

基于PNN算法的5G道路高精度定位方法研究及应用

Research and Application of High Precision Location Method for 5G Roads Based on PNN Algorithm

杨飞虎,刘贤松,石旭荣(中国联通智网创新中心,上海 200050)

Yang Feihu, Liu Xiansong, Shi Xurong (Intelligent Network & Innovation Center of China Unicom, Shanghai 200050, China)

摘要:

5G网络覆盖是运营商保持竞争力的首要条件,如何快速掌握真实用户的覆盖情况、体验感知及位置尤为重要。利用O域MR、工参及DT路测数据,通过PNN算法构建5G道路高精度定位能力,将室外道路平均定位误差提升至50米左右,为实现5G道路免测试功能奠定了基础。

关键词:

5G; PNN; 道路; 高精度定位

doi: 10.12045/j.issn.1007-3043.2024.06.011

文章编号: 1007-3043(2024)06-0051-07

中图分类号: TN929.5

文献标识码: A

开放科学(资源服务)标识码(OSID):



Abstract:

5G network coverage is the primary condition for operators to maintain competitiveness, and it is particularly important to quickly grasp the coverage, experience perception, and location of real users. It utilizes O-domain MR, engineering parameters, and DT road test data to construct a high-precision positioning capability for 5G roads through PNN algorithm, which increases the average positioning error of outdoor roads to about 50 meters, settling the foundation for achieving 5G road test-free function.

Keywords:

5G; PNN algorithm; Roads; High precision location

引用格式: 杨飞虎,刘贤松,石旭荣. 基于PNN算法的5G道路高精度定位方法研究及应用[J]. 邮电设计技术, 2024(6): 51-57.

1 概述

随着5G网络规模越来越大^[1],覆盖越来越广,运营商利用5G MR网络数据开展室外道路精准定位,一方面可以基于运营商特有的用户MR数据,继续延续4G MR在网络定位方面的优势。另一方面可以拓展无线网络的应用场景,不仅提供基础语音和数据服务,还可以提供基于定位的相关服务^[2],推动“地理信息+”业务创新,产生新的价值和收益。高精度定位服

务也是国家“十四五”规划、新基建、数字经济发展规划中的重要内容,研究基于5G MR室外道路精准定位服务具有重要技术、商业和战略意义。

当前4G LTE网络支持MDT(Minimization of Drive Tests)数据自动采集,MDT数据是运营商通过手机终端自动采集的网络测量报告,它包含大量、丰富的小区 and 信号相关信息,如小区ID、频点、信号强度、信号质量等。这些信息可以作为构建定位指纹库的数据源,用于构建室内外高精度定位系统^[3-4]。而5G NR网络由于技术和标准上的限制,暂时还不支持MDT数据采集。这使得5G MR定位在构建高精度的定位指纹

收稿日期: 2024-05-08

库时面临精准指纹数据不足的难题。未来可以考虑从如下几个方向解决该问题。

a) 推动5G NR标准支持MDT,让终端和网络具备MDT的数据采集和上报能力。

b) 利用其他数据源替代MDT,如车载终端、OTT技术等,在一定程度上可弥补数据的不足,但收集难度很大,目前也无法规模推广。

c) 丰富新的定位算法和模型,尽量构建相对准确的5G MR网络需求的定位指纹库。比如研究基于DT路测数据获取指定区域的小区信号数据,构建基础定位指纹库,同时与神经网络定位技术[如PNN^[5](Probabilistic Neural Network)]进行很好的融合,实现指纹库数据的密集化和扩充。

2 传统5G MR定位方法

由于当前5G网络不支持MDT,没有直接可用于构建室内外高精度定位系统的无线特征指纹,因此常规的基于MR数据进行定位的方法主要有:

a) 最近邻定位^[6](Nearest Neighbor)。选择接收信号最强的那个基站,然后将用户位置估计为那个基站的位置。这种方法实现简单,但精度较低,属于小区级,定位误差在200~500 m(取决于基站平均站间距)。

b) 三角定位^[7](Trilateration)。利用信号强度或到达时间差(Time of Arrival, TOA)来测量与多个基站的距离,然后通过三角算法计算用户位置。这种方法精度较差,平均精度在150~200 m。

c) 角度定位^[8](Angle of Arrival, AOA)。利用天线阵列测量信号TA和到达角度,通过TA和AOA角度去计算用户位置。但这种方法在环境比较复杂的城区,会因为受到较严重的信号多径和遮挡效应,对TA和AOA测量产生较大误差,从而导致定位精度不高,平均定位误差在200~300 m。

综上所述,最近邻定位、三角定位、TA+AOA定位方法精度都不高,均无法满足5G高精度定位应用的要求。同时上述3种常规定位方法都需要严格准确的基站工参信息为前提,否则定位误差将更大。因此现阶段迫切需要一种能够在缺失5G MDT数据的前提下,通过定位算法的融合和定位技术手段方法的研究来实现较高精度5G MR定位能力,支撑虚拟5G道路测试、质差TOP小区用户位置定位、VIP用户投诉预警、网络规划等多个专业场景和应用,助力5G网络质量提升。

3 基于PNN算法的5G道路高精度定位方法

在实现5G道路高精度定位的研究实践过程中,需要解决无线工参纠偏、指纹补全和高精度定位3个主要问题。

a) 针对基站工参信息不准的问题,引入无线工参纠偏算法,基于无监督学习DBSCAN^[9]算法智能识别站点的准确位置,并打上工参准确性置信度标签,能够在一定程度上自动纠正工参的错误数据。

b) 针对当前5G网络不支持MDT,没有直接可用于构建室内外高精度定位系统的无线特征指纹的问题,为提升5G网络道路场景下的定位精度,需要对指纹进行补全,还需要选择适合的定位算法。

本文提出一个基于DT路测数据或OTT数据获取区域范围内的小区信号数据来构建基础定位指纹库的方法。但当获取到的道路指纹数据相对有限时,为实现更精准的定位和室内覆盖,就需要使用机器学习来推理和补全完整的道路指纹信息。因此采用PNN算法实现道路指纹补全和精准定位,在实现指纹补全功能时,将PNN竞争层改为TOP N概率竞争输出,输出层改进为加权回归输出,来预测和重建缺失的完整指纹;在进行精准定位时,采用最强激活神经元定位位置信息,最终获得更精准定位效果。

3.1 5G工参纠偏算法

工参纠偏需要输入的参数的准确性直接影响到网络的质量和性能,并给后期定位精度带来较大风险^[10]。在5G建网初期,站点建设速度较快,优化及维护工作量较大,站点新开、搬迁、拆除的情况时有发生,指纹主控小区覆盖识别与纠偏模型需要的输入参数经常存在记录或录入错误的情况。在5G MDT缺失的情况下,基于道路指纹中RSRP、SINR、RSRQ、经纬度、SCS、TA等特征数据进行建模,基于无监督学习算法,并通过密度空间聚类自动化识别和纠正定位基础参数^[11]。

DBSCAN是一种基于密度的聚类算法(均值漂移是基于密度上升的算法),一般假定类别可以通过样本分布的紧密程度决定。同一类别的样本是紧密相连的,在该类别任意样本周围不远处一定有同类别的样本存在。通过将紧密相连的样本划为一类,得到了一个聚类类别。通过将所有各组紧密相连的样本划为各个不同的类别,最终得到所有聚类类别。

由密度可达关系导出的最大密度相连的样本集

合,它任意选择一个没有类别的核心对象作为种子,然后找到所有这个核心对象能够密度可达的样本集合,即为一个聚类簇^[12]。接着继续选择另一个没有类别的核心对象去寻找密度可达的样本集合,这样就得到另一个聚类簇。以此类推,一直运行到所有核心对象都有类别为止。DBSCAN主要解决如下3个核心问题。

a) 异常样本点或者少量游离于簇外的样本点问题。这些点不在任何一个核心对象周围,在DBSCAN中,一般将这些样本点标记为噪声点。

b) 距离的度量问题,即如何计算某样本和核心对象样本的距离。在DBSCAN中,一般采用最近邻思想,采用某一种距离度量来衡量样本距离,比如欧式距离,这和KNN分类算法的最近邻思想完全相同。对于少量的样本,寻找最近邻可以直接去计算所有样本的距离,如果样本量较大,则一般采用KD树或者球树来快速地搜索最近邻。

c) 某些样本可能到2个核心对象的距离都小于 ϵ ,但是这2个核心对象由于不是密度直达,又不属于同一聚类簇,此时DBSCAN一般采用先来后到方法,先进行聚类的类别簇会标记这个样本为它的类别。

DBSCAN算法的流程如下。

输入:样本集 $D=(x_1, x_2, \dots, x_m)$,邻域参数 $(\epsilon, \text{MinPts})$,样本距离度量方式。

输出:簇划分 C 。

a) 初始化核心对象集合 $\Omega=\emptyset$,初始化聚类簇数 $k=0$,初始化未访问样本集合 $\Gamma=D$,簇划分 $C=\emptyset$ 。

b) 对于 $j=1, 2, \dots, m$,按下面的步骤找出所有的核心对象。

(a) 通过距离度量方式,找到样本 x_j 的 ϵ 邻域子样本集 $N_\epsilon(x_j)$ 。

(b) 如果子样本集样本个数满足 $|N_\epsilon(x_j)| \geq \text{MinPts}$,将样本 x_j 加入核心对象样本集合: $\Omega=\Omega \cup \{x_j\}$ 。

c) 如果核心对象集合 $\Omega=\emptyset$,则算法结束,否则转入步骤d)。

d) 在核心对象集合 Ω 中,随机选择一个核心对象,初始化当前簇核心对象队列 $\Omega_{\text{cur}}=\{o\}$,初始化类别序号 $k=k+1$,初始化当前簇样本集合 $C_k=\{o\}$,更新未访问样本集合 $\Gamma=\Gamma-\{o\}$ 。

e) 如果当前簇核心对象队列 $\Omega_{\text{cur}}=\emptyset$,则当前聚类簇 C_k 生成完毕,更新簇划分 $C=\{C_1, C_2, \dots, C_k\}$,更新核心对象集合 $\Omega=\Omega-C_k$,转入步骤c)。

f) 在当前簇核心对象队列 Ω_{cur} 中取出一个核心对象 o' ,通过邻域距离阈值 ϵ 找出所有的 ϵ 邻域子样本集 $N_\epsilon(o')$,令 $\Delta=N_\epsilon(o') \cap \Gamma$,更新当前簇样本集合 $C_k=C_k \cup \Delta$,更新未访问样本集合 $\Gamma=\Gamma-\Delta$,转入步骤e)。

输出结果为:簇划分 $C=\{C_1, C_2, \dots, C_k\}$ 。

3.2 基于PNN道路指纹库构建算法

PNN神经网络是一种基于贝叶斯决策规则的概率密度函数估计来进行模式识别的神经网络,其神经网络的训练期望误差较小,是一种基于统计原理的人工神经网络,学习过程简单,训练速度快。神经网络算法(如BP神经网络^[13])对训练集的大小比较高的要求,而PNN算法可以在小样本条件下,仍然给出较好的分类结果。这主要得益于PNN算法基于统计概率理论,利用概率密度估计^[14]和Bayes决策理论进行分类,而无需像BP神经网络那样进行复杂的训练过程。特别适用于5G道路定位的具体场景应用,因为无线通信环境复杂,覆盖情况与具体场景高度相关,可针对不同空间范围,用样本训练不同的模型来实现定位和道路指纹补全。

在5G道路高精度定位方法的研究中,本文利用PNN算法实现了道路指纹补全和高精度定位,取得了良好的效果。

3.2.1 PNN算法实现步骤

PNN算法实现步骤如下。

a) 构建训练样本集:

$$X = \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1n} \\ X_{21} & X_{22} & \cdots & X_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ X_{m1} & X_{m2} & \cdots & X_{mn} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ \cdots \\ X_m \end{bmatrix}$$

其中, X_{mn} 表示第 m 个训练样本的第 n 个输入变量。隐含层的每个神经元对应一个训练样本,即 m 个隐含神经元中的中心点对应了每个神经元激活函数的中心。

b) 将标准化好的 m 个样本送入到网络输入层中:

$$\begin{bmatrix} \frac{X_{11}}{\sqrt{M_1}} & \frac{X_{12}}{\sqrt{M_1}} & \cdots & \frac{X_{1n}}{\sqrt{M_1}} \\ \frac{X_{21}}{\sqrt{M_2}} & \frac{X_{22}}{\sqrt{M_2}} & \cdots & \frac{X_{2n}}{\sqrt{M_2}} \\ \cdots & \cdots & \cdots & \cdots \\ \frac{X_{m1}}{\sqrt{M_m}} & \frac{X_{m2}}{\sqrt{M_m}} & \cdots & \frac{X_{mn}}{\sqrt{M_m}} \end{bmatrix} = \begin{bmatrix} C_{11} & C_{12} & \cdots & C_{1n} \\ C_{21} & C_{22} & \cdots & C_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ C_{m1} & C_{m2} & \cdots & C_{mn} \end{bmatrix}$$

c) 模式距离的计算。该距离是指样本矩阵与学习矩阵中相应元素之间的距离。假设将由 P 个 n 维向

量组成的矩阵称为待识别样本矩阵, 则经归一化后, 待识别的输入样本矩阵为:

$$D = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1n} \\ d_{21} & d_{22} & \cdots & d_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ d_{p1} & d_{p2} & \cdots & d_{pn} \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \\ \cdots \\ d_p \end{bmatrix}$$

其中, D 表示输入变量待分类样本矩阵, d_{pn} 表示第 p 个待分类的数据, n 表示每一个样本维数。计算欧式距离, 即计算需要识别的归一化的样本向量 d_i 与每一个归一化后的训练样本 (C_j) 的欧式距离:

$$E = \begin{bmatrix} \sqrt{\sum_{k=1}^n |d_{1k} - c_{1k}|^2} & \sqrt{\sum_{k=1}^n |d_{1k} - c_{2k}|^2} & \cdots & \sqrt{\sum_{k=1}^n |d_{1k} - c_{mk}|^2} \\ \sqrt{\sum_{k=1}^n |d_{2k} - c_{1k}|^2} & \sqrt{\sum_{k=1}^n |d_{2k} - c_{2k}|^2} & \cdots & \sqrt{\sum_{k=1}^n |d_{2k} - c_{mk}|^2} \\ \cdots & \cdots & \cdots & \cdots \\ \sqrt{\sum_{k=1}^n |d_{pk} - c_{1k}|^2} & \sqrt{\sum_{k=1}^n |d_{pk} - c_{2k}|^2} & \cdots & \sqrt{\sum_{k=1}^n |d_{pk} - c_{mk}|^2} \end{bmatrix} = \begin{bmatrix} E_{11} & E_{12} & \cdots & E_{1m} \\ E_{21} & E_{22} & \cdots & E_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ E_{p1} & E_{p2} & \cdots & E_{pm} \end{bmatrix}$$

其中, C_i 为归一化的训练样本, $i=1, 2, \dots, m$; d_j 为归一化的待分类样本, $j=1, 2, \dots, p$; E_{ij} 为第 i 个待分类样本 (d_i) 与第 j 个训练样本 (C_j) 的欧式距离。

d) 激活模式层高斯函数的神经元, 选择合适的 spread 值:

$$P = \begin{bmatrix} \frac{E_{11}}{e^{2\sigma^2}} & \frac{E_{12}}{e^{2\sigma^2}} & \cdots & \frac{E_{1m}}{e^{2\sigma^2}} \\ \frac{E_{21}}{e^{2\sigma^2}} & \frac{E_{22}}{e^{2\sigma^2}} & \cdots & \frac{E_{2m}}{e^{2\sigma^2}} \\ \cdots & \cdots & \cdots & \cdots \\ \frac{E_{p1}}{e^{2\sigma^2}} & \frac{E_{p2}}{e^{2\sigma^2}} & \cdots & \frac{E_{pm}}{e^{2\sigma^2}} \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1m} \\ P_{21} & P_{22} & \cdots & P_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ P_{p1} & P_{p2} & \cdots & P_{pm} \end{bmatrix}$$

假设样本有 m 个, 那么一共可以分为 c 类, 并且各类样本的数目相同, 设为 k , 则可以在网络的求和层求得各个样本属于各类的初始概率和:

$$S = \begin{bmatrix} \sum_{l=1}^k P_{1l} & \sum_{l=k+1}^{2k} P_{1l} & \cdots & \sum_{l=m-k+1}^m P_{1l} \\ \sum_{l=1}^k P_{2l} & \sum_{l=k+1}^{2k} P_{2l} & \cdots & \sum_{l=m-k+1}^m P_{2l} \\ \cdots & \cdots & \cdots & \cdots \\ \sum_{l=1}^k P_{pl} & \sum_{l=k+1}^{2k} P_{pl} & \cdots & \sum_{l=m-k+1}^m P_{pl} \end{bmatrix} =$$

$$\begin{bmatrix} S_{11} & S_{12} & \cdots & S_{1c} \\ S_{21} & S_{22} & \cdots & S_{2c} \\ \cdots & \cdots & \cdots & \cdots \\ S_{p1} & S_{p2} & \cdots & S_{pc} \end{bmatrix}$$

e) 计算概率, 即第 i 个样本属于第 j 类的概率:

$$\text{prob}_{ij} = S_{ij} / \sum_{l=1}^c S_{il}$$

3.2.2 PNN 实现定位和指纹补全步骤

在用 PNN 实现定位和指纹补全的过程中, 对 PNN 算法进行了改进, 以便更好地适用定位和指纹补全的场景。主要是对竞争层和输出层进行了改进, 在实现指纹补全功能时, 将概率输出改进为加权回归输出, 用于补全指纹的位置信息。

a) 构建训练样本集。已经构建好的指纹库包含指纹数据, 指纹库数据记录了信号强度与空间位置的关系。指纹数据样本点表示 (x, y) 位置处可以接收到来自小区 1 到小区 n 的信号, 以向量形式表示为 $[\text{RSRP}_1, \text{RSRP}_2, \dots, \text{RSRP}_n, x, y]$ 。可以将指纹数据作为训练样本, 具体处理过程如下: 划定模型训练区域 A , 设定训练区域为一个矩形区域, 包括 $n_1 \times n_2$ 个采样点, 每个采样点对应一个指纹库中的指纹向量 $[\text{RSRP}_1, \text{RSRP}_2, \dots, \text{RSRP}_n, x, y]$, 将区域 A 中的 $n_1 \times n_2$ 个样本点, 构成训练样本集。 $[\text{RSRP}_1, \text{RSRP}_2, \dots, \text{RSRP}_n]$ 为信号强度特征值, $[x, y]$ 为表示位置信息的样本标签。

(a) 训练矩阵特征 X 为:

$$\begin{bmatrix} \text{RSRP}_{11} & \text{RSRP}_{12} & \cdots & \text{RSRP}_{1n} \\ \text{RSRP}_{21} & \text{RSRP}_{22} & \cdots & \text{RSRP}_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ \text{RSRP}_{m1} & \text{RSRP}_{m2} & \cdots & \text{RSRP}_{mn} \end{bmatrix}$$

(b) 训练矩阵标签为:

$$\begin{bmatrix} x_1, y_1 \\ x_2, y_2 \\ \cdots \\ x_m, y_m \end{bmatrix}$$

其中, m 为训练样本数, $m=n_1 \times n_2$ 。

b) 标准化训练样本。对每个位置的训练数据进行标准化处理, 以消除信号强度的绝对值影响。

c) 模式距离数据计算。待定位样本矩阵 D 为:

$$\begin{bmatrix} \text{RSRP}_{11} & \text{RSRP}_{12} & \cdots & \text{RSRP}_{1n} \\ \text{RSRP}_{21} & \text{RSRP}_{22} & \cdots & \text{RSRP}_{2n} \\ \cdots & \cdots & \cdots & \cdots \\ \text{RSRP}_{p1} & \text{RSRP}_{p2} & \cdots & \text{RSRP}_{pn} \end{bmatrix}$$

其中, p 为待定位样本矩阵或待补全样本矩阵。计算待定位样本矩阵或待指纹补全样本矩阵与训练样本矩阵之间的欧式距离^[15]。

d) 激活模式层高斯函数的神经元,选择合适的 spread 值。选择 PNN 的 spread 值,这个值会影响 PNN 的判断边界,需要根据数据分布选择合适的值。在 PNN 的模式层,每个神经元对应一个位置,神经元的权重由该位置的训练样本决定。

e) 在求和层,计算待定位样本或待补全样本矩阵属于每个神经元的概率,这里有 2 种后续算法,可分别实现定位以及指纹补全。

(a) 定位。在模式层找到响应最强的神经元,用该神经元的位置信息定位用户所在位置。

(b) 指纹补全。在模式层计算响应 TOP N 强的神经元,对 TOP N 强的神经元的位置加权回归,可实现指纹补全,通过不断积累新的数据增强 PNN,提高定位和指纹补全精度。

f) 利用时序信息和迭代学习来优化 PNN 模型,以更好地拟合随时间变化的指纹。

(a) 时序信息。加入道路指纹数据的时间戳信息,以捕捉道路指纹随时间变化的特征。传统的 PNN 模型只利用信号的强度等特征,但忽略了时序信息,加入时间戳可以很好地体现指纹随时间变化的规律。

(b) 迭代学习。在 PNN 模型的学习过程中进行迭代,优化模型参数,不断优化拟合效果。原始的 PNN 模型通常是基于单次的概率密度函数拟合,本文通过多轮迭代优化,不断改进概率分布的拟合效果。

因此通过改进竞争层和输出层、添加时序信息、采用迭代学习策略,可以有效改进原始 PNN 模型,可以更好地拟合随时间变化的道路指纹数据,最终提高道路指纹补全和定位的效果。

4 实验分析

4.1 工参纠偏结果分析

工参纠偏分析流程如图 1 所示。

通过分析某市 2 个区域 600 个站点的道路测试数据,发现工参存在明显错误的小区有 59 个,占比 9.83%。工参纠偏结果分布情况如图 2 所示。

以某电话亭 03-5G_1 小区为例,工参位置在新天地商厦附近,而路测采样点样本基本位于复兴中路与西南路周边区域(见图 3),从图 3 可以看到,工参位置(绿色点)距离路测采样点约 850 m,纠偏后的位置(红色点)才是站点真正的位置。

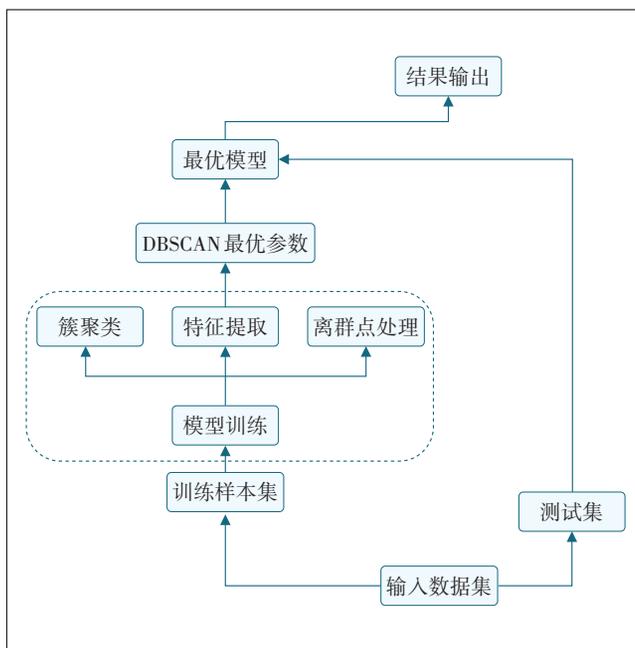


图 1 工参纠偏分析流程

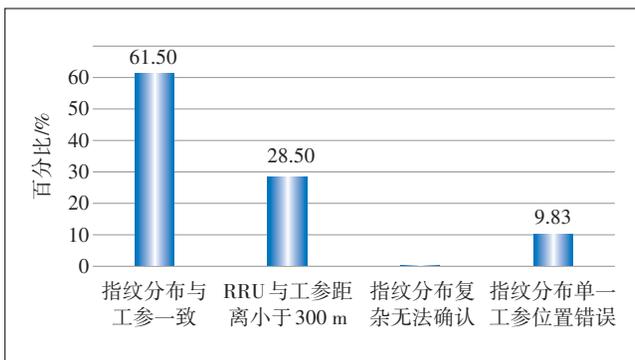


图 2 工参纠偏实验结果分布情况



图 3 工参纠偏站点位置对比结果

色点)才是站点真正的位置。

4.2 道路指纹纠偏结果分析

道路指纹纠偏分析流程如图4所示。

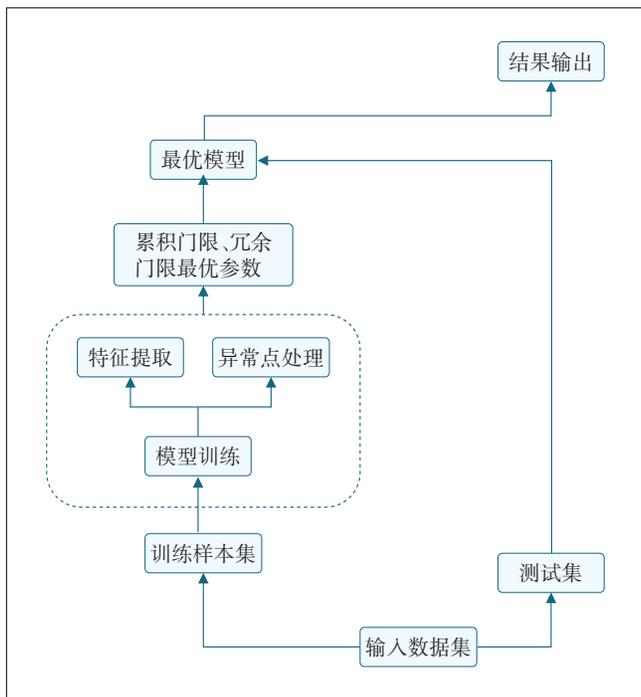


图4 道路指纹纠偏分析流程

对某市一区域(该区域东西长6 km,南北宽4.5 km)内的测试数据进行道路指纹纠偏,道路纠偏后有效的采样点占比为71.86%,有效的20 m栅格数量占比为94.62%(见表1和图5)。

以某路附近的楼宇为例,存在部分栅格(图6中红

表1 实验区域道路纠偏前后对比结果

道路指纹	采样点数	栅格数
纠偏后	7 158 097	36 840
纠偏前	9 960 948	38 933
占比/%	71.86	94.62

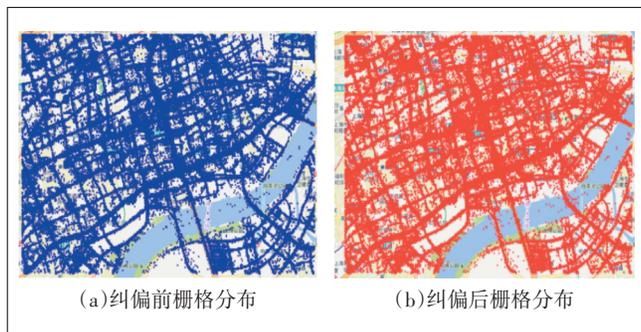


图5 纠偏前后栅格分布



图6 实验区域道路指纹纠偏效果呈现

色小方块),栅格内采样点服务小区的RSRP为-44 dBm且在连续小段时间内测量值没有变化,纠偏模型将这类异常采样判断为噪点,并进行剔除。

4.3 整体实验结果分析

选择某市约14 km²区域,区域内相关5G基站有247个,约1 249个小区,5G的指纹采用道路测试数据经过预处理获取,测试路线如图7所示。

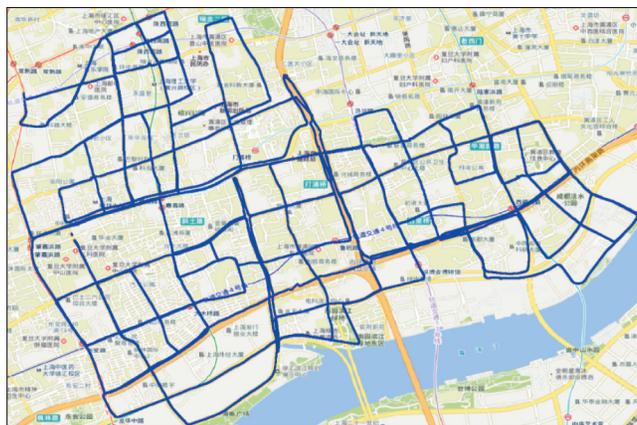


图7 实验区域测试路线

5G MR数据利用定位程序获取位置信息后,我们可开展批量验证或少量测试用户的CQT/DT验证。本轮验证采用DT测试数据开展精度验证,用路测数据做指纹,剔除一些冗余、无效和噪点,采集真实MR数据,通过定位算法计算位置,并与路测数据逐点进行误差对比。图8中红色点是5G MR定位后的结果,绿色点是与5G定位MR对应的路测采样点,从定位形态分析,定位出来的点都是相对连续的线状轨迹,可以看出移动的轨迹特点,符合实际情况。

高精度指纹匹配算法定位率为50.60%,定位平均



图8 实验区域5G定位结果与DT轨迹比对

误差为53.1 m,其中误差在50 m内的占比为61.98% (见表2和图9)。

表2 高精度指纹匹配算法的定位误差

定位方法	5G MR点数量	行数	比例/%	误差	误差50 m以内/%	误差100 m以内/%
道路高精度定位	2 251	1 139	50.60	53.1	61.98	86.39

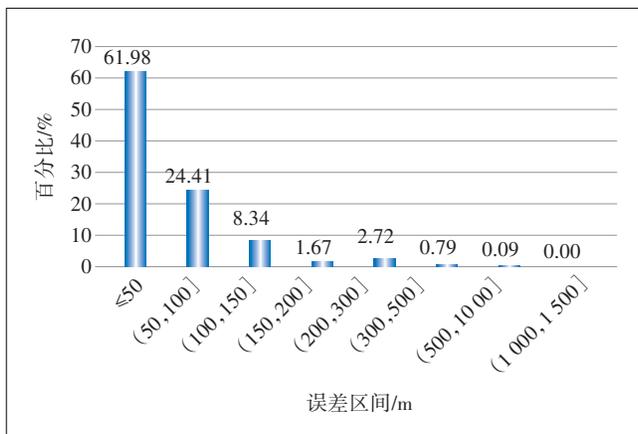


图9 实验区域5G道路定位精度误差呈现分布

5 结束语

本文利用O域MR和DT路测数据,通过无线工参、指纹纠偏和PNN算法构建了5G道路高精度定位能力,将室外道路平均定位误差降至50 m左右,可以满足道路测试的实际要求。目前已将该能力应用到无线网络随心测产品中的5G免测试功能,实现5G RSRP覆盖、下行SINR质量等关键指标的高精度道路位置定位,并推广到全国31省,助力国道、省道、高速等诸多场景,实现对传统路测工作模式的变革,可有效提升道路测试和分析工作的效率,支撑一线网优

工作。

参考文献:

- [1] 徐静,黄宇芳,彭淇. 拉动规模 提质增效 2022年5G用户发展规模预测及展望[J]. 通信企业管理,2022(1):6-11.
- [2] 梁怡兰. 无线通信基站定位技术研究与应用[J]. 大众科技,2018,20(3):5-7.
- [3] 毛永毅,李明远,张宝军. 一种NLOS环境下的TOA/AOA定位算法[J]. 电子与信息学报,2009,31(1):37-40.
- [4] 徐亚楠,蔡超,杨立辉,等. 蜂窝网无线定位技术研究及实践[J]. 邮电设计技术,2021(10):33-37.
- [5] QU Y R, CAI H, REN K, et al. Product-based neural networks for user response prediction[EB/OL]. [2024-01-24]. <https://arxiv.org/abs/1611.00144>.
- [6] COVER T, HART P. Nearest neighbor pattern classification [J]. IEEE Transactions on Information Theory, 1967, 13(1):21-27.
- [7] XU L, WEI Y K. Triangulation algorithm based on Three-Point positioning and weighted coordinates[J]. Computer Engineering and Applications, 2020,56(9):111-116.
- [8] 张曦文. 基于TDOA和AOA的无线定位算法研究[D]. 成都:电子科技大学,2019.
- [9] ESTER M, KRIEGEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise [C]//Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. Menlo Park, Calif.: AAAI Press, 1996:226-231.
- [10] 刘林林. 基于MR数据的用户定位与工参优化的研究[D]. 北京:北京邮电大学,2020.
- [11] 张宝杰,余涛,王玉,等. 流数据聚类方法[J]. 现代计算机,2022,28(23):32-37,54.
- [12] 闫强强,张敏,荀亚玲. 采用有效邻近点和适应密度的密度聚类算法[J]. 计算机技术与发展,2022,32(9):14-22.
- [13] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representations by error propagation [M]//COLLINS A, SMITH E E. Readings in Cognitive Science. San Mateo, Calif.: M. Kaufmann Publishers, 1988:399-421.
- [14] PRASAD P D, VIVEK Y, RAVI V. FedPNN:one-shot federated classification via evolving clustering method and probabilistic neural network hybrid [EB/OL]. [2024-01-02]. <http://export.arxiv.org/abs/2304.04147>.
- [15] 余利国,丁卫平,景炜. 基于最近邻的标签修正推荐算法[J]. 计算机与数字工程,2020,48(4):735-740.

作者简介:

杨飞虎,毕业于华东理工大学,工程师,硕士,主要从事无线网络AI研究及产品设计工作;刘贤松,毕业于武汉大学,高级工程师,硕士,主要从事网络AI研究工作;石旭荣,毕业于山东大学,助理工程师,学士,主要从事AI算法研究及开发工作。