

# 基于烟花算法的分布式车辆神经网络协同定位方法

余泰铮, 廉保旺, 唐成凯, 丹泽升, 刘洋洋  
(西北工业大学 西安 710000)

**摘要:** 在车联网自动驾驶中, 车辆的定位精度是平稳运行的关键。但是以卫星导航、惯性导航为代表的单一导航系统都无法全面保证车辆持续高精度定位, 所以通过车辆之间的信息协同实现高精度定位成为主要手段。本文提出了一种基于神经网络的大规模车辆协同定位方法, 该方法针对车辆在行驶中自由聚散的特性, 首先引入主成分分析法对导航信息进行处理, 降低计算复杂度, 其次通过烟花神经网络方法对车联网中的导航信息进行快速融合, 保证车辆运行中定位的精度和稳定性。将本文的方法与现有的协同定位方法进行对比, 实验结果表明: 本文所提出的方法具有更快的收敛速度和定位稳定度。

**关键词:** 车联网; 异构信息融合; 神经网络; 协同定位; 烟花算法; 主成分分析; 分布式计算; 定位精度

中图分类号: U495; TP18

文献标志码: A

文章编号: 2095-1000(2025)05-0045-14

DOI: 10.12347/j.ycyk.20250811001

CSTR: 32406.14.ycyk.20250811001

引用格式: 余泰铮, 廉保旺, 唐成凯, 等. 基于烟花算法的分布式车辆神经网络协同定位方法[J]. 遥测遥控, 2025, 46(5): 45-58.

## Distributed Vehicle Neural Network Cooperative Positioning Method with Fireworks Algorithm

YU Taizheng, LIAN Baowang, TANG Chengkai, DAN Zesheng, LIU Yangyang  
(Northwestern Polytechnical University, Xi'an 710000, China)

**Abstract:** In autonomous driving within the Internet of Vehicles (IoV), positioning accuracy is key to stable operation. However, standalone navigation systems such as satellite navigation and inertial navigation cannot fully ensure continuous high-precision positioning. Therefore, achieving high-precision positioning through information collaboration between vehicles has become the main approach. This paper proposes a neural network-based large-scale cooperative vehicle positioning method. Aiming at the characteristic of vehicles freely gathering and dispersing during driving, principal component analysis is introduced to process navigation information and reduce computational complexity. Furthermore, the Fireworks Neural Network method is used to rapidly fuse navigation information in the IoV, ensuring positioning accuracy and stability during vehicle operation. Compared with existing cooperative positioning methods, experimental results show that the proposed method has faster convergence and better positioning stability.

**Keywords:** Internet of Vehicles (IoV); Ieterogeneous information fusion; Neural network; Cooperative positioning; Fireworks algorithm; Principal component analysis; Distributed computing; Positioning accuracy

**Citation:** YU Taizheng, LIAN Baowang, TANG Chengkai, et al. Distributed Vehicle Neural Network Cooperative Positioning Method with Fireworks Algorithm[J]. Journal of Telemetry, Tracking and Command, 2025, 46(5): 45-58.

## 0 引言

随着物联网(IoT)技术的快速发展, 作为其关键应用之一的车联网也得到了蓬勃发展。智能导航、自动驾驶、自适应避障等智能技术广泛应用

于车辆, 而导航与定位则是现代车辆智能技术的核心基础之一<sup>[1,2]</sup>。在车辆导航与定位的早期阶段, 系统主要依赖以 GPS(全球定位系统)为代表的卫星导航和车辆自身的惯性导航。然而, 在动态环境下, 卫星导航系统受信号传播过程中的钟差、星

历误差及大气延迟等多因素影响, 单点定位精度通常仅为米级; 且在城市峡谷、隧道等复杂场景中, 易发生信号遮挡与多路径效应, 导致定位性能下降甚至中断。尽管在开阔环境下卫星导航等技术可实现厘米级静态精度, 但车辆在连续运行中仍难以稳定维持高精度动态定位。此外, 惯性导航系统虽可自主提供高频运动信息, 但其误差会随时间累积, 无法长期独立提供可靠定位。因此, 本文基于多传感器融合框架, 融合卫星导航与惯性导航等数据, 通过互补特性提升整体定位系统的精度与鲁棒性。

为了满足车辆导航与定位的需求, 现代车辆配备了多种导航与定位手段, 如红外导航、视觉导航系统等。但这些方法易受天气能见度等外部条件影响, 难以作为独立、可靠的导航信息源。在现代车辆的运行过程中, 超过 90% 的事故为轻微碰撞, 因此, 与绝对定位相比, 车辆之间的相对导航与定位显得更加重要。精确、可靠的车辆定位有助于显著提升安全性与运行效率, 从而有效减少轻微碰撞的发生。

随着车联网的快速发展, 众多学者针对车车导航与定位问题开展了协同定位方法的研究<sup>[3,4]</sup>。该类方法使车辆能够直接进行通信, 实时共享位置信息、速度、方向等, 建立起一个互联的车辆系统。协同定位方法主要包括基于融合算法的集中式定位方法和基于分布式系统架构的协同定位方法。前者如经典的滤波算法(如卡尔曼滤波器)<sup>[5-7]</sup>, 主要通过多源信息融合实现高精度定位; 后者则侧重于车辆之间的分布式信息交互与协同处理, 以增强系统的鲁棒性和实时性。例如, 文献[8]提出了一种面向凹形网络的分布式自适应跳距选择协同定位模型(DCP-AHS), 在复杂网络拓扑中展现了优异的定位性能; 文献[9]提出了一种基于流形梯度的协同定位算法, 有效提升了分布式系统中协同定位的精度和收敛速度。在物联网环境下, 这些协同定位方法融合了传感器网络、无线通信与分布式计算等技术, 使得车辆能够实时共享位置信息、环境数据与交通状况, 从而提升定位精度与可靠性。文献[10]提出了一种基于联邦学习的车辆协同定位方案(FedVCP), 在社会化车联网环境中提升定位精度的同时保护了隐私。文献[11]开发了一种基于深度学习的室内车辆定位方法(DeepVIP), 通过智能手机传感器数据建模的, 实现了高精度

的室内定位服务。文献[12]研究了一种基于深度学习的到达方向估计算法, 通过处理非相干分布源信号实现了高精度车辆定位。此外, 文献[13]提出了一种多传感器融合的全局位姿图优化策略, 通过整合多种传感器的数据实现了高可靠、高精度的智能车辆定位。这些研究为车联网环境中的高效与鲁棒定位提供了新思路, 推动了智能交通的发展。

基于融合的定位方法主要依赖车辆自身搭载的 GPS、惯性导航系统等信息源的集成, 几乎不与车联网中其他车辆的定位信息交互。而早期的协同定位方法多采用集中式方案, 如最小二乘法<sup>[14]</sup>, 这类方法依赖于固定结构的车联网, 限制了其实用价值。为适应车联网中车辆频繁加入与离开的动态特性, 许多学者提出了基于因子图的协同定位方法<sup>[15,16]</sup>。利用因子图的和积算法, 使车辆能够自由地进入或退出车联网。然而, 一旦某车辆的导航信息出现突发误差, 便会对整个网络的定位性能造成影响。这充分体现了基于滤波器与因子图的传统协同定位方法在处理非线性关系及复杂动态环境中的高维数据方面的局限性, 而神经网络则在特征提取与非线性映射方面具有天然优势。

为此, 众多研究者将神经网络引入协同定位研究中<sup>[17,18]</sup>。然而, 目前的神经网络协同定位方法主要通过训练获得高精度定位结果, 忽略了车辆聚散变化的动态特性; 同时, 神经网络计算开销较大, 导致其实时定位性能较差。

为了解决上述问题, 本文提出了一种基于烟花算法(FWA)的分布式车辆神经网络协同定位方法, 其主要创新点如下:

① 提出了一种基于主成分分析(PCA)的导航信息过滤方法, 有效避免了导航突发误差对整体定位网络的影响;

② 提出了一种基于烟花算法的神经网络协同定位方法, 有效解决了传统神经网络协同定位中结果不佳的问题;

③ 搭建了车辆协同定位测试平台, 并在普通道路、高架桥等场景中验证了本文方法。当部分车辆导航信息突发异常时, 该方法表现出更高的稳定性和更快的收敛速度。

本文的结构如下: 第 1 节回顾相关车辆协同技术的发展, 分析现有方法的优缺点; 第 2 节介绍系

统模型；第3节详细阐述了基于烟花算法的分布式车辆神经网络协同定位方法；第4节对本文方法进行实验验证；第5节总结全文内容。

## 1 相关车辆协同技术

在现代导航与定位系统的发展中，协同定位技术因其在提升系统鲁棒性和定位精度方面的能力而受到广泛关注。协同定位通过多个节点之间的协作，利用共享的位置信息来提高单个节点的定位精度，这在多传感器融合与多车导航中尤为重要。例如，文献[19]探讨了在低轨卫星导航系统中采用多普勒辅助协同定位的方法，通过融合多源数据，显著提升了系统在复杂环境下的性能。类似地，文献[20]研究了多车辆协同导航，在该方法中，车辆间共享位置信息，以提升整体导航系统的精度与鲁棒性。

此外，针对在噪声环境下目标跟踪的技术挑战，文献[21]提出了一种鲁棒自适应立方卡尔曼滤波器，通过无线传感器网络实现目标跟踪，在多目标协同定位中表现良好。在工业物联网(IoT)环境中，文献[22]研究了一种基于超宽带(UWB)技术的室内定位系统，并提出了一种适用于复杂工业环境的协同定位算法。该算法通过多个节点的协作实现高精度的室内定位。

然而，受限于卫星导航和惯性导航定位系统的精度与固有误差，单一导航源无法满足自动驾驶车辆的需求。随着6G互联网的快速发展，车联网(IoV)逐渐成为汽车的信息交互终端，并在自动驾驶等领域展现出广阔的应用前景。通过与其他车辆和道路基础设施的协同通信，自动驾驶车辆能够更准确地感知周围环境，实现更高级别的自动驾驶功能，从而大大提升道路交通效率和安全性。因此，如何利用车联网中车辆间的互测与定位信息实现协同定位，以提高导航定位精度，已成为高精度车辆导航的重要研究方向。

早期的车辆定位方法主要依赖于单一传感器，如全球导航卫星系统(GNSS)<sup>[23]</sup>、惯性导航系统(INS)和视觉导航。然而，这些方法在城市峡谷等复杂环境中易受信号遮挡、多径效应以及雨雾等恶劣天气条件的影响，导致较大的定位误差。为克服这些问题，学者们通过集中融合方式集成多种导航源信息，以实现更高的定位精度<sup>[24,25]</sup>。这些方法主要包括两类：一类是以最小二乘法(LS)为代

表的直接融合方法，另一类是以卡尔曼滤波(KF)为代表的滤波融合方法。

LS通过最小化误差平方和来确定模型参数，从而最小化模型预测值与实际观测值之间的差异。为适应不规则网络环境，文献[26]提出了一种改进的距离矢量跳数算法。该算法利用最优权重函数确定未知节点与锚节点之间的跳数，并使用LS计算未知节点坐标，实验结果验证了该算法在降低定位误差方面的有效性。然而，传统的LS难以处理具有不同权重的数据。为了解决这一问题，文献[27]引入了一种改进的自适应麻雀搜索算法(IASSA)，通过引入两步加权最小二乘法、搜索边界自适应调整及发现加入模型数量自适应调整三种策略。实验结果表明：该算法在室内定位精度与鲁棒性方面具有优势。然而，最小二乘法仅适用于线性模型，对非线性关系数据解释能力有限，且对初值敏感，不同初值可能导致不同的最优解，因此需要引入其他方法加以改进。

KF本质上是小二乘估计算法的一种递归形式。由于KF只能应用于线性高斯系统，学者们在非线性条件下对其进行了改进，提出了基于泰勒展开的扩展卡尔曼滤波器(EKF)、基于无迹变换的无迹卡尔曼滤波器(UKF)以及最大相关熵准则鲁棒平方根立方卡尔曼滤波器(MCSCKF)<sup>[28,29]</sup>。文献[20]研究了协同定位在提升多车自主导航性能中的作用，提出了二维和三维车辆动力学模型及其线性化方法，并基于该模型设计了非线性控制算法与相对位置测量方程，利用EKF进行协同定位算法的传播与更新，实验验证了其在不同测量条件下的有效性。为更好地将精确位置识别系统应用于各类汽车技术领域，文献[30]提出了一种基于低成本独立GPS与惯性测量单元(IMU)传感器融合的新型车辆位置估计算法。为使用这两种互补传感器准确估计车辆位置信息，采用了自适应无迹卡尔曼滤波器(AUKF)作为最优状态估计算法，通过与常见的EKF和UKF算法的估计误差对比验证了其有效性。针对测量噪声污染严重时对滤波性能影响较大的问题，文献[31]提出了一种基于最大相关熵准则的MCSCKF车辆协同定位方法，实验验证了该方法在提升相对位置估计精度和鲁棒性方面的效果。对于传感器性能较差、种类繁多的商用机器人，文献[32]提出了一种低成本鲁棒的多传感器数据融合方案，融合了IMU与激光测距仪数据，并

结合离散卡尔曼滤波(DKF)与EKF提升状态估计精度,同时引入YOLO算法处理视觉数据。实验结果表明:该方案可满足自主移动机器人高效协同运动的定位需求。然而,随着导航源数量的增加,观测矩阵迅速扩展,当融合两个以上导航源时,卡尔曼滤波器计算复杂度高、通信开销大,难以满足实时高精度定位需求。此外,卡尔曼滤波器结构固定,难以适应导航源的即插即用特性,算法复杂度普遍较高,不利于多车间数据交互的实现。

为克服卡尔曼滤波等传统集中式融合定位技术的缺陷,分布式融合定位方法应运而生。分布式定位主要包括以因子图为代表的概率融合技术和以神经网络为代表的智能融合技术。因子图是一种信息概率传输模型。文献[33]提出了一种基于因子图的室内移动机器人多传感器融合定位方法。实验结果表明:相较于传统惯性导航系统(INS)和扩展卡尔曼滤波(EKF)算法,该方法显著降低了平均定位误差和计算复杂度,增强了系统稳定性。文献[34]提出了一种基于因子图的无人水下航行器(UUV)集群协同定位方法,结果显示该方法具有更高的定位精度、更快的收敛速度和良好的突变误差抑制能力。针对GNSS信号复杂环境,文献[35]提出了一种基于因子图优化的半紧耦合传感器融合系统,结果表明该系统在定位精度方面优于GNSS策略和常规SLAM(同步定位与地图构建)策略,且具有较高的可靠性。尽管基于因子图的多源融合算法可解决导航源即插即用问题,但其在求解过程中存在大量冗余计算,随时间推移数据量不断增加,导致计算复杂度高,突变误差抑制效果不佳。此外,由于因子图模型难以在多个应用场景中平滑迁移,因此当进入新场景或添加新导航源时需重新配置。

为在保证精度的同时降低定位成本,许多学者对该领域进行了探索。文献[36]对三种不同的神经网络模型用于室内定位进行了对比:一种基于改进BP(反向传播)神经网络模型的室内定位算法、一种基于神经网络角度变化的RSSI(接收信号强度指示)室内定位算法,以及一种基于深度神经网络角度变化的RSSI室内定位算法,旨在提高室内定位坐标的精度。文献[37]将长短期记忆网络(LSTM)与消息传递神经网络(MPNN)结合用于协同定位,实验结果验证了其良好的定位性能。文献

[38]采用LSTM神经网络结合UWB(超宽带)定位系统对低速与高速运动物体的位置进行预测,最终结果显示位置估计误差在0.1 m以内。文献[39]提出了一种协同定位中的车辆排序与选择方法,旨在充分利用低成本GNSS接收器的潜力,在安全关键车辆应用中发挥其最大效益。该方法基于多属性决策(MADM)理论,使用与位置精度和可靠性相关的指标对目标车辆周围的邻近车辆进行排序,通过选择最佳邻车参与协同定位,使目标车辆的低成本接收器增强其位置感知能力,从而提升绝对/相对定位精度。

由于计算任务繁重、数据模型复杂度高以及对非线性/非高斯系统适应性差,传统融合算法难以满足实时高精度位置预测的要求,这促使了基于神经网络的融合算法的出现。神经网络无需建立精确的数学模型,其计算结果完全依赖于输入的样本数据,因此能够有效处理难以建模的非线性系统与数据关系。然而,当训练样本不足或初值选择不合理时,容易出现陷入局部最优甚至无法收敛的问题,因此有必要引入其他算法进行优化,这也是本研究的重点。

综上所述,众多学者围绕多源融合算法展开了分析与研究,通过整合不同类型的传感器,弥补了单一传感器应用的局限性,满足了多场景导航的需求。但现有的信息融合算法仍不可避免地存在模型泛化能力差、计算负担重以及连续性要求难以满足的问题。面对异构导航源参数或导航源数量众多的情况,实时性无法得到保障,且难以很好地适应导航源输出参数的异构性与即插即用特性。

## 2 车辆多源融合模型

车辆的自由聚散特性需要能够快速定位,而在分布式协同定位中,每个用户所接收到的定位信息呈现数量大、方向繁多的特性。因此如何通过庞大的定位信息,快速实现高精度高可靠的位置服务,是车辆互联网应用的重要研究方向。为了得到更好的定位结果,本文提出基于烟花算法的分布式车辆神经网络协同定位方法。本文所研究的分布式协同定位示意如图1所示。

在图1中,黄色链路是车辆之间的通信链路,其与非协同定位之间的区别主要是协同定位中每辆车之间也会传递信息。




图1 协同定位示意

Fig. 1 Cooperative positioning

为了实现快速高精度高可靠的位置服务, 本文将主成分分析法(Principle Component Analysis,

PCA)、烟花算法(Fireworks Algorithm, FWA)引入基于神经网络的分布式协同定位算法。首先获得定位信息, 由于所接收到的定位信息呈现数量大、方向繁多的特性, 因此, 本文通过PCA算法对获得的源信息进行处理, 获得重构后的定位信息, 此时的定位信息在保留源信息必要特征的同时, 极大地降低了算法需要处理的数据量。另一方面, 神经网络在处理数据时可能会存在收敛速度慢或者局部收敛的情况, 因此通过引入烟花算法来优化神经网络的网络参数, 以达到快速收敛并避免出现局部收敛。基于烟花算法的分布式车辆神经网络协同定位方法原理如图2所示。

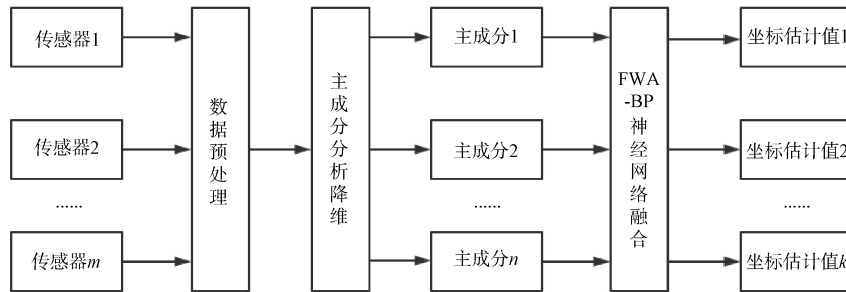


图2 基于烟花算法的分布式车辆神经网络协同定位方法(BP-CP-FWA)原理

Fig. 2 The BP-CP-FWA Principle

其中, 传感器是用来获取车辆定位信息, 数据预处理是将定位信息重构为能够用于后续主成分分析降维, 再将降维后获得的主成分进行重构输入到BP-CP-FWA中进行预测得到坐标估计值。

本文算法旨在通过多辆车来进行协同定位, 以多数车辆与待定位车辆进行信息解算获得的待定位车辆位置信息为输入, 待定位车辆位置信息为输出。当训练集为测试集时, 待定位车辆每个时刻的位置信息已知, 以此来训练神经网络。本文为了使神经网络能够更好地发挥性能, 采用以下网络拓扑结构:

① 输入维度: 输入层的神经元数等于输入数据的维度。本文的输入数据维度为  $m$ ,  $m$  为与待定位车辆进行数据交互的车辆数量。

② 隐藏层: 一般情况下, 单隐藏层即可逼近大多数连续函数, 但对于复杂的定位问题, 单一隐藏层并不适合, 因此为了更好地使神经网络适用于协同定位, 本文采用多隐藏层设计, 隐藏层的计算采用通用经验公式

$$n = \sqrt{m+p} + d \quad (1)$$

式中,  $n$  为隐含层节点数,  $m$  为输入层节点数,  $p$  为输出层节点数,  $d$  为调节常数, 通常调节该常数得到不同的隐含层节点数。

③ 输出层: 本文中输出层的神经元数等于定位问题的目标维度。本文的目标维度是待定位车辆的空间坐标即三维坐标, 因此输出层节点数  $p$  设定为 3。

④ 激活函数: 传递函数(激活函数)决定了神经网络对非线性关系的建模能力和训练的效果。不同层的激活函数选择会对定位精度和收敛速度产生重要影响。由于定位数据属于非线性数据, 为了更好地处理这些数据, 因此选用 Sigmoid(S型函数)来作为激活函数。

### 3 BP-CP-FWA 算法

BP神经网络是一种常见的人工神经网络, 用于机器学习和深度学习任务。它是一种监督学习算法, 广泛应用于分类、回归和模式识别等任务。BP神经网络的典型架构由三部分组成: 输入层, 隐含层和输出层, 其中隐含层可以包含多层。典

型的单隐含层 BP 神经网络结构如图 3 所示。




图 3 BP 神经网络结构

Fig. 3 Structure of the BP neural network

BP 神经网络的训练学习过程主要分为正向传递计算过程和误差反向传播计算过程。正向传递计算过程即为：输入数据通过网络，逐层计算每个神经元的输出。每个神经元的输出通过激活函数进行非线性变换，增强网络的表达能力。前向传播产生最终的预测结果。误差反向传播计算过程为 BP 神经网络训练的核心。通过计算预测结果与实际标签之间的误差，然后将误差从输出层反向传播回网络，调整每个连接的权重和每个神经元的偏置，以减小整体误差。最后通过计算误差关于参数的梯度，然后更新参数以降低误差。这一过程在整个数据集上迭代多次，直至网络收敛到满意的性能。具体算法流程如下：

#### ① 正向传递计算过程

由图 3 可知， $x_1, x_2, \dots, x_p$  为网络的输入值，输入层神经元个数为  $p$ ；隐含层神经元个数为  $h$ ； $y_1, y_2, \dots, y_o$  为网络的输出值，输出层神经元个数为  $o$ ； $w_{ph}$  为输入层与隐含层的链接权值， $w_{ho}$  为隐含层与输出层的连接权值。

由输入层至隐含层的输入为：

$$u_i = \sum_{j=1}^p x_j w_{ij}, j=1, 2, 3, \dots, h \quad (2)$$

隐含层输出为：

$$H_j = f_1(u_j + b_1) \quad (3)$$

式中， $f_1$  为隐含层激活函数， $b_1$  为隐含层的阈值。

由隐含层至输出层的输入为：

$$v_m = \sum_{j=1}^h H_j w_{jm}, m=1, 2, 3, \dots, o \quad (4)$$

输出层输出为：

$$y_m = f_2(H_j + b_2) \quad (5)$$

#### ② 误差反向传播计算过程

网络的期望输出为：

$$\dot{Y} = \dot{y}_1, \dot{y}_2, \dots, \dot{y}_o \quad (6)$$

网络的总误差为：

$$E = \frac{1}{2} \sum_{m=1}^o (y_m - \dot{y}_m)^2 \quad (7)$$

式中， $E$  被定义为误差函数。

### 3.1 主成分分析法

主成分分析法可以从高维中提取特征信息，减少维度的同时还能最大程度保留原高维数据中的信息，是一种被广泛使用的数据处理方法。该方法的核心思想是寻找数据空间中的若干个方向，使得所有数据投影在这些方向上的信息量最大，其中在这些投影方向上的信息量通过方差来衡量，同时它还可以通过数据降维。PCA 具体降维步骤如下：

对任意一个定位用户进行第  $k$  次定位，所接收到的  $m$  个周围导航用户的当前时刻的前  $n$  个时刻的定位数据，组成该用户的定位样本矩阵  $\mathbf{X}$ ，进行如下变换，得到标准化矩阵  $\mathbf{U}$ ：

$$u_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, i=1, 2, \dots, n, j=1, 2, \dots, m \quad (8)$$

式中， $x_{ij}$  表示定位样本矩阵  $\mathbf{X}$  中第  $i$  行  $j$  列的定位数据， $\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}$ ， $s_j = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}$ ， $u_{ij}$  表示定位样本矩阵  $\mathbf{U}$  中第  $i$  行  $j$  列的数据。

对标准化矩阵  $\mathbf{U}$  求相关系数矩阵  $\mathbf{R}$ ：

$$\mathbf{R} = \frac{\mathbf{U}^T \mathbf{U}}{n-1} \quad (9)$$

求解相关系数矩阵  $\mathbf{R}$  的特征方程：

$$|\mathbf{R} - \lambda \mathbf{E}_m| = 0 \quad (10)$$

通过式(10)求解该方程得到  $m$  个特征值。

将特征值降序排列，取前  $p$  个特征值对应的特征向量组成变换矩阵  $\mathbf{A}^T$ ：

$$\mathbf{A}^T = (u_1, u_2, \dots, u_p), p < m \quad (11)$$

计算  $\mathbf{Y} = \mathbf{A}\mathbf{X}$ ，计算各个主成分的得分，实现降维的目的。

对于不同传感器最终解算的位置信息，其最终结果为车辆绝对位置信息以及不同传感器各自独有的噪声，而 PCA 则是将从不同传感器得到的位置信息进行降维，提取贡献率最大的分量即真实位置信息，因为不同传感器不同时刻产生的噪声差别相对于车辆前进的位置变化方差较小，能被 PCA 初步处理。以此为依据，设定主成分提取门限即总贡献率，当总贡献率大于 95% 或 99% 时，

提取出相应的成分,作为重构后的数据。然后将重构后的一部分数据作为神经网络的训练数据,一部分作为神经网络的测试数据。

由于本文在神经网络中引入了烟花算法,而烟花算法搜索最优值的过程使得算法的最终复杂度上升,因此引入主成分分析法,来降低算法的复杂度。PCA降维后,输入数据的维度从 $n$ 降到 $k$ ,直接减少了烟花算法的搜索空间维度,这主要体现在爆炸过程和随机火花两个方面,降维后火花生成的位置在低维空间中分布,减少每次搜索的计算量以及随机火花的数量,搜索范围也会随维度降低而减小。

烟花算法的时间复杂度 $O_{FWA}$ 主要与维度 $n$ 和每次搜索的迭代次数 $T$ 相关:

$$O_{FWA} \approx O(T \cdot N \cdot n) \quad (12)$$

其中, $N$ 为每次爆炸的火花数量,降维后 $n$ 减小,复杂度显著降低。

对神经网络PCA降维,减少了输入特征的维度 $n$ ,从而优化神经网络的结构:输入层神经元数量减少,参数个数显著降低。隐藏层的神经元数量通常与输入层相关,参数量进一步减少。神经网络的时间复杂度可以近似表示为:

$$O_{PCA} \approx O\left(\sum_{i=1}^{L-1} n_i \cdot n_{i+1}\right) \quad (13)$$

其中 $n_i$ 是第 $i$ 层的神经元数量, $L$ 是网络的层数。PCA降维后,输入层和随后的隐藏层的神经元数量减少,显著降低网络的训练和推理复杂度。

当车辆过多以及面对复杂环境时,难免会出现异常数据,因此本文对异常数据的阈值进行定义并进行筛选。

① 首先通过公式(11)获得主成分空间投影 $Y$ ,然后通过公式(14)对原始数据进行重建

$$Y_{\text{recon}} = Y \cdot A^T \quad (14)$$

② 计算残差,残差 $E$ 代表数据点在非主成分方向上的偏离

$$E = X - Y_{\text{recon}} \quad (15)$$

③ 计算每个数据点的残差平方和(Residual Sum of Squares, RSS):

$$S_{\text{RSS}_i} = \|E_i\|^2 \quad (16)$$

根据RSS的分布,设置异常检测阈值,选取95%或99%的数据作为正常范围数值,最后标记异常数据。

### 3.2 烟花算法

烟花算法是国内学者谭营等人提出的新型群体智能优化算法。在该算法中,烟花爆炸产生的每个火花被抽象为目标问题在解空间内的一个解决方案,烟花不断爆炸的过程可以抽象为不断寻求最优解的过程。由于FWA相比于其他算法具有搜索范围广、算法简单的特点,因此该算法在优化问题求解上表现出较优的性能,得到了国内外学者们的关注。

在定位问题中,目标函数通常是基于测量误差的最小化。由于实际环境中的多路径效应、噪声、遮挡等复杂情况,这些误差往往会形成非凸函数,导致在定位问题的搜索空间中,会存在多个“误差最小”的点(局部最优),而全局最优通常较难到达。因此本文引入烟花算法来解决这一问题,其具体优化过程为:烟花算法生成多组初始权重,每组权重相当于一个烟花。这样多样化的初始解能覆盖更广的搜索空间,减少网络因不良初始化陷入局部最优。然后通过动态调整爆炸半径使得网络权重在早期阶段有较大的变化,避免陷入局部最优,考虑到过大的爆炸半径会影响结果的精度,因此在后期,烟花算法通过减小爆炸半径进行精细优化,逐步逼近全局最优,以此来优化神经网络,其具体优化过程如下:

FWA首先确定初始烟花的数量 $N$ 以及每个烟花的维度 $n$ ,并设置烟花每个维度的上限和下限,在维度范围内随机产生 $N$ 个初始烟花,再根据映射规则和选择策略执行爆炸操作和高斯变异操作。

#### ① 爆炸操作

每个烟花爆炸产生的火花都随机均匀分布在烟花周围,其中产生的数量和范围主要由爆炸半径和爆炸火花数决定,其定义如下:

$$A_i = E_r \cdot \frac{f(x_i) - y_{\min} + \varepsilon}{\sum_{i=1}^N (f(x_i) - y_{\min}) + \varepsilon} \quad (17)$$

$$S_i = E_n \cdot \frac{y_{\max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (y_{\max} - f(x_i)) + \varepsilon} \quad (18)$$

式中, $f(x_i)$ 用来计算每个烟花的适应度,设置 $y_{\max}$ 和 $y_{\min}$ 分别为最差和最优值; $E_r$ 为控制产生火花范围参数; $E_n$ 为控制产生火花数量的参数; $\varepsilon$ 是一个非常小的实数,用于避免出现公式无意义的情况。

根据计算得到的爆炸个数和爆炸范围,对每个烟花 $x_i$ 进行爆炸操作。每个烟花 $x_i$ 随机确定要偏

移的维度数目  $D_{\text{select}} = \text{rand}(D)$ , 通过偏移产生爆炸火花  $x_{i,c}$ :

$$x_{i,c} = x_{ik} + h \quad (19)$$

式中,  $x_{ik}$  为第  $i$  个烟花的被选中要偏移的维度  $k$ ,  $x_{i,c}$  为第  $i$  个烟花爆炸后产生的爆炸火花,  $h$  为爆炸半径  $A_i$  内生成的随机数:

$$h = A_i \cdot \text{rand}(-1, 1) \quad (20)$$

### ② 高斯变异

FWA 通过引入高斯火花增加种群多样性。首先确定高斯火花的数量  $g$ , 从初始烟花种群中随机选取  $g$  个烟花, 对其某一维度  $k$  乘上符合高斯分布的随机数  $e$ :

$$\dot{x}_{i,k} = x_{i,k} \cdot e \quad (21)$$

式中,  $e$  为符合高斯分布的随机数,  $e \sim N(1, 1)$ ,  $N(1, 1)$  为高斯分布。

### ③ 终止判断

对每一代的烟花种群计算适应度值, 若最优适应度满足要求或达到最大迭代次数, 则判定烟花寻优结束, 否则跳转步骤②。

### ④ 映射规则

由于爆炸火花以及高斯火花的产生都是通过随机选取维度并施加随机量偏移, 难免会有个别爆炸火花或高斯火花维度超出边界, 因此 FWA 采用模运算映射机制, 将超出边界的烟花映射回界限以内。对于火花  $x_i$ , 若第  $k$  维度超出了边界, 则利用式(22)重新将火花  $x_i$  映射到范围内的新位置:

$$\dot{x}_{ik} = x_{\text{LB},k} + |x_{ik}| - \{|x_{ik}| / (x_{\text{UB},k} - x_{\text{LB},k})\} \cdot (x_{\text{UB},k} - x_{\text{LB},k}) \quad (22)$$

式中,  $x_{\text{UB},k}$  和  $x_{\text{LB},k}$  分别为维度  $k$  范围的上下限。

### ⑤ 参数设置

FWA 寻优开始前需要确定以下参数: 种群大小  $N$ 、烟花维度的上限和下限、爆炸火花半径调节常数  $E_r$ 、爆炸火花数调节常数  $E_n$ 、高斯火花数  $g$  以及最大迭代次数  $T$ 。其中种群大小决定了在解空间初始烟花个数, 个数越多, 对于解空间的搜索范围越大, 但是算法计算速度越慢; 爆炸半径调节常数越大, 扩大了搜寻全局最优解的范围, 但局部搜索能力变弱; 爆炸火花数调节常数越大, 则爆炸产生的火花数越多, 全局搜索能力更强, 但同样会增加算法的计算时间; 高斯火花数过少会减少烟花空间搜索的随机性, 高斯火花数过多则大大增加了算法的不确定性, 使算法失去寻优能力, 通常数量设置为种群大小  $N$  的二分之一; 迭代

次数过大会大大增加算法运算时间, 迭代次数过小会导致算法还没搜寻到全局最优点就提前收敛。以上参数的设置需要在实验中不断调整来确定。

## 3.3 模型建立

图 4 为基于烟花算法的分布式车辆神经网络协同定位模型的建立流程, 其具体步骤如下:

① 通过传感器获得定位数据, 通过  $\text{rand}$  函数分别随机生成  $x, y, z$  各 60 组数据组成样本数据, 并加入均值为 0、方差为 1 的高斯白噪声。

② 将得到的样本数据通过主成分分析法进行降维, 提取总贡献率大于 95% 的相应成分, 作为重构后的数据。

③ 创建一个 BP 神经网络, 包括确定其拓扑结构和传递函数。

④ 初始化烟花种群。FWA 优化的目标是 BP 神经网络中的所有网络参数, 因此需要将网络中所有参数编码为烟花个体的形式, 以建立烟花的维度空间与神经网络参数之间的映射。确定每个烟花的维度为  $D = n_{\text{iv}}(1, 1) + n_b(1, 1) + n_{\text{iv}}(2, 1) + n_b(2, 1)$ ; 其中  $n_{\text{iv}}(1, 1)$  为神经网络输入层与隐含层间权值的个数,  $n_b(1, 1)$  为隐含层神经元阈值的个数,  $n_{\text{iv}}(2, 1)$  为隐含层与输出层间权值的个数,  $n_b(2, 1)$  为输出层神经元阈值的个数。

⑤ 计算每个烟花的适应度函数, 此处使用的适应度函数如下:

$$f(x_i) = \frac{(\sin \sqrt{x_{i1}^2 + x_{i2}^2})^2 - 0.5}{(1 + 0.001 \times (x_{i1}^2 + x_{i2}^2))^2 - 0.5} \quad (23)$$

其中,  $x_{i1}$  对应每个行为个体的第一列,  $x_{i2}$  对应每个行为个体的第二列。

⑥ 通过烟花种群寻优, 获得最优个体, 将最优个体解码, 获得神经网络相应的参数, 算法中主要体现为神经网络的对应的权值和阈值。

⑦ 将重构后的定位数据一部分作为神经网络的训练数据, 一部分作为神经网络的测试数据输入到神经网络之中。

⑧ 当测试数据的预测输出与实际输出之间的误差满足误差要求时, 输出相应的预测数据。

## 4 车联网定位实验

在本节中进行多源信息融合实验, 在常规直线场景、无突变的曲线场景以及存在突变的曲线

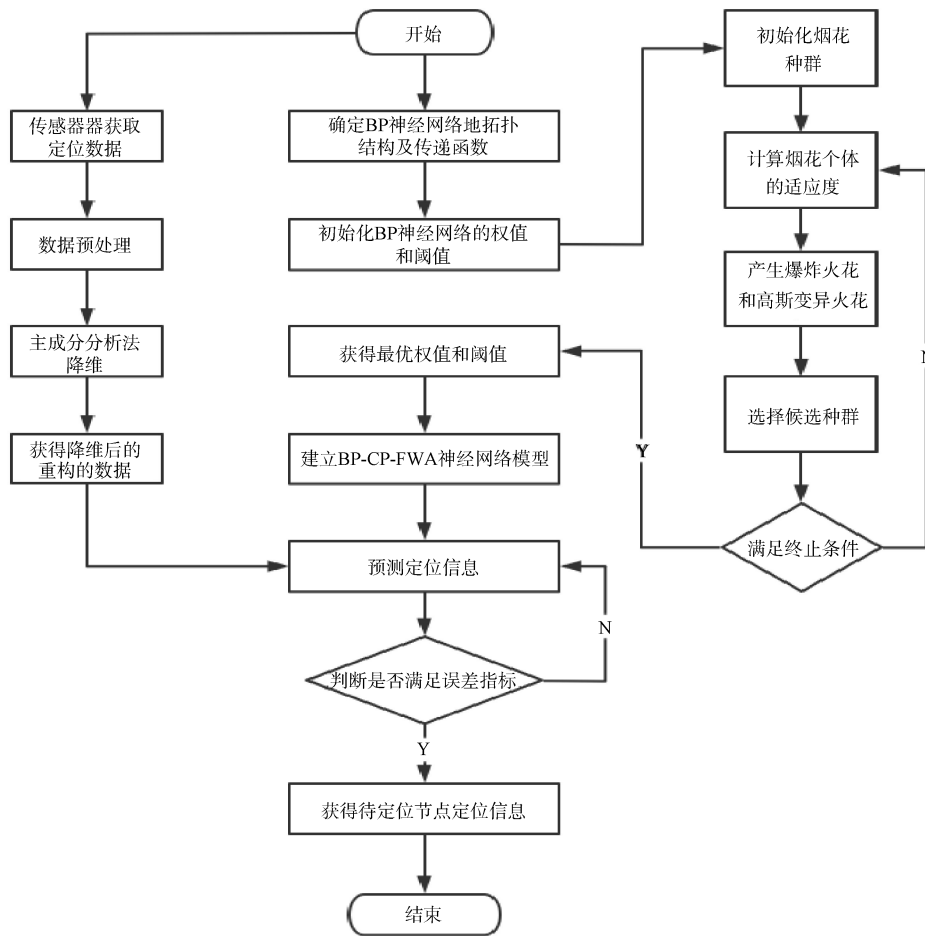


图4 基于烟花算法的分布式车辆神经网络协同定位模型的建立方法

Fig. 4 Construction method of the distributed vehicle neural network cooperative positioning model based on the FWA

场景三种情况下)验证所提出的BP-CP-FWA算法的可行性,并与文献[1]提出的最小二乘法,文献[9]提出的卡尔曼滤波方法,以及文献[10]提出的因子图方法等当前主流车辆多源融合定位方法进行性能对比。在本章中,单个车辆采用空间绝对误差来体现定位精度,最后使用平均绝对误差体现定位性能,其物理含义是欧氏空间下的绝对距离误差。

#### 4.1 仿真实验场景设置

仿真实验场景设置为互通式立交桥,其中又分为常规直线轨迹和复杂曲线轨迹,具体轨迹如图5所示。

#### 4.2 BP-CP-FWA 多源数据融合仿真实验

本节首先进行算法收敛速度的验证,然后验证在无突变误差情况下算法在常规直线场景和复杂曲线场景的可行性,最后验证算法在存在突变误差情况下,在复杂曲线场景下的可行性,并与




图5 车辆仿真场景

Fig. 5 Vehicle simulation scenario

其他方法进行对比,体现本文算法的优势。

#### 4.2.1 算法参数设置及神经网络收敛速度

本次实验中神经网络的训练次数设置为1 000次,学习速率设置为0.01,训练目标最小误差设置为0.000 000 1,输入层节点数量为59,隐含层节点数量为6,输出层节点数量为1。烟花算法参数设置为种群数量 $N=100$ ,维度 $D=367$ ,高斯变异火

花数  $M=5$ , 爆炸数目  $E_n=6$ , 爆炸半径  $E_r=5$ , 爆炸数目限制因子  $a=0.3$ ,  $b=0.6$ , 迭代次数  $T=200$ 。神经网络收敛速度如图 5 所示。

从图 6 可以看出, 神经网络具有较快的收敛速度, 损失函数值稳定在一个较低的水平, 表明网络已经学习到了数据集中的特征和规律。经过训练, 网络已经具备了较好的泛化能力, 能够对新的数据进行准确的预测和分类。与其他方法相比, 本算法具有更高的收敛速度, 能够更好地满足实际需要。

#### 4.2.2 无突变误差的多源融合仿真实验

本小节进行的是无突变误差下的神经网络多源数据融合仿真实验, 由于车辆的运行情况可能





图 6 神经网络收敛速度图


Fig. 6 Convergence speed diagram of the neural network

会对车辆的最后定位结果产生影响, 因此本节进行不同场景下车辆定位结果的仿真实验, 取直线场景下车辆数目  $N=8$ , 轨迹可视化车辆数目  $N1=8$ 。仿真轨迹结果如图 7 所示。



(a) 全局仿真图

(a) Global simulation diagram



(b) 直线场景下的局部放大轨迹图


(b) Locally enlarged trajectory diagram in the straight-line scenario

图 7 仿真轨迹结果

Fig. 7 Simulation trajectory results


图 7 中红色直线为真实轨迹, 蓝色直线神经网络预测轨迹, 在图中两者轨迹贴合较紧仿真结果与预期结果相符, 另一方面右侧图中中间区域中的变道, 两种颜色的曲线贴合也较为紧密, 说明算法能够应对现实生活中存在的变道。接下来将上述直线间的误差进行数字可视化, 其结果如图 7 所示。

从图 8(a) 可以看到: 8 辆车的仿真结果都稳定在 0.1 m~0.2 m 范围内。结合图 7, 无论是直线场景, 还是变道场景, 仿真结果均在可以接受的范围内, 算法效果良好, 说明本文的协同定位算法满足车辆定位实际需求。另一方面, 从图 8(b) 可以看到, 本文算法在当前的数据结构下能有效提高



(a) 直线场景下车辆的定位误差随时间的变化关系

(a) The positioning error of the vehicle versus time in a straight-line scenario



(b) 五种不同算法的定位精度

(b) Positioning accuracy of five different algorithms

图 8 直线场景下车辆的误差

Fig. 8 Vehicle positioning error in the straight-line scenario

定位精度，并且在五种融合定位算法中的定位精度是最好的，说明用主成分分析法处理后的数据输入到烟花算法优化的神经网络可以有效提高定

位精度。

之后取复杂场景下车辆数目 $N=8$ ，轨迹可视化车辆数目 $N1=8$ 。仿真轨迹结果如图9所示。

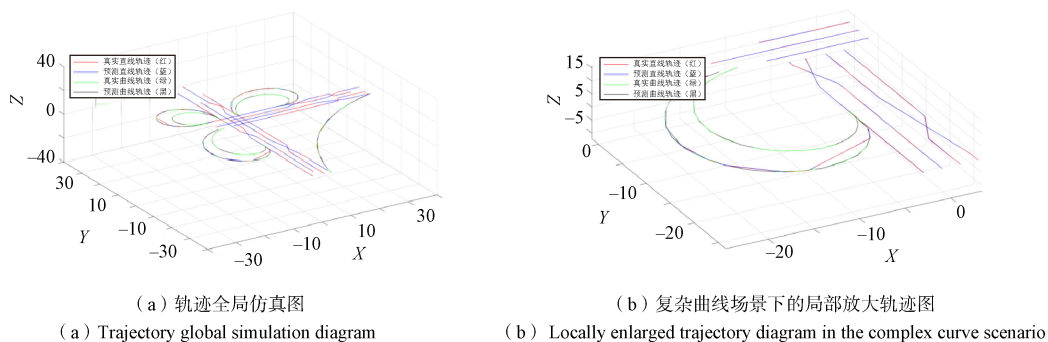


图9 仿真轨迹结果

Fig. 9 Simulation trajectory results

图9中红色曲线和绿色曲线为真实轨迹，蓝色曲线和黑色曲线为神经网络预测轨迹，在图中两者轨迹贴合较紧仿真结果与预期结果相符，说明

算法能够应对现实生活中存在的车辆进行曲线运动时的情况。接下来将上述曲线间的轨迹误差进行数字可视化，其结果如图10所示。

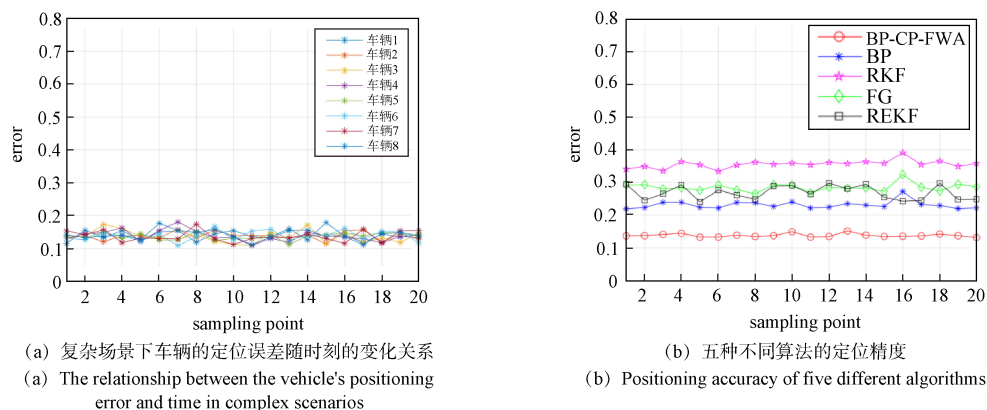


图10 复杂场景下车辆误差

Fig. 10 Vehicle positioning error in the complex scenario

从图10(a)可以看到：仿真结果同样稳定，且定位误差在0.1 m~0.2 m。结合图9，仿真结果均在可以接受的范围内，算法效果良好，说明本文的协同定位算法满足车辆定位实际需求。从图10(b)可以看到：本文算法在当前的数据结构下能有效提高定位精度，并且在五种融合定位算法中的定位精度是最好的，说明本算法能够可以有效提高曲线场景下的定位精度。

#### 4.2.3 存在突变误差的多源融合仿真实验

在实际车辆运行过程中，由于城市峡谷效应以及电磁干扰等因素，不可避免地会出现卫星信

号或无线电信号受到干扰甚至中断，因此接下来本节将进行突变情况下的多源融合仿真实验，以复杂场景中展现的8辆车为例，其中车辆在从其他车辆获取自身位置信息时产生了突变误差，突变误差产生时间设置为第3和第16个时刻，产生突变的车辆数量为10%，数值设定分别为6 m和2 m，通过添加不同大小的突变误差，来验证算法在不同幅度误差下的鲁棒性；另一方面为了验证数据丢失时算法的鲁棒性，选择第3和第16个时刻，数据丢失的车辆数量为10%，其他参数设置与无突变时一致。

为了更好地体现本文算法抗突变误差的性能, 以定位数据平均误差为指标, 存在突变误差下车辆多源数据融合定位仿真结果如图 11 所示。

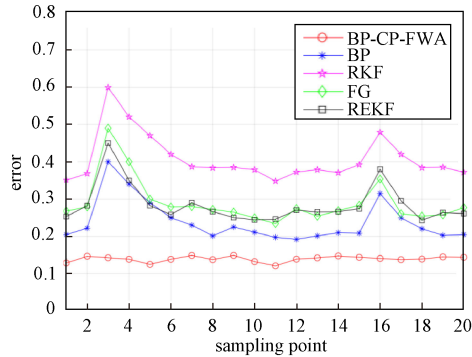


图 11 突变情况下五种方法定位误差与时间的仿真结果图

Fig. 11 Simulation results of positioning error versus time for four methods under sudden change conditions

图 11 给出了突变情况下 BP-CP-FWA、BP、RKF、FG、REKF 五种不同算法的定位精度。可以看出, 通过 PCA 将突变误差滤除后的神经网络算法的稳定性更强, 并且在五种融合定位算法中本文算法的定位精度是最好的, 在含有突变误差的情况下定位误差最高也是在 0.12 m 左右浮动, 说明将不同车辆之间传递的信息以合适的方式输入到神经网络之中, 得到的结果可以有效抑制融合过程中突变误差带来的影响, 进一步提高定位精度。同时也说明了神经网络可以有效处理非线性系统。另一方面, 结合前文所述的神经网络收敛速度, 相较于传统神经网络算法, BP-CP-FWA 算法能够实现对多源信息的快速融合, 满足车辆定位的实时性需求。

## 5 结论

针对现有车辆多源信息融合协同定位算法中存在的一些问题, 本文提出了一种基于烟花算法的分布式车辆神经网络协同定位方法。该算法首先通过烟花算法优化神经网络的网络参数, 主要为权值和阈值, 避免神经网络在训练过程中出现局部收敛或者发散的情况。然后将获取的定位数据信息进行数据预处理, 将得到的数据转换为适合输入到神经网络中的数据, 然后通过神经网络输出结果来与实际结果进行对比。实验通过对互通式立交桥这一现实场景进行实验, 验证了算法在车辆定位方面的有效性。另一方面, 算法通过

对车辆数据加入突变误差以及模拟车辆变道的情景, 验证了算法在实际应用中的可行性。在本算法中, 物联网和车联网提供的多源数据不仅丰富了神经网络的训练数据, 还通过实时更新和动态调整, 增强了系统的适应性和鲁棒性。特别是在突变误差和车辆变道的模拟场景中, 车联网的数据共享机制使得算法能够迅速调整定位策略, 保证车辆的精确定位和安全运行。综上所述, 结合物联网和车联网技术, 基于烟花算法的分布式车辆神经网络协同定位方法展示了在复杂交通环境下的优越性和应用潜力, 为未来智能交通系统的发展提供了新的思路和解决方案。

## 参考文献

- [1] LUO Q, LI Y, LIU C, et al. A SINS/DVL/USBL integrated navigation and positioning IoT system with multiple sources fusion and federated Kalman filter[J]. Journal of Cloud Computing: Advances, Systems and Applications, 2022(11): 18.
- [2] YUAN C, LAI J, LYU P, et al. A real-time factor-graph-optimized pedestrian navigation method[J]. IEEE Internet of Things Journal, 2023, 10(22): 20201-20215.
- [3] WANG Q, WANG B, DENG J, et al. A novel adaptive sliding observation-based cooperative positioning algorithm under factor graph framework for multiple UUVs [J]. IEEE Transactions on Industrial Informatics, 2023, 19(11): 8743-8753.
- [4] LIU J, CAI B, WANG J. Cooperative localization of connected vehicles: Integrating GNSS with DSRC using a robust cubature Kalman filter[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(8): 2111-2125.
- [5] XIN S, WANG X, ZHANG J, et al. A comparative study of factor graph optimization-based and extended Kalman filter-based PPP-B2b/INS integrated navigation[J]. Remote Sensing, 2023, 15(20): 5144.
- [6] SUN W, ZHANG X, DING W, et al. Maximum correntropy-based robust square-root cubature Kalman filter for vehicular cooperative navigation[J]. Scientific Reports, 2023, 13: 22961.
- [7] ZHANG X, WANG J, ZHANG Y, et al. Research on combined localization algorithm based on active screening-Kalman filtering[J]. Sensors, 2024, 24(9): 2372.
- [8] YAN X, LIU Y, ZHAO L, et al. DCP-AHS: A high-performance distributed cooperative positioning model

- for concave networks[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(5): 4334-4347.
- [9] SONG Z, ZHANG Y, YU Y, et al. A cooperative positioning algorithm via manifold gradient for distributed systems[J]. *IEEE Signal Processing Letters*, 2023, 30: 967-971.
- [10] KONG X, GAO H, SHEN G, et al. Fedvcp: A federated-learning-based cooperative positioning scheme for social internet of vehicles[J]. *IEEE Transactions on Computational Social Systems*, 2021, 9(1): 197-206.
- [11] ZHOU B, GU Z, GU F, et al. DeepVIP: Deep learning-based vehicle indoor positioning using smartphones[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(12): 13299-13309.
- [12] TIAN Y, LIU S, LIU W, et al. Vehicle positioning with deep-learning-based direction-of-arrival estimation of incoherently distributed sources[J]. *IEEE Internet of Things Journal*, 2022, 9(20): 20083-20095.
- [13] TAO X, ZHU B, XUAN S, et al. A multi-sensor fusion positioning strategy for intelligent vehicles using global pose graph optimization[J]. *IEEE Transactions on Vehicular Technology*, 2021, 71(3): 2614-2627.
- [14] LI F, WANG M, BAI W, et al. Assessment accuracy of standard point positioning enhanced by observation and position domain filtering utilizing a multi-epoch least-squares integration method[J]. *Remote Sensing*, 2024, 16(3): 517.
- [15] MORAGREGA A, FERNÁNDEZ-PRADES C. A data-driven factor graph model for anchor-based positioning [J]. *Sensors*, 2023, 23(12): 5660.
- [16] ZHANG H, PAN S. LSOS: An FG position method based on group phase ranging ambiguity estimation of BeiDou pseudolite[J]. *Remote Sensing*, 2023, 15(7): 1924.
- [17] XU Y, LIU C, LIU H, et al. Motion-constrained GNSS/INS integrated navigation method based on BP neural network[J]. *Remote Sensing*, 2022, 15(1): 154.
- [18] HUA L, ZHUANG Y, YANG J. SmartFPS: Neural network based wireless-inertial fusion positioning system [J]. *Frontiers in Neurorobotics*, 2023, 17: 1121623.
- [19] WANG W, GAO Y, LI X, et al. Doppler-aided positioning for fused LEO navigation systems[J]. *Aerospace*, 2023, 10(10): 864.
- [20] OLIVEROS J C, ASHRAFIUON H. Multi-vehicle navigation using cooperative localization[J]. *Electronics*, 2023, 12(24): 4945.
- [21] FANG X, HUANG D. Robust adaptive cubature Kalman filter for tracking manoeuvring target by wireless sensor network under noisy environment[J]. *IET Radar, Sonar & Navigation*, 2023, 17(2): 179-190.
- [22] CHE F, AHMED Q Z, LAZARIDIS P I, et al. Indoor positioning system (IPS) using ultra-wide bandwidth (UWB)—For industrial internet of things (IIoT)[J]. *Sensors*, 2023, 23(12): 5710.
- [23] LI J, YANG G, CAI Q. Autonomous aerial – ground cooperative navigation based on information-seeking in GNSS-denied environments[J]. *IEEE Internet of Things Journal*, 2023, 10(19): 17058-17069.
- [24] JANSSEN T, KOPPERT A, BERKVEN R, et al. A survey on IoT positioning leveraging LPWAN, GNSS, and LEO-PNT[J]. *IEEE Internet of Things Journal*, 2023, 10(13): 11135-11159.
- [25] 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.
- [26] WU G, WU J, DONG J, et al. Application research of DV-HOP wireless sensor localization system based on geometric constraint optimization[J]. *IEEE Access*, 2024, 12: 49078-49091.
- [27] DONG J, LIAN Z, XU J, et al. An improved adaptive sparrow search algorithm for TDOA-based localization [J]. *ISPRS International Journal of Geo-Information*, 2023, 12(8): 334.
- [28] LEE K, OH J, YOU K. TDOA/FDOA-based adaptive active target localization using iterated dual-EKF algorithm[J]. *IEEE Communications Letters*, 2019, 23(4): 752-755.
- [29] BUCCI A, FRANCHI M, RIDOLFI A, et al. Evaluation of UKF-based fusion strategies for autonomous underwater vehicles multisensor navigation[J]. *IEEE Journal of Oceanic Engineering*, 2023, 48(1): 1-26.
- [30] PARK G. Optimal vehicle position estimation using adaptive unscented Kalman filter based on sensor fusion [J]. *Mechatronics*, 2024, 99: 103144.
- [31] WU X, SHAO S, DAI Y. A dynamic self-tuning maximum correntropy Kalman filter for wireless sensors networks positioning systems[J]. *Remote Sensing*, 2022, 14(18): 4345.
- [32] CAI Z, LIU J, CHI W, et al. A low-cost and robust multi-sensor data fusion scheme for heterogeneous multi-robot cooperative positioning in indoor environments[J]. *Re-*

- mote Sensing, 2023, 15(24): 5584.
- [33] ZHANG L, WU X, GAO R, et al. A multi-sensor fusion positioning approach for indoor mobile robot using factor graph[J]. Measurement, 2023, 216: 112926.
- [34] ZHANG L, WU S, TANG C. Cooperative positioning of underwater unmanned vehicle clusters based on factor graphs[J]. Ocean Engineering, 2023, 287: 115854.
- [35] ZHU J, ZHOU H, WANG Z, et al. Improved multi-sensor fusion positioning system based on GNSS/LiDAR/Vision/IMU with semi-tight coupling and graph optimization in GNSS challenging environments[J]. IEEE Access, 2023, 11: 95711-95723.
- [36] FEI R, GUO Y, LI J, et al. An improved BPNN method based on probability density for indoor location[J]. IEICE Transactions on Information and Systems, 2023, E106.D(5): 773-785.
- [37] CAMAJORI TEDESCHINI B, BRAMBILLA M, NICOLI M. Message passing neural network versus message passing algorithm for cooperative positioning [J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(6): 1666-1676.
- [38] PASZEK K, GRZECHCA D. Using the LSTM neural network and the UWB positioning system to predict the position of low and high speed moving objects[J]. Sensors, 2023, 23(20): 8270.
- [39] MPIMIS T, KAPSIS T T, GIKAS V, et al. Dynamic optimal vehicle selection for cooperative positioning using low-cost GNSS receivers[J]. IEEE Access, 2023, 11: 134146-134154.

#### [作者简介]

- 余泰铮 2000年生, 硕士研究生。  
廉保旺 1962年生, 博士, 教授。  
唐成凯 1985年生, 博士, 副教授。  
丹泽升 1990年生, 博士, 研究员。  
刘洋洋 1990年生, 博士, 副教授。

(本文编辑: 傅 杰)