

DOI: 10.19650/j.cnki.cjsi.J2312282

城市峡谷下视觉辅助的 GNSS/INS 多阶段定位方法*

田哲铭, 李 旭, 胡 悦, 韦 坤, 刘锡祥
(东南大学仪器科学与工程学院 南京 210096)

摘 要:城市峡谷环境中卫星信号遮挡严重且质量易变,导致智能车的定位易失准甚至失效。为有效利用可观测的卫星信号,提出了一种基于可视卫星的 GNSS/INS 融合定位方法。首先,利用鱼眼相机筛选视距卫星,进而基于正交回归拟合方法定义空视情况优劣;接着,构建基于因子图的 GNSS/INS 融合定位框架,考虑到观测的不稳定性,分别构建了伪距、多普勒频率、载波相位观测因子,并在满足观测条件时增添对应的约束因子进行优化;最后,设计了基于空视情况的区间优化规则,优化长度跟随遮挡区间变化,以适应不同的遮挡情况。实车实验表明,相比传统的多传感融合方法,本文的多阶段定位方法在严重遮挡区域内定位精度提高了 40% 以上,有效提高了城市峡谷中的定位精度。

关键词:城市峡谷定位;非视距信号;GNSS/INS 紧组合;因子图

中图分类号: TH761 TH89 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Multi-stage localization method based on camera-aided GNSS/INS integration in urban canyon areas

Tian Zheming, Li Xu, Hu Yue, Wei Kun, Liu Xixiang

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

Abstract: The GNSS signal within the urban canyon areas suffers from the severe blockage and variable quality, which can lead to the inaccurate or even ineffective positioning of intelligent vehicles. To effectively utilize available satellite observations, a multi-sensor fusion method based on camera-aided GNSS/INS integration is proposed. Firstly, a sky-pointing camera is utilized to capture the sky view image and exclude the NLOS measurements, meanwhile the satellites distribution state is defined by the remaining LOS measurements with orthogonal linear regression method. Additionally a factor graph fusion framework based on GNSS/INS integration is proposed by considering the instability of observations, three factors consisting of pseudorange, Doppler frequency, and carrier phase are added for the optimization estimation when the corresponding observation conditions are met. Lastly, the dynamic window optimization rules are designed according to the satellites distribution state, and the length of optimization window is adjusted to follow the change of GNSS blockage. The road tests show that the proposed method enhances more than 40% of positioning accuracy in the blockage interval compared to the conventional fusion method and improves positioning accuracy in urban canyons effectively.

Keywords: urban localization; NLOS; GNSS/INS integration; factor graph

0 引 言

惯性/卫星组合导航系统凭借其优异的精度与鲁棒性,广泛搭载在各类智能车中,可以满足大多数场景中的定位需求^[1]。然而在典型的现代化都市中,城市道路周边高楼林立,容易形成城市峡谷环境,这会导致卫星构型

较差、可用数减少,并且引入多径效应(multipath effects)、非视距(non-line-of-sight, NLOS)信号等干扰,这些不利因素可能会严重影响全球卫星导航系统(global navigation satellite systems, GNSS)的可靠性,甚至严重降低整个组合导航系统的定位精度。

因此,许多研究试图去提高此类环境下的定位精度。在卫星导航方面,得益于 GNSS 的不断发展和完善,可视

收稿日期:2024-01-31 Received Date: 2024-01-31

* 基金项目:国家重点研发计划(2022YFB3904404)、江苏省重点研发计划(BE2022053-5)项目资助

卫星数不断上升,空视受限的场景能够捕获更多的卫星,这也为改善城市峡谷中 GNSS 的定位精度提供了契机。为了提高遮挡环境中的卫星定位可靠性,可以从改善 GNSS 信号本身出发,许多早期研究关注于 GNSS 信号测量域处理技术的改进,主要基于物理或经验模型来缓解多径干扰,比如采用测量信号强度(信噪比(signal to noise ratio, SNR)和载波噪声比(carrier to noise ratio, CNR)等来间接建模多径误差^[2]或通过接收机自主完整性监测(receiver autonomous integrity monitoring, RAIM)方法^[3-4]隔离 NLOS 信号等,但这类方法在观测冗余量不足^[5]并且存在强信号强度的多径反射^[6]的城市峡谷中的效果并不理想。随着三维地图的引入,出现了一些基于三维环境模型的 NLOS 判别方法,比如阴影匹配法^[7-9],但其高度依赖接收机的初始位置假设以及先验地图准确性;也有方法使用红外相机^[10]、鱼眼相机^[11]、旋转式激光雷达^[12]等传感器感知周边信息,辅助检测卫星视线方向上是否存在遮挡,这为 NLOS 提供了一种新的判别思路。随着基于学习的方法的兴起,采用模糊逻辑^[13]、支持向量机^[14]以及长短期记忆网络^[15]的方法在 NLOS 信号判别以及多径误差预测工作中取得了良好的泛化成果,然而该类方法基于大量的数据进行训练,并且需要占用较多的计算资源,其通用性存在限制,难以实际落地。

除了合理选用视距(line-of-sight, LOS)信号之外,由于卫星的定位效果受限于卫星观测质量,自主性较差,现实中经常使用短时精度高、抗干扰性强的惯导系统(inertial navigation system, INS)予以弥补,构成泛用性更高的 GNSS/INS 组合导航系统^[16]。传统的融合方法通常采用卡尔曼滤波及其变体^[17],依赖于事先建立的固有且准确的数学模型,当观测信号多变时适应性较弱。最近提出的因子图优化方法^[18]可以通过非线性优化集成各种传感器测量,相较于马尔科夫过程的卡尔曼滤波可以对多个历史状态进行联合优化^[19-20],在类似城市峡谷的挑战性环境中,伪距级融合的因子图优化方法(factor graph optimization, FGO)相较扩展卡尔曼滤波(extend Kalman filter, EKF)方法展现出了更好的效果^[21],但其准确性和效率在很大程度上取决于优化窗口的大小,如何合理的调整优化窗口大小还需进一步考虑^[22]。此外伪距级融合方法也受制于伪距观测精度,在开阔情况下才能达到分米级别,常需要引入多普勒频率和载波相位等精度更高的观测才能进一步提升定位精度。这3种观测的误差特性不尽相同,并且常规使用载波相位的实时差分定位(real time kinematic, RTK)一般还需要基地的辅助,但这样既引入了通信链路的成本问题,又涉及到用户的隐私安全问题,这进一步限制了 GNSS 高精定位的应用。

针对以上问题,本文提出了一种面向城市峡谷环境的智能车定位方案,采用鱼眼相机辅助筛选视距卫星并构建基于因子图的 GNSS/INS 融合框架。在卫星观测质量不佳的情况下仅选用视距卫星,紧耦合 GNSS 与 INS 的输出,依次实现伪距粗定位、多普勒频率对准、载波相位细化的三阶段定位流程,并针对载波相位进行时间差分,不需与基站通信;同时制定因子图优化调整规则,跟随卫星可视情况动态调整,实现智能车在城市峡谷环境下的可靠定位。

1 理论分析

本文提出的定位流程如图1所示,主要包含视距判别、阶段优化定位、自适应调整规则3个部分。

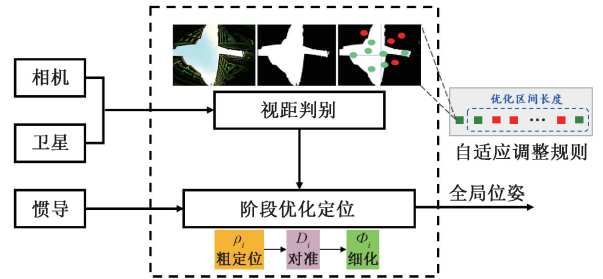


图1 视觉辅助的GNSS/INS定位流程

Fig. 1 The process of GNSS/INS integration aided by camera

首先通过鱼眼相机获取天空视图,结合 GNSS 原始数据进行视距判别,并根据视距卫星分布定义当前空视情况;其次,通过 INS 获取加速度、角速度信息,融合 GNSS 的伪距、多普勒频率、载波相位依次进行初始化定位、航迹对准与细化定位,利用因子图即插即用的特性,构建由粗到细的三阶段定位流程;最后,基于制定的自适应调整规则,根据当前历元的空视情况调整优化区间,对 GNSS/INS 数据进行动态融合,实现卫星观测受限下的融合定位。

1.1 视距判别

非视距是指信号直线的传播路径上存在遮挡物,接收机仅接收到了反射信号的情况,为了实现可靠的卫星定位,需要对参与融合的卫星进行筛选,优先选用视距信号。传统方法通常考虑信噪比、高度角、方位角等参数选用最佳分布的低噪卫星,在遮挡严重的城市峡谷中并不能明确区分视距与非视距信号。为了提高卫星观测的可靠性,参考鱼眼相机选星方法^[11],本文同样引入垂直水平面安装的鱼眼相机来监测车辆的空视环境,与其不同的是图像处理在 HSV (hue saturation value) 颜色空间进行,通过提取掩膜的方案区分前景与背景(遮挡区域与天空区域),将卫星投影至分割图像中进行非视距判别,并

利用判别结果定义空视情况优劣。

在进行分割之前,首先对 GNSS 观测与相机图像进行同步,以历元为基准进行选星,即选星周期与卫星观测更新频率一致;随后在 HSV 颜色空间对图像进行分割:

- 1) 图像转 HSV 格式并对 S 通道和 V 通道进行直方图均值化;
- 2) 根据设定的 HSV 三通道阈值(本文选用范围 H: 0~180; S: 30~200; V: 200~255)选定天空的颜色范围,提取天空掩膜 mask;
- 3) 天空掩膜 mask 取反得到遮挡区域掩膜_mask;
- 4) 提取_mask 轮廓区域并进行开运算;
- 5) 输出遮挡区域掩膜_mask,像素值为 1 的即为天空区域。

在得到天空分割图_mask 后,结合相机参数选用对应的径向对称投影^[23],将卫星投影至天空分割图中,其中卫星 i 与图像中心的距离 r_{pix} 与其高度角 β_i 有关,可以表示为:

$$r_{pix} = 2f_c \tan\left(\left(\frac{\pi}{2} - \beta_i\right) / 2\right) \quad (1)$$

式中: f_c 是焦距,假设天空视图中心像素坐标为 (x_c, y_c) ,基于如图 2 所示的转换关系,则卫星 i 的像素坐标为 (x_i^{sat}, y_i^{sat}) :

$$\begin{cases} x_i^{sat} = x_c + r_{pix} \cos(\varphi + \alpha_i) \\ y_i^{sat} = y_c - r_{pix} \sin(\varphi + \alpha_i) \end{cases} \quad (2)$$

式中: φ 是车辆航向角, α_i 的是卫星 i 的方位角。




图 2 像素坐标系卫星投影转换关系

Fig. 2 Projection of satellites in Pixel coordinate

根据卫星 i 的像素坐标 (x_i^{sat}, y_i^{sat}) 与天空分割图_mask 的天空区域进行对照,即可筛选出视距内卫星与非视距卫星,筛选结果如图 3 所示。

此外,本文研究了一种基于正交回归拟合的改进方法辅助判断卫星分布情况,用于定义当前空视情况。该方法仅对视距内卫星进行正交回归拟合,通过对比视距




图 3 天空分割与卫星筛选示意图

Fig. 3 The result of sky segmentation and satellite visibility

内卫星与拟合直线距离,对卫星构型进行判断,首先在像素坐标系下对卫星坐标采用正交回归拟合,综合考虑纵横坐标的误差,误差函数的形式为:

$$J = \sum_{i=1}^{n_{LOS}} [(\hat{x}_i - x_i^{sat})^2 + (\hat{y}_i - y_i^{sat})^2] \quad (3)$$

式中: n_{LOS} 是视距内卫星个数; (\hat{x}_i, \hat{y}_i) 是直线上到 (x_i^{sat}, y_i^{sat}) 距离最短的点。可以证明,拟合直线 l 为 $a(x - \bar{x}_0) + b(y - \bar{y}_0) = 0$,其中 (\bar{x}_0, \bar{y}_0) 是 (x_i^{sat}, y_i^{sat}) 的均值点,单位法向量 (a, b) 为矩阵 $S = \begin{bmatrix} s_{xx} & s_{xy} \\ s_{xy} & s_{yy} \end{bmatrix}$ 的最小特征值对应的特征向量,其中 s_{xx} 和 s_{yy} 分别是 x 和 y 的方差, s_{xy} 是 x 和 y 的协方差。

设置距离阈值 $d^{sat} = d_c / 4$,其中 d_c 是鱼眼相机视场圆的直径长度,该距离阈值依据经验值设置,具体可根据跟踪卫星数以及卫星密度,合理设置与 d_c 的比例。如果与拟合直线 l 距离大于 d^{sat} 的可视卫星数 ≥ 2 ,则认为当前空视情况良好,该条件为后续自适应调整规则提供卫星分布判断基础。

1.2 三阶段优化定位

由于智能车运动的高动态性以及城市峡谷周边环境的复杂性,观测到的卫星往往数量较少且信号易变,为了充分利用有限的观测信息,引入 3 种 GNSS 因子进行融合,以应对不同的观测状态,本方法构建的因子图模型如图 4 所示。




图 4 基于的因子图多源融合框架

Fig. 4 Multi-source fusion framework based on factor graph

图中变量节点(空心大圆)代表系统状态 x_i ;因子节点(实心小圆)代表系统先验、惯导预积分、卫导观测(伪

距、多普勒频率、载波相位)。本文的融合策略如下:

以卫星观测历元为基准创建节点,对于卫星因子,当卫星位于视距内时加入伪距因子;当速度较大时加入多普勒频移因子;当卫星在视距内被连续跟踪一段时间后加入载波相位因子;对于惯导因子,以预积分的形式在节点间被稳定添加,避免每次优化对位姿重新积分,从而有效地参与区间优化。

本方法使用原始层级的数据进行融合,属于紧耦合的融合方法,智能车在时刻 k 的状态可以表示为:

$$\mathbf{x}_k = [\mathbf{p}_k^e, \mathbf{q}_k^e, \mathbf{v}_k^e, \mathbf{b}_a, \mathbf{b}_w, \hat{\delta}_k]^T \quad (4)$$

式中: \mathbf{p}_k^e 、 \mathbf{q}_k^e 和 \mathbf{v}_k^e 分别代表智能车在地心地固坐标系 f_{ecdf} 下的位置、姿态和速度; \mathbf{b}_a 和 \mathbf{b}_w 分别代表加速度计的零偏与陀螺仪的零偏; $\hat{\delta}_k$ 为接收机钟漂。

截止到时刻 k 因子图窗口内待优化状态可以表示为:

$$\boldsymbol{\chi} = [\mathbf{x}_0, \dots, \mathbf{x}_k] \quad (5)$$

而最优状态估计 $\boldsymbol{\chi}^*$ 最大后验估计问题可以转化为最小二乘问题,最小化所有观测残差的先验和马氏距离之和,以获得最大后验概率估计:

$$\boldsymbol{\chi}^* = \min_{\boldsymbol{\chi}} \sum (\|\mathbf{r}_p - \mathbf{H}_p \boldsymbol{\chi}\| + \|\mathbf{r}_b\|_{\Sigma_b}^2 + \|\mathbf{r}_\rho\|_{\Sigma_\rho}^2 + \|\mathbf{r}_{dp}\|_{\Sigma_{dp}}^2 + \|\mathbf{r}_\phi\|_{\Sigma_\phi}^2) \quad (6)$$

式中: $\mathbf{r}_p - \mathbf{H}_p \boldsymbol{\chi}$ 代表边缘化的先验因子; \mathbf{r}_b 代表惯导预积分因子,协方差为 Σ_b ; \mathbf{r}_ρ 、 \mathbf{r}_{dp} 、 \mathbf{r}_ϕ 分别代表 GNSS 的伪距因子、多普勒频率因子、差分载波相位因子,协方差分别为 Σ_ρ 、 Σ_{dp} 、 Σ_ϕ 。惯导预积分因子用来约束两节点之间位姿、速度和零偏,并用来提供高频的状态更新,残差 \mathbf{r}_b 的构建方法依照文献[24],本方法主要描述 GNSS 相关因子残差的构建方法。

如果接收机在 t_i 时刻锁定了一颗卫星 m ,其伪距观测通常由信号传播时间乘以光速 c 获得,但其中包含着接收机钟差、卫星钟差、电离层延时、对流层延时等误差,多普勒频率与载波相位也有着类似的误差形式,在 t_i 时刻对于卫星 m 的 3 种观测^[25] 依次可以建模为:

$$\rho_i^m = \rho^m + c(\delta t_i - \Delta t^m) + T_i^m + I_i^m + \varepsilon_\rho \quad (7)$$

$$D_i^m = \dot{\rho}^m + c(\delta f_i - \Delta f^m) + \varepsilon_D \quad (8)$$

$$\Phi_i^m = \rho^m + c(\delta t_i - \Delta t^m) + T_i^m - I_i^m + \lambda N_i^m + \varepsilon_\Phi \quad (9)$$

式中: $\rho^m = \|\mathbf{s}_i^m - \mathbf{T}_{EL} \mathbf{p}_i\|$ 表示接收机相位中心到卫星相位中心的几何距离, \mathbf{s}_i^m 是卫星 m 在 f_{ecdf} 系下的位置; \mathbf{T}_{EL} 是 f_{ecdf} 系到局部东北天坐标系的转换矩阵; \mathbf{p}_i 是接收机的局部坐标位置; δt_i 和 δf_i 分别表示接收机的钟差与频偏; Δt^m 和 Δf^m 分别表示卫星 m 的钟差与频偏; T_i^m 是对流层时延误差; I_i^m 是电离层时延误差; λ 是载波波长; $N_i^m \in \mathbb{N}^+$ 是卫星 m 的整周模糊度; ε_ρ 、 ε_D 和 ε_Φ 是其他不易建模的误差,主要包括多径效应、非视距、接收机噪声、硬件延迟等引起的误差。

1) 伪距粗定位

在进行融合优化之前,首先需要获取智能车粗略位置以初始化局部东北天坐标系 f_{enu} 。因此,初始化过程总是以 GNSS 的单点定位解算 (single point position, SPP) 开始,在跟踪到至少 $N+3$ 颗卫星后 (N 代表观测到的卫星系统数),利用所有的伪距观测计算出粗略的基准点与航向角,固定 f_{enu} 原点在 f_{ecdf} 下的位置,以进行后续的全局到局部的坐标转换。考虑到卫星观测受限, SPP 的结果精度较低,对于初始化误差对后续坐标转换的影响将在实验部分进一步讨论。

此外,对伪距观测选用特定的模型修正后,伪距观测模型为:

$$\rho_i = f_\rho(\mathbf{s}_i^m, \mathbf{p}_i, \delta t_i) + \omega_{\rho,i} \quad (10)$$

式中: $f_\rho(\mathbf{s}_i^m, \mathbf{p}_i, \delta t_i) = \|\mathbf{s}_i^m - \mathbf{T}_{EL} \mathbf{p}_i\| + c\delta t_i$, $\omega_{\rho,i}$ 是伪距的测量误差,其协方差矩阵 $\Sigma_{\rho,i}$ 由卫星高度角、信噪比等参数建立:

$$\Sigma_{\rho,i} = \frac{n_m n_\rho}{\sin^2 \beta} \quad (11)$$

式中: n_m 由广播星历精度决定; n_ρ 是伪距测量噪声,可以由接收机直接获得; β 是卫星高度角,因此最终的伪距因子残差为:

$$\|\mathbf{r}_\rho\|_{\Sigma_\rho}^2 = \|\rho_i - f_\rho(\mathbf{s}_i^m, \mathbf{p}_i, \delta t_i)\|_{\Sigma_{\rho,i}}^2 \quad (12)$$

2) 多普勒频率对准

在智能车初始化完成且具有足够的动态性能后,引入多普勒频率因子进行优化。在视距情况下的多普勒频率精度在 dm/s 级别,相较伪距精度存在一个数量级的优势;而在非视距且反射点变化时其精度可能会降低值 m/s 级别,基于此,在多普勒频率对准阶段仅选用视距内卫星数据,针对性地优化对频移更为敏感的变量,主要包括接收机钟差、智能车的速度,用多普勒频率对相邻时刻进行约束,构建该阶段的残差,多普勒测速的观测模型为:

$$\mathbf{v}_i = f_v(\mathbf{s}_i^m, \mathbf{p}_i, \delta t) + \omega_{v,i} \quad (13)$$

式中: $f_v(\mathbf{s}_i^m, \mathbf{p}_i, \delta t) = \|\mathbf{s}_i^m - \mathbf{T}_{EL} \mathbf{p}_i\| / \Delta t + c\delta t$, δt 是接收机钟漂, Δt 是时间更新间隔,因此该模型精度与接收机更新频率有关。类似的, $\omega_{v,i}$ 是多普勒测速的测量误差,其协方差矩阵 $\Sigma_{v,i} = \frac{n_m n_v}{\sin^2 \beta}$, 其中 n_v 是接收机的多普勒频率测量噪声,因此最终的多普勒因子残差为:

$$\|\mathbf{r}_{dp}\|_{\Sigma_{dp}}^2 = \|\mathbf{v}_i - f_v(\mathbf{s}_i^m, \mathbf{p}_i, \delta t_i)\|_{\Sigma_{dp,i}}^2 \quad (14)$$

基于此,可以得到多普勒频率对准阶段的优化目标:

$$\min_{\mathbf{v}, \delta t} \sum \|\mathbf{r}_{dp}\|_{\Sigma_{dp}}^2 \quad (15)$$

在多普勒频率对准阶段本质上是对三维速度 \mathbf{v} 以及接收机钟漂 δt 进行优化,其同时也可以根据 \mathbf{v} 的水平分量对智能车历史轨迹进行全局对准,并且预先修正车辆的航向角 φ ,以提高式(2)卫星在图像坐标中的投影精

度,从而提升非视距判别的准确性。

3) 载波相位细化定位

在信号易变的城市峡谷中,卫星的频繁失锁与重新捕获使得实时动态地解算式(9)中未知的整周模糊度 N_i^m 更为困难,因此有学者提出了历元差分^[25]的方法来避免计算 N_i^m ,即使用当前历元与包含一段先前历元的历史状态构成时间差分观测。由于载波相位跟踪的不稳定性,本方法也采用类似的时间差分思想构建双差载波相位观测,进一步约束航迹对准后的定位误差。选择相同的卫星系统的卫星 m 与卫星 n 同时进行星间差分,对于序列时刻 i, j 进行时间差分:

$$\nabla\Delta\Phi_{ij}^{mn} = (\Phi_j^m - \Phi_j^n) - (\Phi_i^m - \Phi_i^n) \quad (16)$$

式中:卫星 n 是参考卫星,一般选取天空视图中跟踪时间长、高度角高的视距卫星。由于序列时刻 i, j 之间时间较短,大气时延误差变化可以忽略不计,基于时间差分的双差载波相位观测模型为:

$$\phi_{DD,i,j} = f_\phi(s_i^m, s_i^n, s_j^m, s_j^n, p_i, p_j) + \omega_{\phi,i,j} \quad (17)$$

式中: $f_\phi(s_i^m, s_i^n, s_j^m, s_j^n, p_i, p_j) = (\|s_j^m - T_{EL}p_j\| - \|s_i^m - T_{EL}p_i\|) - (\|s_j^n - T_{EL}p_j\| - \|s_i^n - T_{EL}p_i\|) + \nabla\Delta\Phi_{ij}^{mn}$; $\omega_{\phi,i,j}$ 是双差测量误差,其协方差矩阵 $\sum_{\phi,i,j}$; 因此最终的差分载波因子残差为:

$$\|r_\phi\|_{\sum_\phi}^2 = \|\phi_{DD,i,j} - f_\phi(s_i^m, s_i^n, s_j^m, s_j^n, p_i, p_j)\|_{\sum_{\phi,i,j}} \quad (18)$$

基于此,可以得到载波相位优化阶段的优化目标:

$$\min_{p, T_{EL}, \delta_i} (\|r_\rho\|_{\sum_\rho}^2 + \|r_\phi\|_{\sum_\phi}^2) \quad (19)$$

使用伪距因子可以获得全局无漂移的绝对定位,使用差分载波因子可以实现准确平滑的局部相对定位,在载波相位细化定位阶段,本方法对两种因子进行联合优化,以在无基站的情况下充分利用载波相位观测,提升智能车定位精度。

1.3 自适应调整规则

为了解决 GNSS 观测信号多变的影响,利用因子图的历史关联特性制定如下的自适应调整规则,如图 5 所示。

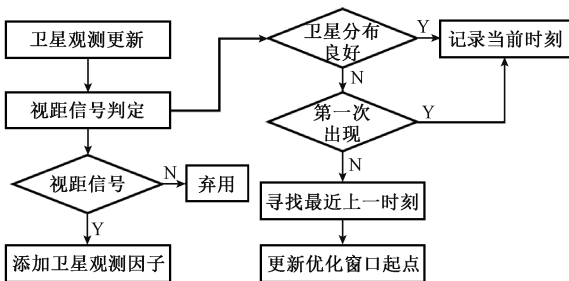


图 5 优化窗口调整规则

Fig. 5 The adjustment rule of optimizing window

- 1) 仅将视距信号的观测因子接入因子图;
- 2) 记录良好观测节点出现时刻,寻找最新的时刻作为优化窗口起点;
- 3) 优化区间随视距观测增加而增长,直至区间终点出现良好观测节点,此时对该段区间进行最后一次联合优化。

2 实验验证

本实验中使用的传感器包括 INS (Epson_G320)、GNSS (ublox-F9P)、鱼眼相机 (HF890) 和组合导航 (Npos 220),其中组合导航接入差分数据源,输出的高精 INS/RTK 定位结果不参与智能车位置估计,只用做参考值进行对比,实验设备如图 6 所示,其中鱼眼相机进行预先标定^[26],转换为高度角与距像素中心像素的关系如图 7 所示。



图 6 实验设备

Fig. 6 Experiment equipment




图 7 鱼眼相机标定结果

Fig. 7 The calibration result of fisheye camera

为验证本文方法的有效性,选取两个典型的城市场景进行实车实验,选取的实验地段如图 8 所示,对应的卫星可视情况如表 1 所示。



图8 实验实施路段与轨迹

Fig. 8 The road section and trajectory of field test

表1 卫星可视情况
Table 1 Satellite visibility

卫星	路段1		路段2	
	LOS	NLOS	LOS	NLOS
平均数量	5.41	8.64	6.05	4.37
方差	2.17	1.7	2.91	2.25
最大数量	7	10	8	7
最小数量	2	3	1	2
占比/%	38.5	61.5	58.1	41.9

考虑到伪距粗定位阶段初始位姿存在较大误差,为验证其对后续定位精度的影响,选取实验路段1起始部分对其进行验证,以参考系统的初始位姿为真值,分别对比不同精度初始值的影响,分别单独使用航向角真值、位置真值以及共同使用航向角真值与位置真值替换 SPP 的初始位姿,对比结果如图9所示。

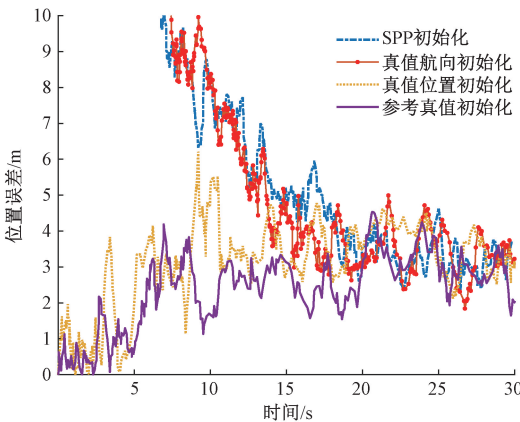


图9 路段1不同初始化方法定位误差

Fig. 9 Positioning errors for trajectory 1 with different initialization methods

可以看出,在只考虑绝对定位误差的前提下,初始位置的精度以及航向角的精度对定位效果有着不同的影

响,但4种方法最终的定位精度相当。精准的初始位置能够帮助本方法快速达到理想的精度,而精准的初始航向角同样对定位有促进作用,但其效果并不明显;对于仅使用 SPP 初始化的方法,其最终精度与真值初始化的最终精度相当,不过收敛耗时接近真值初始化的两倍。因此,本文的初始化方法对不稳定初始观测具有较高的稳定性,利用 SPP 获取的粗略位置与航向角在后续优化阶段能得到进一步校正,收敛后对坐标转换并不会产生较大影响,能够适应城市峡谷中质量易变的卫星观测。

为验证本文视距判别+INS/GNSS 紧耦合+动态优化方法的有效性(LOS-TFG-DO),主要将本文方法与下列常见方法进行对比:1)标准单点定位(SPP);2)标准单点定位+视距判别(LOS-SPP);3)GNSS/INS 松耦合+视距判别(LOS-LFG);4)GNSS/INS 紧耦合+视距判别(LOS-TFG)。

其中,SPP方法是传统的卫星定位方法;LOS-SPP方法加入了视觉选星来验证视距判别的有效性;LOS-LFG方法加入了INS数据,即常见的松耦合;LOS-TFG方法即常见的紧耦合;主要用来对比验证区间优化的有效性。两组实验不同定位方法的误差如表2所示。

表2 不同方法定位误差对比

Table 2 Positioning performance of different method

		平均误差/m	最大误差/m
SPP	路段1	20.73	45.23
	路段2	13.49	21.17
LOS-SPP	路段1	9.46	13.15
	路段2	8.33	11.21
LOS-LFG	路段1	4.78	8.22
	路段2	4.02	8.40
LOS-TFG	路段1	3.68	7.73
	路段2	2.22	7.41
LOS-TFG-DO	路段1	3.21	7.65
	路段2	1.46	3.13

结合表1可以看出,实验路段1是典型的城市峡谷环境,存在严重的非视距问题,路段1的NLOS占比达到61.5%,已经超过了LOS占比,最差时LOS卫星只有两颗,存在不满足SPP解算的时刻,传统的SPP定位误差最大也达到了45.23m。在引入视觉辅助选星后,其最大误差明显得到了明显改善,仅有原先的1/3,并且LOS-SPP的平均误差降低了54.4%,这表明该路段中的非视距信号严重影响了卫星定位的精度。对于GNSS与INS的融合方法,从图10中可以看出,融合定位的轨迹明显更为平顺,两种基于紧耦合的方法最大误差均降至10m

以内,说明采用多传感融合的方法对提升系统的鲁棒性有较大的帮助;在平均误差方面,本文的 LOS-TFG-DO 相较其他方法分别降低了 84.5%、66.1%、32.8%、和 12.8%,精度得到了大幅的提高,在严重遮挡环境中本方法能稳定取得最好的定位结果。




图 10 路段 1 定位结果

Fig. 10 Positioning result for trajectory 1

对于实验路段 2,由于其包括了空旷区域与遮挡区域,选取如图 11 所示的一段典型的“空旷-遮挡-空旷”区间进行分析,该区间位于图中虚线部分,放大如图 12 所示,定位误差位于图 13 中虚线部分。可以看出,由于该区间内卫星可视情况较差,LOS-TFG 方法出现了的偏差显著增加,而添加动态区间优化的 LOS-TFG-DO 方法依旧能维持的原有精度,区间内最大误差明显降低,分别较其他方法降低了 85.2%、72.1%、62.7% 和 57.8%,对粗大误差有良好的抑制作用;区间内平均误差相比未添加优化的 LOS-TFG 方法下降了 46.6%,表明了本方法对遮挡区间优化的有效性。




图 11 路段 2 定位结果

Fig. 11 Positioning result for trajectory 2

综上,实车实验结果表明本方法能够在城市峡谷环境中有效缓解 NLOS 信号对定位的影响,面对不同的遮

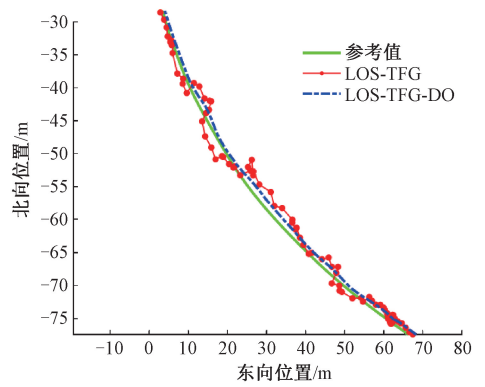


图 12 遮挡区间内定位结果

Fig. 12 Positioning result for blockage interval

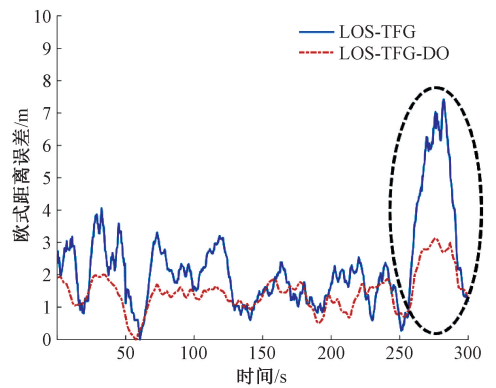


图 13 路段 2 定位误差

Fig. 13 Positioning errors for trajectory 2

挡情况,特别是严重遮挡的城市峡谷环境有着较强的适应力。相较传统的纯卫导定位与松、紧耦合方法,本方法的全程平均误差均降低了一倍以上;严重遮挡区间的最大误差降低了 50% 以上,平均误差降低了 40% 以上,为卫星受限情况下的可靠定位提供了一种有效的改进思路。

3 结 论

为提高城市峡谷环境下智能车的定位精度,本文提出了一种视觉辅助的 GNSS/INS 多阶段定位方法。首先,采用鱼眼相机辅助筛选视距卫星;其次,构建基于因子图的 GNSS/INS 融合框架,在卫星观测受限的情况下,紧耦合 GNSS 与 INS 的输出,依次实现伪距粗定位、多普勒频率对准、载波相位细化的三阶段定位流程;最后,制定因子图优化自适应调整规则,跟随卫星可视情况动态调整,对遮挡区间针对性优化。实车实验证明,本方法在城市峡谷环境中有着较高的鲁棒性,在遮挡区间的定位精度提高了 40% 以上,以较低的成本有效提升了智能车在城市峡谷中的定位精度。

参考文献

- [1] 朱东琴, 王红茹, 岳敬轩. 基于 EM 估计的多模型车载组合导航算法[J]. 仪器仪表学报, 2022, 43(7): 239-246.
- ZHU D Q, WANG H R, YUE J X. A multi-model vehicle integrated navigation algorithm based on EM estimation[J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 239-246.
- [2] ALTUNTAS C, TUNALIOGLU N. Enhancing snow depth estimations through iterative satellite elevation range selection in GNSS-IR to account for terrain Variation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61:1-9.
- [3] PESONEN H. A framework for bayesian receiver autonomous integrity monitoring in urban navigation[J]. Navigation. 2011, 58(3), 229-240.
- [4] 兰晓伟, 许承东, 赵靖. 基于 FGO 的 GNSS/INS 组合导航完好性监测算法[J]. 计算机仿真, 2023, 40(9): 7-12.
- LAN X W, XU CH D, ZHAO J. Integrity monitoring for GNSS/INS integration based on factor graph optimization[J]. Computer Simulation, 2023, 40(9): 7-12.
- [5] ZHU N, MARAIS J, BETAILLE D, et al. GNSS position integrity in urban environments: A review of literature[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(9): 2762-2778.
- [6] XIN S, GENG J, ZHANG G, et al. 3D mapping-aided PPP-RTK aiming at deep urban canyons[J]. Journal of Geodesy, 2022.
- [7] NG H, HSU L, FENG J, et al. Real-Time loosely coupled 3DMA GNSS/Doppler measurements integration using a graph optimization and its performance assessments in urban canyons of New York[J]. Sensors, 2022, 22(17):6533.
- [8] NG H, ZHANG G H, HSU L. Robust GNSS shadow matching for smartphones in urban canyons[J]. IEEE Sensors Journal, 2021, 21(16):18307-18317.
- [9] LI L, WEN C, DENG P C. Research on shadow matching algorithm based on error ellipse [C]. IEEE International Conference on Computer and Communication Systems (ICCCS), 2021, 6: 363-368.
- [10] MEGURO J, MURATA T, TAKIGUCHI T, et al. GPS multipath mitigation for urban area using omnidirectional infrared camera [J]. IEEE Transactions on Intelligent Transportation Systems, 2009, 10(1):22-30.
- [11] WEN W, BAI X, KAN Y C. et al. Tightly coupled GNSS/INS integration via factor graph and aided by fish-eye camera [J]. IEEE Transactions on Vehicular Technology, 2019, 68(11):10651-10662.
- [12] WEN W, HSU L. 3D LiDAR aided GNSS NLOS mitigation in urban canyons[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 18224-18236.
- [13] SUN R, HSU L, XUE D, et al. GPS signal reception classification using adaptive Neuro-Fuzzy inference system[J]. The Journal of Navigation, 2019, 72(3): 685-701.
- [14] XU H, ANGRISANO A, GAGLIONE S, et al. Machine learning based LOS/NLOS classifier and robust estimator for GNSS shadow matching [J]. Satellite Navigation, 2020.
- [15] GAO W, LI Z, CHEN Q, et al. Modelling and prediction of GNSS time series using GBDT, LSTM and SVM machine learning approaches [J]. Journal of Geodesy, 2022, 96: 71.
- [16] SUN R, DAI Y, CHENG Q. An adaptive weighting strategy for multisensor integrated navigation in urban areas [J]. IEEE Internet of Things Journal, 2023, 10(14): 12777-12786.
- [17] 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 Instrument, 2023, 37(5): 171-179.
- [18] 张福斌, 王凯, 廖伟飞, 等. 激光雷达/MEMS IMU/里程计紧组合导航算法[J]. 仪器仪表学报, 2022, 43(7): 139-148.
- ZHANG F B, WANG K, LIAO W F, et al. Lidar/MEMS IMU/Odometer integrated tightly navigation algorithm[J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 139-148.
- [19] 朱建良, 王栋, 徐旋孜. 一种基于图优化的行人协同定位方法[J]. 仪器仪表学报, 2023, (6): 126-134.
- ZHU J L, WANG D, XU X Z. A pedestrian cooperative

- localization method based on graph optimization [J]. Chinese Journal of Scientific Instrument, 2023, (6): 126-134.
- [20] CAO S, LU X, SHEN S. GVINS: Tightly coupled GNSS-visual-inertial fusion for smooth and consistent state estimation [J]. IEEE Transactions on Robotics, 2022, 38(4): 2004-2021.
- [21] WEN W, PFEIFER T, BAI X, et al. Comparison of extended kalman filter and factor graph optimization for GNSS/INS integrated navigation system [J]. ArXiv, 2020, DOI:10.48550/arXiv.2004.10572.
- [22] 胡悦, 李旭, 徐启敏, 等. 卫星拒止环境下基于因子图的智能车可靠定位方法[J]. 仪器仪表学报, 2021, 42(11): 79-86.
- HU Y, LI X, XU Q M, et al. Reliable positioning method of intelligent vehicles based on factor graph in GNSS-denied environment [J]. Journal of Scientific Instrument, 2021, 42(11): 79-86.
- [23] KANNALA J, BRANDT S S. A generic camera model and calibration method for conventional, wide-angle, and fish-eye lenses [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(8):1335-1340.
- [24] FORSTER C, CARLONE L, DELLAERT L, et al. On-manifold preintegration for real-time visual-inertial odometry [J]. IEEE Transactions on Robotics, 2017, 33(1): 1-21.
- [25] CHI C, ZHANG X, LIU J H, et al. GICI-LIB: A GNSS/INS/Camera integrated navigation library [J]. IEEE Robotics and Automation Letters, 2023, 8: 7970-7977.
- [26] SCARAMUZZA D, MARTINELLI A, SIEGWART R. A toolbox for easily calibrating omnidirectional cameras[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2006: 5695-5701.

作者简介



田哲铭, 2021年于东南大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为车辆多传感融合定位。

E-mail: 220213631@seu.edu.cn

Tian Zheming received his B.Sc. degree from Southeast University in 2021, now he is a master student in Southeast University. His main research interests include vehicle multi-sensor fusion localization.



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 from Southeast University in 2006. He is currently a professor in the School of Instrument Science and Engineering at Southeast University. His main research interests include vehicle navigation and localization, environment perception and autonomous control.