信号和非视距信号的均值、方差等数学统计特征是不一样的,因此通过对数学统计信息进行监控并确定相关阈值,来判别非视距信号。然而此类方法需要较为准确的先验信息,阈值也较难确定,且具有一定的滞后性。2)基于学习的方法^[15-17],此类方法主要利用机器学习或者深度学习方法构建分类模型,对无线信号的距离、强度、信道冲激响应等特征进行分析,从而输出视距或非视距的分类结果。然而此类方法需要大量的数据进行预先训练,可解释性弱,环境适应能力较差。

虽然现有的非视距判别方法取得了一定的成功,但依然存在以下的问题:1)输入信息单一,现有方法多以无线信号的特征(如距离、强度、信道冲激响应等)作为判别模型的输入,此类信号只能表征无线信号的变化情况,然而,某些情况下无线信号的突然变化并不一定是因为非视距造成的(例如智能车的速度突然增加导致无线信号的距离测量结果突然变大,此时属于正常的视距信号,但容易被判为非视距),从而导致误判;2)判别模型单一,现有方法多基于单一的数学或学习网络模型来判别,由于单个模型并不能适用于所有情况,因此总会出现误判或者漏判的情况。综上,非视距判别的能力仍需进一步提升。此外,在可靠判别非视距信号的基础上,如何针对信号的非视距情况动态调整融合定位模型,避免非视距误差对融合定位的影响,也是进一步提升定位性能的关键。

针对上述问题,面向非视距环境,提出了一种智能车 UWB/IMU 鲁棒融合定位方法。首先,提出了基于两阶段多模型融合的非视距信号判别方法,进而根据信号的非视距情况来对融合模型进行动态调整。本文所提的非视距信号判别方法,在输入端同时考虑了 UWB 信号和车载 IMU 信号,丰富了输入信息,同时,先分别基于学习模型和数学模型对非视距信号进行粗判别,再利用 D-S 证据理论对粗判别的结果进行决策级融合,从而实现非视距信号的精判别,进一步提升了非视距信号的判别性能。在此基础上,根据信号的非视距情况,动态调整了预先构建的 UWB/IMU 融合定位模型,避免将受到非视距误差污染的 UWB 信号引入到融合定位模型中,提升了非视距环境下 UWB/IMU 融合定位的精度与鲁棒性,克服了现有常规方法的不足。

1 方法

1.1 方法概述

所提的面向非视距环境的智能车 UWB/IMU 鲁棒融

合定位方法如图 1 所示。首先,采集 UWB 信号和 IMU 信号,接着,建立基于两阶段多模型融合的非视距信号判别方法,将 UWB 信号和 IMU 信号输入到模型,通过粗细两级模型来提升非视距信号判别的准确性;最后,构建基于因子图的动态融合模型,同时依据上述非视距信号判别的结果,调节融合策略以动态融合 UWB 和 IMU 信息,从而实现非视距环境下的智能车鲁棒融合定位。下文将对主要模块分别进行介绍。




图 1 智能车 UWB/IMU 鲁棒融合定位方法框架

Fig. 1 Framework of UWB/IMU robust fusion positioning methodology for intelligent vehicles

1.2 基于两阶段多模型融合的非视距信号判别方法

针对现有非视距信号判别方法由于在输入端和算法端的单一性导致判别能力有限的问题,构建了如图 2 所示的基于两阶段多模型融合的非视距信号判别方法。首先,模型的输入端既包含了表征无线端的 UWB 距离信息变化率 v_{uk} 、UWB 相邻时刻测量距离变化值 $\Delta\rho_k$ 等,还包含了表征车端的智能车速度 v_{ik} 、上一时刻到当前时刻的行驶距离 Δd_k 等,从而丰富了输入端的特征,能够更加全面地表征实际环境情况;同时,在算法端,分别设计了基于支持向量机(support vector machine, SVM)的学习模型和基于多传感一致性的数学模型,对信号的非视距情况进行粗判别,学习模型和数学模型分别输出各自的判别结果及属于非视距信号的概率 p_1 和 p_2 ;最后,采用 D-S 证据理论对上述粗判别的结果进行融合,从而输出最终的判别结果以及属于非视距信号的概率 p ,实现对非视距信号的精判别。




图 2 基于两阶段多模型融合的非视距信号判别方法

Fig. 2 NLOS signal identification methodology based on two-stage multi-model fusion

1) 基于 SVM 的非视距粗判别学习模型

SVM 是一种经典的机器学习方法,通过将输入数据

映射到更高维的空间中,并寻找合适的超平面来对数据实施分类或回归任务^[18]。文献[16-17]尝试采用 SVM 来判别非视距信号,并取得了不错的效果。虽然采用了距离、强度等无线信号的均值、方差等多个特征,但其数据来源仍是只有无线端,因此较难全面表征实际的环境。对此,所构建的 SVM 非视距粗判别模型,在输入端进一步引入了车端的 IMU 数据,以更全面地表征实际的情况。具体而言,构建的 SVM 模型的输入包括当前 k 时刻 UWB 测距信息的变化率 v_{uk} 和通过 IMU 获得的智能车速度 v_{ik} ,记为 (v_{uk}, v_{ik}) 。通过 IMU 获取车辆速度属于通用方法,此处不再介绍,而 UWB 测距信息的变化率 v_{uk} 通过式(1)进行计算。

$$v_{uk} = \frac{\rho_k - \rho_{k-1}}{\Delta t} \quad (1)$$

式中: ρ_k 和 ρ_{k-1} 分别代表相邻的 k 时刻和 $k-1$ 时刻 UWB 的距离测量数值; Δt 表示上述两个相邻时刻的时间间隔。确定输入后,需进一步设置 SVM 模型的核函数。核函数用来将数据映射到高维空间,是影响 SVM 模型性能的一个重要因素。目前,常用的核函数包括线性核函数、多项式核函数、Sigmoid 核函数以及径向基函数等。考虑到所构建的 SVM 模型特征输入不多,训练样本数量可观,因此选择参数少、非线性处理能力强、泛化性好的径向基函数作为核函数,其公式为:

$$K_{RBF}(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (2)$$

式中: x 和 x' 分别代表不同的数据点; γ 是超参数, $\|x-x'\|$ 表示两个数据点之间的欧氏距离。采用交叉验证的方法进行优化,经过训练后的模型将输出对信号的视距和非视距情况的判别结果,并同时输出其属于非视距信号的概率 p_1 。

2) 基于多传感一致性的非视距粗判别数学模型

现有判别方法在算法端多只采用单一的模型,因此其判别性能有限。对此,除了上述的 SVM 学习模型以外,还构建了基于多传感一致性的非视距粗判别数学模型。UWB 当前 k 时刻的距离测量值 ρ_k 、上一时刻的距离测量值 ρ_{k-1} 以及智能车从上一时刻到当前 k 时刻的行驶距离 Δd_k ,在数学模型上可以构成三角形的 3 条边,如图 3 所示。因此,根据三角形三边关系有:

$$|\rho_k - \rho_{k-1}| < \Delta d_k \quad (3)$$

由于不知道 ρ_k 和 ρ_{k-1} 之间的具体关系,因此在式(3)中加入了绝对值。不难发现,两者的差值实际上就是 UWB 相邻时刻测量距离结果的变化值,定义该数值为 $\Delta\rho_k$ 。此外, Δd_k 是通过 IMU 数据推算出来的,在此之前将通过基本的小波变换对 IMU 数据进行降噪处理,且由于时间间隔非常短,因此可以认为其精度有较高保证。而 UWB 的测量结果中必定会存在 UWB 传感器的测量误差 σ^{UWB} ,此处对其进行考虑。假设上一时刻是视距环

境,则距离测量值 ρ_{k-1} 只包含测量误差 σ^{UWB} ,而不包括非视距误差。如果当前时刻是视距信号,则距离测量值 ρ_k 中也只包含测量误差 σ^{UWB} ,所以有:

$$|\Delta\rho_k| - \Delta d_k < 0 \tag{4}$$

而如果当前时刻是非视距环境,则距离测量值 ρ_k 中除了测量误差 σ^{UWB} 之外,还包括非视距误差,且非视距误差必然为正,因此 ρ_k 的数值必然偏大,所以 $|\Delta\rho_k|$ 的数值也必然偏大。因此,如果出现了:

$$|\Delta\rho_k| - \Delta d_k > \sigma^{UWB} \tag{5}$$

则认为当前信号是非视距信号,同时,根据式(6)确立其属于非视距信号的概率 p_2 。

$$p_2 = \begin{cases} 0.35, & |\Delta\rho_k| - \Delta d_k \leq \sigma^{UWB} \\ 0.55, & |\Delta\rho_k| - \Delta d_k > \sigma^{UWB} \\ 0.7, & |\Delta\rho_k| - \Delta d_k > 2\sigma^{UWB} \\ 0.9, & |\Delta\rho_k| - \Delta d_k > 3\sigma^{UWB} \end{cases} \tag{6}$$

式(6)中的概率数值主要是通过工程经验预先设置,并通过试验结果进行微调。至此,通过基于多传感一致性的非视距粗判别数学模型得到信号的非视距情况及其属于非视距信号的概率 p_2 。




图 3 多传感一致性数学模型示意图

Fig. 3 Diagram of multi-sensor consistency mathematical model

3) 基于 D-S 证据理论的非视距精判别融合模型

最后,引入了 D-S 证据理论来对上述两个模型的粗判别结果进行融合。D-S 证据理论是一种数据融合方法,在处理不确定性或者模糊性信息方面具有一定优势^[19]。记非视距信号为 N ,视距信号为 L , M_1 为基于 SVM 模型得到的概率分配函数,同时有 $M_1(N) = p_1$, $M_1(L) = q_1$, M_2 为通过多传感一致性模型得到的概率分配函数,同时有 $M_2(N) = p_2$, $M_2(L) = q_2$, M 为 M_1 和 M_2 的正交和,计算归一化常数 K 为:

$$K = \sum_{x_1 \cap x_2 \neq \emptyset} M_1(x_1)M_2(x_2) = p_1p_2 + q_1q_2 \tag{7}$$

进而计算属于非视距信号的最优概率 R :

$$R = M(N) = \frac{1}{K} \sum_{x_1 \cap x_2 = N} M_1(x_1)M_2(x_2) = \frac{p_1p_2}{p_1p_2 + q_1q_2} \tag{8}$$

根据 D-S 证据理论预测的概率 R 来对当前信号的非视距情况进行判定,将通过工程经验与实际调试优化来

确定 R 的数值,当最优概率 R 超过 0.8 时,则判定该信号属于非视距信号。

1.3 基于因子图的动态融合定位模型

考虑到实际环境中 UWB 信号的视距/非视距情况是来回切换的,因此融合定位模型需要具备根据信号情况动态调整的能力。因子图是一种图优化方法^[20],包括变量节点和因子节点两种类型,其中变量节点表示待估计数值,因子节点表示观测数值,用边表示不同节点之间的关系。因子图具备“即插即用”的特性,即因子节点可以根据实际情况动态接入或脱出,符合非视距环境下的动态定位需求,因此基于因子图来构建融合定位模型,其结构如图 4 所示。




图 4 基于因子图的 UWB/IMU 鲁棒融合定位模型

Fig. 4 Robust UWB/IMU fusion positioning model based on factor graph

图 4 中,空心大圆圈代表智能车状态变量节点,包含了智能车的位置等变量,实心菱形代表 IMU 观测因子节点 f_{IMU} ,其代价函数为:

$$f_{IMU}(X_{k-1}, X_k) = d(Z_k^{IMU} - h^{IMU}(X_k)) \tag{9}$$

式中: Z_k^{IMU} 代表 k 时刻 IMU 传感器提供的观测信息; $h^{IMU}()$ 为其观测方程。实心小圆形代表 UWB 基站提供的距离观测数值,利用距离观测数值可以计算得到图中由实心正方形表示的 UWB 观测因子节点 f_{UWB} ,其代价函数为:

$$f_{UWB}(X_k) = d(Z_k^{UWB} - h^{UWB}(X_k)) \tag{10}$$

式中: Z_k^{UWB} 代表 k 时刻 UWB 提供的智能车位置等观测信息; $h^{UWB}()$ 为其观测方程。图 4 中部分的 UWB 观测因子节点与智能车状态变量节点之间的边是用虚线表示的,这是基于非视距判别结果来决定的,虚线表示此时不将该 UWB 观测因子节点与智能车状态变量节点连接。此外,实心小三角形表示先验节点,即先验信息。

针对实际定位过程中 UWB 信号的非视距情况,做出如下的动态融合策略:如果当前信号均判别为视距信号,则将 UWB 观测因子节点接入融合定位模型;如果非视距信号的数量少于 UWB 信号总数的一半,且通过 D-S 证据理论得到的非视距信号的最优概率 R 高于 0.7,此时可以认为信号的非视距程度较低,对融合定位结果的影响不会太大,因此也将 UWB 观测因子节点接入融合定位模型;其他情况下,均不将 UWB 观测因子节点接入融合定位模型,以避免引入较大的非视距误差。

2 实车试验与结果分析

2.1 试验装置及场景

为了验证所提方法的有效性,在实际环境中进行了实车试验。首先组建了试验装置,如图5所示。试验装置主要包括智能车和路侧的UWB基站,其中,智能车配备了UWB接收器、差分GNSS接收器、MEMS-IMU以及车载计算单元。UWB接收器用于接收路端UWB基站的测距信号,MEMS-IMU可以提供智能车的角速度和加速度信息,而差分GNSS则用于提供智能车位置信息的真值,从而可以对所提方法进行定量评估,且不参与所提方法的解算过程。车载计算单元的CPU为i5-7300HQ,内存为16G,软件平台基于Ubuntu16的ROS系统。此外,在实车试验中,将IMU的采集频率设置为100 Hz,UWB的采集频率设置为50 Hz,各传感器数据将通过ROS时间戳进行对齐。各个传感器与实车试验内容相关的具体参数如表1所示。




图5 试验装置

Fig.5 Experimental setups

表1 实车试验中传感器参数

Table 1 Sensor parameters in real vehicle experiment

传感器	技术指标	参数
UWB	测距精度	10 cm(典型值)
	最大通信距离	500 m
	采集频率	200 Hz(最大值)
	陀螺仪量程	±150°/s
MEMS-IMU	陀螺仪零偏重复性	0.5°/s
	角度随机游走	0.1°/√h
	加速度计量程	±5 g
	加速度计零偏重复性	15 mg
差分GNSS	位置精度	2 cm

共进行了两次实车试验。第1次实车试验是为了验证提出的基于两阶段多模型融合的非视距信号判别方法的有效性,主要是在实际的视距环境下采集了UWB信号和IMU信号,来构建非视距识别的训练集和测试集。对

于采集得到的视距情况下的UWB数据,按照文献[8]中的统计结果,选取其中1/2的UWB数据加入均值在1~2m的随机噪声,并将其标签设置为非视距,对于未加入噪声的UWB数据,将其标签设置为视距。第1次实车试验中共设置了4个UWB基站,每个基站采集了9001个UWB数据点,一共包含了36004个UWB数据点,大致按7:3的比例划分为训练集和测试集,且保证训练集和测试集中非视距和视距信号的比例相同。同时,为了验证所提出的融合定位方法的整体性能,在实际的非视距环境中进行了第2次实车试验。试验场景在室外停车场,同样设置了4个UWB基站,调整基站的高度使其略低于车辆(图5),以形成非视距传播,试验环境开阔,因此可以利用差分GNSS提供位置真值。

2.2 结果分析

1) 非视距信号判别结果与分析

首先,对非视距信号判别方法的结果进行了分析。进行验证的方法包括只采用UWB距离变化速率作输入特征的SVM模型(SVM1),所提出的采用UWB距离变化速率和IMU速度一同作为输入特征的SVM模型(SVM2),所提出的基于多传感一致性的数学模型(MC)以及所提出的基于两阶段多模型融合的非视距信号判别方法,通过精度(precision)、召回率(recall)和准确率(accuracy)3个指标来进行评价,计算方法如式(11)~(13)所示。

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

式中:TP表示实际为非视距且判别成功的信号,FP表示实际为视距但判别错误的信号,FN表示实际为非视距但判别错误的信号,TN表示实际为视距且判别成功的信号。不同方法的非视距判别结果如表2所示,加粗数字代表最优结果。

表2 不同方法非视距判别结果

Table 2 Results of different NLOS identification methods (%)

方法	Precision	Recall	Accuracy
SVM1	82.88	84.74	83.61
SVM2	86.27	88.89	87.37
MC	85.19	88.56	86.58
本文	88.66	89.29	88.93

由表2可以看出,所提方法的精度、召回率和准确率均优于其他方法。需要说明的是,虽然MC方法不需要

预训练,但为了公平比较,其结果也是在预测集上给出的。首先,可以看到 SVM2 方法的精度、召回率和准确率等均优于 SVM1 方法,这表明,在同一模型的输入端引入多个来源的传感信息特征,有助于提高同一模型的判别效果;同时,所提方法在精度、召回率和准确率等指标上均优于 SVM2 方法和 MC 方法,这是因为通过单个模型来预测会存在一定的局限性。例如,SVM 方法的性能取决于训练数据的大小、核函数的选取等方面,而 MC 方法虽然不需要依赖训练数据等因素,但其假设了前一时刻是视距或者后一时刻的非视距程度更大,因此在相邻时刻的非视距程度比较接近的时候容易产生错误判别,而所提方法通过对多模型结果进行决策级融合,有效避免了单个判别模型的局限性,从而进一步提高了非视距判别的性能。同时,如何在不影响实时性的前提下,采用更多的输入特征,并构建更精准的模型是进一步提升非视距信号判别性能的方法。

2) 融合定位结果与分析

接着,对融合定位的结果进行分析。进行验证的方法包括只使用 IMU 信息进行定位(IMU),传统的基于 UWB 测距信号的最小二乘定位方法,但不进行 UWB 信号的非视距判别(LS-UWB),不进行 UWB 信号的非视距判别,并基于因子图模型融合 UWB/IMU 的定位方法(FG-UWB/IMU)以及所提出的基于非视距判别结果的 UWB/IMU 动态融合定位方法,采用均方根误差(RMSE)、最大误差(MAX)和标准差(STD)等指标来对各个方法的定位结果进行评价,计算方法如式(14)~(16)。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{X}_i - X_i)^2} \quad (14)$$

$$MAX = \max(|\hat{X}_i - X_i|) \quad (i = 1, 2, \dots, N) \quad (15)$$

$$STD = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{X}_i - \bar{X})^2} \quad (16)$$

式中: N 表示实车试验中估计序列的总数, X 代表通过差分 GNSS 获取的位置真值, \hat{X} 表示各个定位方法的估计值, \bar{X} 表示估计值的平均值,同时最大误差按照绝对值来计算。实车试验的结果如表 3 所示,加粗数字代表最优结果。

对表 3 进行分析,首先,根据 IMU 定位方法的结果可以看到,如果仅依靠 IMU 定位,会受到累积误差的影响,定位精度有限,难以支撑智能车的后续应用,其定位方法结果的均方根误差、最大误差和标准差分别为 6.941、17.147 和 4.979 m,在各个定位方法中表现均为最差;其次,根据 LS-UWB 定位方法的结果可知,如果不进行非视距判别,在非视距环境下极容易引入非视距误差,从而导致无线定位的结果失准,其均方根误差、最大

误差和标准差分别为 1.028、5.118 和 1.005 m,鲁棒性差;同时,从 FG-UWB/IMU 定位方法的结果可以看出,虽然将 UWB 和 IMU 两个传感器进行了融合,但由于非视距误差依然存在,因此定位效果依然欠佳,不过相较于 LS-UWB 定位方法,其均方根误差、最大误差和标准差分别降低了 4.28%、32.59% 以及 4.58%,这是由于 IMU 信号的引入在一定程度上抑制了非视距误差的影响,这在最大误差指标上表现的最为明显;最后,所提出的定位方法取得了最好的结果,均方根误差、最大误差和标准差分别为 0.899、1.873 和 0.872 m,这是因为在定位过程中对非视距信号进行了可靠判别,并根据非视距信号的情况对融合定位模型进行了动态调整,相较于常规的 LS-UWB 定位方法,所提方法的均方根误差、最大误差和标准差分别降低了 12.55%、63.40% 以及 13.23%,相较于 FG-UWB/IMU 定位方法,均方根误差、最大误差和标准差分别降低了 8.64%、45.71% 以及 9.07%,表明了提出的非视距信号识别和动态融合策略的有效性,由于减少了非视距误差的引入,因此所提方法的最大误差指标下降的尤为明显,显著提高了非视距环境下智能车定位的鲁棒性。

表 3 实车试验中不同方法定位误差

Table 3 Positioning errors of different methods in real vehicle experiment (m)

方法	RMSE	MAX	STD
IMU	6.941	17.147	4.979
LS-UWB	1.028	5.118	1.005
FG-UWB/IMU	0.984	3.450	0.959
本文	0.899	1.873	0.872

同时,对不同定位方法的东向定位误差和北向定位误差的误差分布情况进行了讨论。首先,为了定性化展示,图 6 和 7 所示分别是不同定位方法得到的东向定位误差和北向定位误差的累积分布函数,为了更加直观,此处对各定位误差取绝对值,其中,虚线代表 IMU 方法,虚点线代表 LS-UWB 方法,点划线代表 FG-UWB/IMU 方法,实线代表提出的方法。由图 6 和 7 可以看出,北向位置误差整体大于东向位置误差,这是因为实车试验北向位移远大于东向位移造成的。需要注意的是,在东向位置误差方面,LS-UWB 定位方法的误差分布虽然比 IMU 定位方法的集中,但是其误差分布范围甚至大于 IMU 定位方法,这是由于非视距信号导致的,因此可以看出非视距误差对定位造成的影响,有时候甚至会超过 IMU 的累积误差。同时,可以看到,所提出的方法与其他定位方法相比,误差分布在更小的范围之内,且更加集中,具有最佳的误差分布。

其次,为了量化描述各个方法定位误差的分布情




图6 不同方法的东向定位误差累积分布函数

Fig. 6 Empirical cumulative distribution function of positioning errors in east of different methods

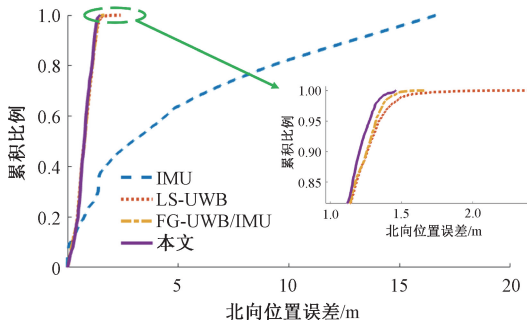


图7 不同方法的北向定位误差累积分布函数

Fig. 7 Empirical cumulative distribution function of positioning errors in north of different methods

况,表4为不同定位方法得到的东向定位误差和北向定位误差,在50%、70%和90%处对应的误差分布范围数值,加粗数字代表最优结果。由表4可知,在东向位置误差方面,所提出的方法有50%的误差小于0.222 m,70%的误差小于0.385 m,90%的误差小于0.589 m,在北向位置误差方面,所提方法有50%的误差小于0.754 m,70%的误差小于0.955 m,90%的误差小于1.205 m,均为各个方法中最小的,这也表明所提方法的误差分布优于其他的方法。

表4 实车试验中不同方法定位误差分布情况

Table 4 Distribution of positioning errors of different methods in real vehicle experiment (m)

方法	50%误差范围		70%误差范围		90%误差范围	
	东向	北向	东向	北向	东向	北向
IMU	0.913	2.941	0.913	6.416	3.157	12.857
LS-UWB	0.274	0.755	0.469	0.991	0.823	1.261
FG-UWB/IMU	0.261	0.767	0.449	0.978	0.759	1.255
本文	0.222	0.754	0.385	0.955	0.589	1.205

此外,分别展示了各个方法结果的东向定位误差和北向定位误差的误差曲线,如图8和9所示,其中,虚线

代表IMU方法,虚点线代表LS-UWB方法,点划线代表FG-UWB/IMU方法,实线代表提出的方法。首先,可以看到由于受随时间增长的累积误差的影响,IMU定位方法的定位误差最大;其次,因为引入了UWB无线信号,LS-UWB定位方法和FG-UWB/IMU定位方法的误差相较于IMU定位方法得到了很大的提升,但由于受到非视距信号的影响,两种方法的误差波动较为明显,其中FG-UWB/IMU定位方法由于融合了IMU信息,因此其误差曲线相较于LS-UWB定位方法稍平滑些;最后,所提出的定位方法的误差曲线最为平滑,这归功于有效的非视距信号判别以及基于判别结果的动态融合策略,避免了将大量的非视距误差引入到融合定位模型中。可以看到,所提方法有效提升了非视距环境下的UWB/IMU融合定位的精度与鲁棒性。

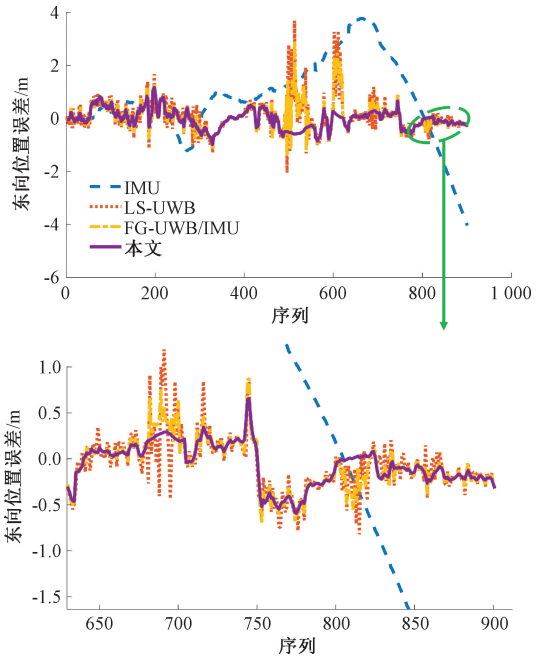


图8 不同方法的东向定位误差

Fig. 8 Position errors in east of different methods

最后对比了不同定位方法得到的智能车位置轨迹与真实轨迹,如图10所示,其中,虚线代表IMU方法,虚点线代表LS-UWB方法,点划线代表FG-UWB/IMU方法,粗实线代表提出的方法,细实线代表真值。从图10可以看出,IMU定位方法由于累积误差的影响,其定位轨迹出现了较大偏移,尤其随着时间的推进,虽然轨迹的整体趋势仍较为正确,但其偏移程度逐渐增大;而LS-UWB定位方法和FG-UWB/IMU定位方法由于引入了UWB无线测量值,因此整体的定位轨迹没有出现大的偏移,然而由于这两种方法均引入了非视距误差,因此其定位轨迹中出现了较多的异常值,其中FG-UWB/IMU定位方法由于融合了IMU信息,因此异常轨迹值的偏移程度要小于LS-




图 9 不同方法的北向定位误差

Fig. 9 Position errors in north of different methods

UWB 定位方法;最后,所提出的方法有效规避了大量非视距信号的引入,在一些非视距比较严重的区域,如图 10 中的子图所示,所提方法在有效判别出非视距信号的基础上,只采用了 IMU 信息进行定位,因此轨迹更为平滑,也最接近于实际的轨迹真值。但是也可以看到,定位结果中还存在不少异常值,这是因为所提方法只针对非视距误差数据进行了动态筛选,并没有进行修正,这也是后续进一步提升定位精度的主要方法。

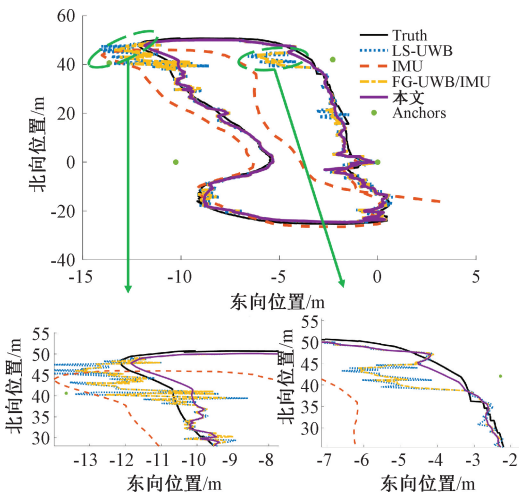


图 10 实车试验中不同方法的定位轨迹

Fig. 10 Positioning trajectories of different methods in real vehicle experiment

3) 实时性结果与分析

所提出方法各个模块处理单点数据的实时性情况,如表 5 所示。其中,多传感一致性模型和 D-S 证据理论模型属于数值计算类型,因此其耗时很短,几乎可以忽略不计;SVM 模型的耗时是指其经过训练之后的推理耗时,结果为 0.189 3 ms,远低于 UWB 的采集频率;融合定位模型的单点耗时为 2.322 6 ms,也可以满足 IMU 的采集频率。综上,所提方法在处理单个数据的时候,各模块的总体耗时为 2.513 5 ms,实时性能较为优异,即便后续部署应用在算力稍差的车载计算单元上,也具备保障实车运行的能力。

表 5 各模块的实时性结果

Table 5 Time consumption of each module

模块	耗时/ms
SVM 模型	0.189 3
多传感一致性模型	0.001 0
D-S 证据理论模型	0.000 6
融合定位模型	2.322 6

3 结 论

针对非视距环境下智能车无线定位误差变大的难题,提出了一种 UWB/IMU 鲁棒融合定位方法。首先设计了基于两阶段多模型融合的非视距信号判别方法,实现了对非视距信号的粗细两级判别,在此基础上,构建了基于因子图的融合模型,根据上述模型的非视距判别结果对 UWB/IMU 融合模型进行动态调整,以避免引入大量的非视距误差。实车试验结果表明了所提方法的有效性,在非视距判别方面,相较于常规的 SVM 判别模型,所提方法的非视距判别精度、召回率和准确率分别提高了 6.97%、5.37% 和 6.36%;在定位性能方面,相较于传统的 UWB 最小二乘定位方法,非视距环境下的定位均方根误差、最大误差和标准差分别降低了 12.55%、63.40% 以及 13.23%,具有可靠性高、环境适应力强等优点,有效抑制了非视距信号对无线定位性能的影响,提高了非视距环境下智能车无线定位的鲁棒性与可靠性。

参考文献

[1] CUI X F, LI Y B, WANG Q Y. Enhanced vehicle heading estimation for magnetometer/gyroscope integration with random magnetic interference detection based on pearson correlation coefficient [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73:1-16.

[2] SHI J, WANG W, LI X, et al. Motion distortion elimination for LiDAR-inertial odometry under rapid

- motion conditions [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-16.
- [3] 王东宇, 张慧君, 李孝辉, 等. 遮挡环境下的基于AKF组合导航定位方法研究[J]. *电子测量与仪器学报*, 2023, 37(5):171-179.
WANG D Y, ZHANG H J, LI X H, et al. Research on positioning in covering environment with an AKF-based integrated navigation system [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37 (5) : 171-179.
- [4] 田哲铭, 李旭, 胡悦, 等. 城市峡谷下视觉辅助的GNSS/INS多阶段定位方法[J]. *仪器仪表学报*, 2024, 45(4):217-225.
TIAN ZH M, LI X, HU Y, et al. Multi-stage localization method based on camera-aided GNSS/INS integration in urban canyon areas [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(4):217-225.
- [5] YAO H Y, LIANG X L, CHEN R ZH, et al. A benchmark of absolute and relative positioning solutions in GNSS denied environments [J]. *IEEE Internet of Things Journal*, 2024, 11(3):4243-4273.
- [6] JIANG W, CAO ZH J, CAI B G, et al. Indoor and outdoor seamless positioning method using UWB enhanced multi-sensor tightly-coupled integration [J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(10):10633-10645.
- [7] YU Y, CHEN R ZH, CHEN L, et al. A robust seamless localization framework based on Wi-Fi FTM / GNSS and built-in sensors [J]. *IEEE Communications Letters*, 2021, 25(7):2226-2230.
- [8] HU Y, LI X, DONG X, et al. A reliable cooperative fusion positioning methodology for intelligent vehicle in non-line-of-sight environments[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71:1-11.
- [9] 瞿智, 张慧晴, 陈建云. 基于UWB的无线网络精密时钟同步设计[J]. *国外电子测量技术*, 2023, 42(6):86-92.
QU ZH, ZHANG H Q, CHEN J Y. Design of precise clock synchronization in wireless networks based on UWB [J]. *Foreign Electronic Measurement Technology*, 2023, 42(6):86-92.
- [10] 杨承志, 张晓明, 张鸽. 基于WLS-KF的UWB室内定位滤波算法研究[J]. *电子测量与仪器学报*, 2024, 38(1):25-33.
YANG CH ZH, ZHANG X M, ZHANG G. Research on UWB indoor localization filtering algorithm based on WLS-KF [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(1):25-33.
- [11] CHEN Y E, LIEW H H, CHAO J C, et al. Decimeter-accuracy positioning for drones using two-stage trilateration in a gps-denied environment [J]. *IEEE Internet of Things Journal*, 2023, 10(9):8319-8326.
- [12] LI X X, WU Z ZH, SHEN ZH H, et al. An indoor and outdoor seamless positioning system for low-cost UGV using PPP/INS/UWB tightly coupled integration [J]. *IEEE Sensors Journal*, 2023, 23(20):24895-24906.
- [13] 鹿浩, 侯玉涛, 杨晓倩, 等. 基于复域超多维标度的混合TOA/AOA定位算法[J]. *电子测量技术*, 2023, 46(13):39-45.
LU H, HOU Y T, YANG X Q, et al. Research on hybrid TOA/AOA location algorithm based on super multidimensional scale in complex domain [J]. *Electronic Measurement Technology*, 2023, 46 (13) : 39-45.
- [14] JIANG CH H, SHEN J CH, CHEN SH, et al. UWB NLOS/LOS classification using deep learning method [J]. *IEEE Communications Letters*, 2020, 24(10):2226-2230.
- [15] NKROW R E, SILVA B, BOSHOFF D, et al. Transfer learning-based NLOS identification for UWB in dynamic obstructed settings [J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(3):4839-4849.
- [16] YANG H C, WANG Y J, SEOW C K, et al. UWB Sensor-based indoor LOS/NLOS localization with support vector machine learning [J]. *IEEE Sensors Journal*, 2023, 23(3):2988-3004.
- [17] MIRAMÁ V, BAHILLO A, QUINTERO V, et al. NLOS detection generated by body shadowing in a 6.5 GHz UWB localization system using machine learning [J]. *IEEE Sensors Journal*, 2023, 23(17):20400-20411.
- [18] 周彦臻, 吴瑞东, 于潇, 等. 面向FPGA部署的CNN-SVM算法研究与实现[J]. *电子测量与仪器学报*, 2021, 35(4):90-98.
ZHOU Y ZH, WU R D, YU X, et al. Research and implementation of CNN-SVM algorithm based on FPGA [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(4):90-98.
- [19] 潘伟豪, 徐赛博, 郭弘扬, 等. 基于D-S证据理论的高分遥感影像建筑物变化检测[J]. *电子测量与仪器学报*, 2022, 36(8):194-203.
PAN W H, XU S B, GUO H Y, et al. Building change

detection of high-resolution remote sensing images based on D-S evidence theory[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8):194-203.

- [20] 李倩, 蒋正华, 孙炎, 等. 基于因子图的 INS/UWB 室内行人紧组合定位技术[J]. 仪器仪表学报, 2022, 43(5):32-45.

LI Q, JIANG ZH H, SUN Y, et al. INS/UWB tight integrated localization technology for pedestrian indoor based on factor graph[J]. Chinese Journal of Scientific Instrument, 2022, 43(5):32-45.

- [21] BAI S, LAI J, LYU P, et al. A novel plug-and-play factor graph method for asynchronous absolute/relative measurements fusion in multisensor positioning[J]. IEEE Transactions on Industrial Electronics, 2022, 70(1):940-950.

作者简介



胡悦(通信作者), 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, 2024 年于东南大学获得博士学位, 现为国防科技大学第六十三研究所助理研究员, 主要研究方向为多模态信息融合、智能计算等。

E-mail: hyhfut@163.com

Hu Yue(Corresponding author) received his B. Sc. degree from Hefei University of Technology in 2015, M. Sc. degree from Hefei University of Technology in 2018, and Ph. D. degree from Southeast University in 2024. Now he is a research associate in the 63rd Research Institute, National University of Defense Technology. His main research interests include multi-sensor fusion, intelligent computing, etc.

DOI: 10.13382/j.jemi.B2407908

嵌套型开口谐振环阵列设计及其在冰层检测中的应用*

胡崇琳 高尚 王浩 杨尚可 江剑

(南京理工大学机械工程学院 南京 210094)

摘要:针对传统技术检测飞行器表面冰层厚度存在灵敏度低、检测面积小及线性度差的行业难题,利用嵌套型开口谐振环(nested split ring resonator, NSRR)结构辐射能力强、低损耗、高品质因数、场集中效应强、易小型化的特性,以尺寸大小为 11×11 mm的NSRR单元结构为基础,设计并制备了一种由72个单元组成的传感器阵列,该阵列总体尺寸为 88×99 mm,通过提取传感器阵列谐振频率偏移量实现金属结构件上冰层厚度的反演。ADS等效电路仿真结果表明,NSRR等效电容与传感器阵列的谐振频率存在一一对应关系。HFSS仿真结果表明,该传感器阵列具备不同浓度介质检测和毫米级冰层平均厚度测量的能力,仿真灵敏度为 23.46 MHz/mm。实验结果表明,该传感器阵列的谐振频率与冰层平均厚度具有良好的线性关系,线性拟合的决定系数为 0.989 ,对冰层平均厚度的最大检测灵敏度达到 21.15 MHz/mm,最大相对误差小于 5% ,证明了该传感器能够实现对结构表面冰层平均厚度的大面积量化检测,具有高灵敏度、大尺寸、低成本、易扩展等优点。

关键词: 结冰检测;开口谐振环;有限元分析;谐振频率;传感器阵列

中图分类号: TP212.9; TN304.3

文献标识码: A

国家标准学科分类代码: 510.1025

Design of nested split ring resonator (NSRR) array and application in ice detection

Hu Chonglin Gao Shang Wang Hao Yang Shangke Jiang Jian

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In response to industry challenges such as low sensitivity, limited detection area, and poor linearity in conventional methods for measuring ice thickness on aircraft surfaces, this study proposes a sensor array based on the nested split-ring resonator (NSRR) structure. This structure is characterized by strong radiation capability, low loss, high quality factor, strong field confinement effect, and ease of miniaturization. A sensor array composed of 72 nested split-ring resonator (NSRR) units (11×11 mm) was designed and fabricated, achieving a compact footprint of 88×99 mm. This system quantifies ice thickness by monitoring shifts in resonance frequency. ADS equivalent circuit simulations revealed a deterministic relationship between the NSRR's equivalent capacitance and the array's resonance frequency. HFSS electromagnetic simulations further demonstrated the array's capability to detect media with varying dielectric constants and measure ice thickness at millimeter-scale resolution, with a simulated sensitivity of 23.46 MHz/mm. Experimental results further validate a strong linear relationship between the resonance frequency and average ice thickness, with a coefficient of determination (R^2) of 0.989 . The maximum detection sensitivity reaches 21.15 MHz/mm, with a maximum relative error of less than 5% . These findings demonstrate that the proposed sensor facilitates large-area, quantitative detection of average ice thickness on structural surfaces, offering advantages such as high sensitivity, extensive coverage, low cost, and scalability.

Keywords: ice detection; split-ring resonator; finite element analysis; resonant frequency; sensor array