

利用神经网络逐级缩小定位区域的低复杂度 多级干扰源直接定位方法

赵晓丹, 张国梅, 尹佳文, 李国兵
(西安交通大学电子与信息学部, 710049, 西安)

摘要: 针对利用直接定位(DPD)方法对全球导航卫星系统(GNSS)终端面临的干扰源进行定位时,在线计算复杂度高的问题,提出了一种利用神经网络逐级缩小定位区域的低复杂度多级干扰源直接定位方法。该方法首先使用多级全连接神经网络(FNN)逐级缩小干扰源所在的区域范围,每一级处理将目标区域均分为两个子区域,并利用预训练的以接收信号功率作为输入特征的神经网络选出干扰源所在的子区域,从而大幅缩小干扰源所在的目标区域;然后在锁定的最终子区域内划分网格并使用 DPD 方法对干扰源进行精细定位。由于逐级二分处理已将干扰源可能存在的区域大幅缩小,因此有效降低了 DPD 方法的网格搜索集合大小。仿真结果表明:在较高干噪比条件下(对于压制式干扰通常大于 20 dB),所提方法能获得与 DPD 方法接近的定位性能,而在线计算复杂度相比于 DPD 方法可降低大约 2^M 倍(M 为神经网络级数),定位误差相比于传统基于到达时间差(TDOA)的 Chan 氏定位方法可降低 90% 以上。

关键词: 全球导航卫星系统;干扰源定位;直接定位;神经网络

中图分类号: TN972.4 **文献标志码:** A

DOI: 10.7652/xjtuxb202207015 **文章编号:** 0253-987X(2022)07-0136-09



OSID 码

Low Complexity Multi-Stage Direct Position Determination of Interference Source Based on Neural Networks to Narrow the Location Area

ZHAO Xiaodan, ZHANG Guomei, YIN Jiawen, LI Guobing
(Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To reduce the high online computation complexity of conventional direct positioning determination (DPD) used to locate interference sources of the global navigation satellite system (GNSS), a low complexity multi-stage direct position determination approach is proposed, in which the neural networks are applied to narrow the location area stage by stage. Firstly, multi-stage fully connected neural network (FNN) is applied to narrow the area where the interference source is located step by step. In each step, the target area is divided into two sub-areas, and the pre-trained neural network with received signal power as input feature is used to identify the sub-area where the interference source is located, thus greatly reducing the target area where the interference source is located. Then, the grids are divided in the locked final sub-area and the proposed DPD is used to fine locate the interference source. Since the possible area where the interference source is located has been narrowed significantly after the step-by-step binary processing, the set size for grid searching of the DPD can decrease efficiently. The simulation

results show that compared with the conventional DPD approach, the proposed approach is close to it in performance at high jamming-noise ratio (usually greater than 20 dB for blanket jamming), and the online calculation complexity can be reduced by about 2^M times (M is the number of neural networks). Furthermore, the positioning error is more than 90% lower than CHAN algorithm based on the estimated time difference of arrival (TDOA).

Keywords: global navigation satellite system; interference source position; direct position determination; neural network

全球导航卫星系统(global navigation satellite system, GNSS)广泛应用于国防和民用领域,已成为全球的重要基础设施,但是由于 GNSS 信号的脆弱性,加之其应用领域和环境的日益复杂化,使得其接收机极易受到有意或无意的干扰。如何对抗干扰成为 GNSS 应用领域关注的焦点,而快速准确地定位干扰源并将其从源头消除,作为一种高效的抗干扰技术成为领域内的研究热点。

针对 GNSS 接收机的干扰源定位属于无源定位,通常需要多个传感器或接收机的相互协作^[1]。对此,传统两步定位系统通常使用接收信号强度(received signal strength, RSS)、到达角(angle of arrival, AOA)和到达时间差(time different of arrival, TDOA)等测量参数或参数组合来估计射频干扰位置^[2-4]。其中基于 TDOA 的方法因其对传感器节点的同步要求低且设备实现简单而得到了广泛应用, TDOA 定位参数的精确估计则是要解决的关键问题。文献[5]提出了一种二次相关 TDOA 估计和改进阈值小波去噪相结合的 TDOA 参数估计方法,提高了低信噪比下 TDOA 参数的估计精度。文献[6-7]进一步通过改进小波系数阈值函数提高了定位精度。

为了避免传统两步定位法对定位参数高精度估计的依赖和参数估计带来的信息损失,学者们提出了直接定位(direct position determination, DPD)方法^[8-10]。DPD 方法利用原始的或简单预处理后的信号数据构建代价函数,再求得代价函数的最优解以获取目标位置,避免了参数估计带来的信息损失,定位精度相比于传统两步法更接近克拉美罗界^[9]。然而,由于 DPD 方法的代价函数通常是非凸的,存在多个局部最优解。通常通过对目标所在的区域进行网格划分,再在网格集合内进行穷举搜索的方法来寻找全局最优解^[11]。当网格搜索集合很大时,其在线计算复杂度过高,实际可用性受限。DPD 方法还被推广到了多干扰源^[12]以及分布式定位场景^[13]。

近年来,具有强大特征挖掘和数据处理分析能

力的深度学习技术也被用于 GNSS 接收机的干扰检测和识别研究。文献[14]提出了基于两级反向传播(back propagation, BP)神经网络的压制式和欺骗式干扰自动分类识别方法。文献[15]使用多层感知器神经网络实现了对压制式干扰信号、欺骗信号和多径干扰信号的高精度检测。深度学习技术也被用于室内定位来提升定位精度。文献[16]利用栈式自动编码器(stacked auto encoder, SAE)为离线指纹数据库构建深度神经网络,获得了更精确的 Wifi 室内定位精度。文献[17]将自动编码器与长短期记忆(long short term memory, LSTM)网络连接起来用于室内指纹定位,改善了模型的准确性。文献[18]将 SAE 与卷积神经网络(convolutional neural networks, CNN)相结合用于室内定位, SAE 用于从稀疏接收信号强度数据中提取关键特征,而 CNN 用于对多建筑物和多楼层进行区分。以上研究中,神经网络主要用于区域有限的室内定位中,或对信号进行特征提取,或对目标所处区域进行分类,但是这些处理方法并不能直接推广到室外场景,原因主要有以下几点:室外定位通常具有广阔的面积和开放的无线传输环境,训练网络需要生成能遍历各个位置和经历随机无线传输的巨量样本,一方面这样的样本数据难以获取,另一方面也不利于神经网络训练的收敛;若先提取特征再输入网络通过分类来确定目标位置,在室外场景下分类类别非常巨大(成千上万),无法获得准确的分类结果;若基于 DPD 思想,将原始接收信号送入回归网络,利用网络自动提取特征并回归目标位置,又由于位置相近的干扰源对应的接收信号具有强相关性,难以构造和训练出满足所需回归精度的网络。因此截止目前,采用神经网络等学习方法对位置进行直接求解的相关研究还比较少。

受已有研究工作的启发,本文针对面向 GNSS 接收机的静态单干扰源场景,仍将采用 DPD 方法来实现对目标的高精度定位。如何在大幅降低其计算复杂度的同时还尽量保留其定位效果则是本文的设

计目标。为此,提出了先采用多级二分类人工神经网络对目标区域进行逐级缩小,再在缩小的区域内采用 DPD 方法的多级干扰源定位方法。通过区域缩小可大幅降低 DPD 方法网格搜索的集合大小,进而降低其在线计算复杂度。通过在最终目标区域内采用 DPD 方法,可实现较高的定位精度。仿真实验结果验证了所提方法可达到设计目标。

1 系统模型及问题描述

1.1 系统模型

考虑如图 1 所示的静态单干扰源二维定位场景。假设有 L 个频率和时间上同步的单天线定位接收机,位置已知,假设第 l 个接收机的位置记为 $\mathbf{p}_l = (x_l, y_l)$ 。干扰源位置用 $\mathbf{q} = (x, y)$ 表示,位置未知。第 l 个接收机收到的中频信号 $r_l(t)$ 可表示为

$$r_l(t) = s_l(t) + j_l(t) + w_l(t) \quad (1)$$

式中: $s_l(t)$ 为有用卫星信号; $j_l(t)$ 为干扰信号; $w_l(t)$ 为加性高斯白噪声,其均值为 0、方差为 σ_l^2 。卫星信号经过长距离传输后,接收信号功率极低,例如 GPS L1 频点民用卫星信号到达地面时最小平均信号强度为 -160 dBW^[19-20]。另外,此处考虑压制式干扰,其接收功率远高于卫星信号接收功率,因此本文忽略了对 $s_l(t)$ 的影响。




图 1 静态单干扰源二维定位场景图

Fig. 1 Two-dimensional positioning scene diagram of static interference source

假设干扰源发送二进制相移键控(binary phase shift keying, BPSK)窄带压制式干扰信号,其信号模型可表示为^[14]

$$j(t) = \sqrt{2P_j} \sum_i (a_i g(t - iT_b) \cos(2\pi f_j t + \varphi)) \quad (2)$$

式中: P_j 为干扰信号的发送功率; f_j 为干扰信号频率; φ 为 $[0, 2\pi]$ 上均匀分布的随机相位; a_i 表示随机二进制不归零比特流; $g(t)$ 表示矩形窗; T_b 表示二进制比特的码元宽度。

假设干扰信号的衰落系数记为 β_l ,则第 l 个接收机在 t 时刻的观测信号记为

$$r_l(t) = \beta_l j(t - \tau_l) + w_l(t), \quad 0 \leq t \leq T \quad (3)$$

式中: T 为观测时长,假设在观测区间 T 内衰落系数保持不变; τ_l 为干扰源发射信号到接收机 l 的传播时延,可定义为

$$\tau_l = \frac{\sqrt{(x - x_l)^2 + (y - y_l)^2}}{c} \quad (4)$$

式中 c 为电磁波信号传播速度。

以时间间隔 T_s 对接收信号进行采样,得到 N 点采样序列为

$$\left. \begin{aligned} \mathbf{r}_l @ [\mathbf{r}_l(0), \mathbf{r}_l(1), \dots, \mathbf{r}_l(N-1)]^T \\ \mathbf{w}_l @ [\mathbf{w}_l(0), \mathbf{w}_l(1), \dots, \mathbf{w}_l(N-1)]^T \\ \mathbf{j}_l @ [\mathbf{j}_l(0), \mathbf{j}_l(1), \dots, \mathbf{j}_l(N-1)]^T \end{aligned} \right\} \quad (5)$$

由式(3)可以得到

$$\mathbf{r}_l = \beta_l \mathbf{j}_l + \mathbf{w}_l \quad (6)$$

可以看出与干扰源位置有关的时延信息蕴藏在 $\mathbf{j}_l$ 中,对式(6)进行离散傅里叶变换,将干扰源发射信号与传播时延解耦,得到接收信号的频域表达式

$$\mathbf{r}_l(k) = \beta_l \bar{\mathbf{j}}_l(k) e^{-j\omega_k \tau_l} + \mathbf{w}_l(k), \quad 0 \leq k \leq N-1 \quad (7)$$

式中: $\bar{\mathbf{j}}_l(k)$ 为干扰源发射信号离散傅里叶变换的第 k 个频率分量; $\mathbf{w}_l(k)$ 为第 l 个接收机噪声离散傅里叶变换的第 k 个频率分量; ω_k 为傅里叶变换角频率,定义为 $\omega_k @ 2\pi k / (NT_s)$ 。

假设各接收机将其接收序列的离散傅里叶变换结果无误差地发送给处理中心,得到频域接收信号矩阵 $\mathbf{r} = [\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_L]$ 。那么单干扰源定位问题就是依据接收信号矩阵 $\mathbf{r}$ 和接收机位置 $\mathbf{p}_l (l=1, 2, \dots, L)$,求解干扰源位置 $\mathbf{q}$ 的问题,可采用 DPD 方法来解决。

1.2 单干扰源直接定位过程

假设 $\mathbf{w}_l(k)$ 的自相关矩阵为 $\mathbf{R}_l = \sigma_l^2 \mathbf{I}$ 。状态 H_0 代表当前接收信号中只有噪声,状态 H_1 代表当前接收信号中存在干扰信号和噪声,两种状态下接收信号的似然比函数可表示为^[12]

$$\begin{aligned} L(\mathbf{r}; \mathbf{q}) &= \frac{p(\mathbf{r} | H_1; \mathbf{q})}{p(\mathbf{r} | H_0)} = \frac{K_0}{K_1} \prod_{l=1}^L L(\mathbf{r}_l; \mathbf{q}) = \\ &= \frac{K_0}{K_1} \prod_{l=1}^L \exp\left(-\frac{1}{2} \mathbf{r}_l - \beta_l \bar{\mathbf{j}}_l)^H \mathbf{R}_l^{-1} (\mathbf{r}_l - \beta_l \bar{\mathbf{j}}_l) + \right. \\ &\quad \left. \frac{1}{2} \bar{\mathbf{r}}_l^H \mathbf{R}_l^{-1} \bar{\mathbf{r}}_l \right) \end{aligned} \quad (8)$$

式中: K_0 和 K_1 为常数。

由广义最大似然比准则先求解与干扰源位置无

直接关联的衰落系数 β_l 。令 $\frac{\partial L(\mathbf{r}_l)}{\partial \beta_l} = 0$, 得到

$$\beta_l = \frac{\bar{\mathbf{j}}_l^H \mathbf{R}_l^{-1} \mathbf{r}_l}{\bar{\mathbf{j}}_l^H \mathbf{R}_l^{-1} \bar{\mathbf{j}}_l} \quad (9)$$

将式(9)代入式(8)可推导出

$$L(\mathbf{r}_l; \mathbf{q}) = \exp\left(\frac{1}{2} \frac{1}{\bar{\mathbf{j}}_l^H \mathbf{R}_l^{-1} \bar{\mathbf{j}}_l} |\bar{\mathbf{j}}_l^H \mathbf{R}_l^{-1} \mathbf{r}_l|^2\right) \quad (10)$$

假设 $|\bar{\mathbf{j}}|^2 = 1$, 进一步有

$$L(\mathbf{r}_l; \mathbf{q}) = \exp\left(\frac{1}{2\sigma_l^2} |\bar{\mathbf{j}}_l^H \mathbf{r}_l|^2\right) \quad (11)$$

将式(11)代入(8), 并忽略常数项, 可以得到

$$L(\mathbf{r}; \mathbf{q}) \propto \sum_{l=1}^L \frac{1}{\sigma_l^2} |\bar{\mathbf{j}}_l^H \mathbf{r}_l|^2 = \sum_{l=1}^L \frac{1}{\sigma_l^2} \left| \sum_{k=0}^{N-1} e^{j\omega_k \tau_l} \bar{\mathbf{j}}^*(k) \mathbf{r}_l(k) \right|^2 \quad (12)$$

令

$$\mathbf{b}_l @ \left[\frac{1}{\sigma_l^2} e^{j\omega_0 \tau_l} \mathbf{r}_l(0), \dots, \frac{1}{\sigma_l^2} e^{j\omega_{N-1} \tau_l} \mathbf{r}_l(N-1) \right]^T \quad (13)$$

进一步定义对数似然比为

$$\Gamma(\mathbf{r}; \mathbf{q}) = \sum_{l=1}^L |\bar{\mathbf{j}}^H \mathbf{b}_l|^2 = \bar{\mathbf{j}}^H \left(\sum_{l=1}^L \mathbf{b}_l \mathbf{b}_l^H \right) \bar{\mathbf{j}} = \bar{\mathbf{j}}^H \mathbf{B} \bar{\mathbf{j}} \quad (14)$$

下面以 $\Gamma(\mathbf{r}; \mathbf{q})$ 为代价函数, 找到使代价函数最大的干扰源位置 $\mathbf{q}$ 。要让 $\Gamma(\mathbf{r}; \mathbf{q})$ 最大, 对于某固定的 $\bar{\mathbf{j}}$ 来说, 就是要让矩阵 $\mathbf{B}$ 的最大特征值最大。因此, 干扰源位置 $\mathbf{q}$ 的估计便转化为如下问题

$$\hat{\mathbf{q}} = \arg \max_{\mathbf{q} \in \{\mathbf{q}_g\}} \lambda_{\max}(\mathbf{B}) \quad (15)$$

通常采用遍历搜索方法求解问题式(15)。将整个定位区域均匀划分为 G 个网格, 以每个网格的中心位置 $\mathbf{q}_g (g=1, 2, \dots, G)$ 代表该网格, 并组成网格搜索集合 $\{\mathbf{q}_g\}$, 遍历该集合找出使 $\lambda_{\max}(\mathbf{B})$ 最大的位置 $\hat{\mathbf{q}}$ 作为估计的干扰源位置。 $\mathbf{B}$ 为 $N \times N$ 维矩阵, 采样点数较大时求解特征值的计算负荷很大。为了减少计算开销, 利用 $\mathbf{B} = \mathbf{U}\mathbf{U}^H$ 和 $\hat{\mathbf{B}} = \mathbf{U}^H \mathbf{U}$ (其中 $\mathbf{U} @ [\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_L]$) 两矩阵的最大特征值相同的结论, 将式(15)问题转化为

$$\hat{\mathbf{q}} = \arg \max_{\mathbf{q} \in \{\mathbf{q}_g\}} \lambda_{\max}(\hat{\mathbf{B}}) \quad (16)$$

式中 $\hat{\mathbf{B}}$ 为 $L \times L$ 维矩阵, 因为 L 通常远小于 N , 所以 $\lambda_{\max}(\hat{\mathbf{B}})$ 的计算开销可大幅降低。

由上述 DPD 方法过程可以看出, DPD 方法利用所有接收机的原始数据构建代价函数并求解目标位置, 避免了参数估计精度不够带来的信息损失。

但是, 采用网格搜索方式求解问题式(16)的计算复杂度与网格搜索集合大小成正比, 当目标定位区域较大或网格划分较小时, 网格搜索集合较大, 过高的搜索复杂度将限制 DPD 方法的可用性。为了降低网格搜索集合大小, 可增大网格边长或缩小目标可能存在的区域。网格边长的选取与目标定位精度有关, 网格边长越大定位精度越低, 因此通过增大网格边长来降低计算复杂度将得不偿失。如果可以缩小目标可能存在的区域, 先将目标锁定在一个较小的区域内再实施 DPD 方法, 计算复杂度将大幅降低。

2 神经网络驱动的多级定位方法

基于以上分析, 本节提出了一种利用多个二分类神经网络缩小定位区域再应用 DPD 方法的多级干扰源定位方法, 有效解决 DPD 方法在线计算复杂度过高的问题, 同时相较于传统两步定位方法还能继续获得 DPD 方法的高定位精度。显然, 这种降低实现复杂度的方法得以有效, 根本上是由 DPD 方法计算量对目标区域大小敏感的固有特性所决定的, 两者结合有其内在适应性。

2.1 多级干扰源定位方法原理

所提出的多级干扰源定位方法, 总体分为两个步骤。第 1 步使用多个实现二分类功能的神经网络逐级缩小干扰源所在的区域范围。每一级处理将目标区域均分为两个子区域, 并利用训练好的神经网络选出干扰源所在的子区域。如此逐级处理, 直到某一级划分的子区域大小低于设定的区域边长门限 T , 该过程如图 2 所示。在初始定位区域固定的情况下, 区域边长门限的选取会决定子区域选择正确率以及最终干扰源定位的复杂度。区域边长门限越小, 级数越多, 子区域选择正确率会降低, 但是第 2 步执行 DPD 方法的区域越小, 干扰源定位复杂度也越低。因此, 区域边长门限的选择需要在定位精度和计算复杂度之间进行折中考虑。在图 2 中, 进行 4 级二分处理后, 子区域大小将满足门限 T 要求, 此时选定的子区域称为最终子区域, 即图 2 中深蓝色部分。定位方法第 2 步是在最终子区域内使用 1.2 节的 DPD 方法得到干扰源位置的估计值 $\hat{\mathbf{q}} = (\hat{x}, \hat{y})$ 。

2.2 神经网络结构与训练

现有神经网络根据中间功能层的不同主要分为 3 种: 全连接神经网络 (fully connected neural network, FNN), 其每一层的每个神经元与上一层所有神经元都有连接, 主要用于分类和数值预测; 卷积神




图 2 逐级缩小干扰源所在区域示意图
Fig. 2 Schematic diagram of narrowing the area where the interference source is located step by step

神经网络 (convolutional neural network, CNN) 由卷积层、池化层和全连接层构成, 具有强大的图像特征提取能力, 主要用于图像识别领域; 循环神经网络 (recurrent neural network, RNN) 的特点是隐藏层之间的节点是有连接的, 且隐藏层的输入不仅包括输入层的输出还包括上一时刻隐藏层的输出, 主要用于前后样本数据具有关联性的文本、语音等序列数据。在本文方法中需要一个复杂度较低的善于做分类任务的神经网络, 根据上述 3 类神经网络的技术特点, 这里选择简单有效的 FNN 网络实现方法第一步的逐级二分类过程。通常 FNN 网络中隐藏层的个数和隐藏层的神经元个数均不是先验已知的, 在本文中, 采用多次实验 (经验选定) 的方法获取最佳的网络结构, 设计了表 1 所示的 4 种 FNN 结构。根据测试准确率最终选取的 FNN 结构为一个输入层、一个输出层以及两个节点数分别为 8 和 16 的隐藏层。

表 1 4 种 FNN 结构及其测试准确率	
Table 1 Four FNN structures and their testing accuracy	
网络结构	测试准确率
[4, 8, 1]	0.98
[4, 8, 12, 1]	0.99
[4, 8, 16, 1]	1.00
[4, 8, 12, 16, 1]	0.98

训练和测试时, 神经网络输入均为 L 个接收机的接收功率向量 $\mathbf{P}_r = [P_{r1}, P_{r2}, \dots, P_{rL}]$, 其中 $P_{rl} = \frac{1}{N} \sum_{n=0}^{N-1} |r_l(n)|^2$, 输出为每一级划分的两个子区域

的编号 $i \in \{1, 2\}$ 。

针对某干扰源定位区域和某固定位置的 L 个接收机, 设定足够大的初始二分类处理级数 M , 对每一级所使用的神经网络均需进行离线训练, 每一级训练过程相同, 训练过程如下。

步骤 1 生成训练数据集。在当前定位区域内随机产生 K 个干扰源位置。根据式 (2) 模拟生成干扰源发射信号。将当前定位区域等分为两个子区域并编号, 记录干扰源所处子区域编号 i 。干扰发射信号经过大尺度衰落和瑞利衰落到达各个接收机, 根据式 (3)、(4) 模拟生成 L 个接收机的接收信号。再采样得到时域接收序列, 计算接收功率向量 $\mathbf{P}_r$, 形成一个由 K 个训练样本组成的训练集。注意生成训练集时, 接收信号中不包含噪声项。这是因为, 在实际中无法预先知道噪声强度, 因此在训练集中无法加入具有准确功率大小的噪声; 其次, 从实验经验上看不加入噪声可以使网络收敛更快; 第三, 本文假设干扰源类型为大功率压制式干扰, 相较而言噪声的影响可以忽略; 最后, 这样处理参考了文献 [21-23] 中的做法。

步骤 2 训练神经网络结构和参数。利用本级训练样本对本级所用神经网络的结构和参数进行反复调整 and 参数训练。输入为接收功率向量 $\mathbf{P}_r$, 标签为子区域编号 i 。

步骤 3 生成验证数据集并验证神经网络性能。生成方法与训练数据集相同, 不同的是验证集的接收信号中含有噪声项, 噪声强度根据设定的干噪比计算得到。验证集信号中加入噪声, 是因为实际中接收信号都是存在噪声的, 为了验证的真实性有必要加入随机噪声; 此外, 这样处理还可以测试所训练网络对噪声的鲁棒性。然后利用验证数据集对训练好的神经网络进行性能测试。

完成对所有神经网络的训练和测试后, 记录每一级神经网络的子区域分类准确率测试值。随着级数增加, 准确率会降低。这里有两种确定最终区域边长门限 T 的思路: 一种是性能优先, 当准确率低于 100% 时停止分级, 这意味着 T 会比较大, 第 2 步 DPD 方法的复杂度会比较高; 另一种是复杂度优先, 给定 DPD 方法的计算开销限制, 例如通过限制网格数反过来确定最终子区域大小。本文实验中采用了第一种思路。

2.3 本文方法步骤总结

基于以上分析, 本文提出的多级干扰源直接定位方法的具体步骤如下。

步骤 1 根据初始定位区域和 2.2 节描述方法,设定区域边长门限 T 和相应级数 M 。

步骤 2 处理中心根据各接收机反馈的接收序列,计算接收功率向量 $\mathbf{P}_r$ 。

步骤 3 将接收功率向量 $\mathbf{P}_r$ 送入当前级神经网络,输出为当前级子区域编号,并由此确定下一级定位子区域和对应的神经网络。

步骤 4 重复执行步骤 3,逐级缩小定位子区域大小,直到下一级定位子区域边长小于等于区域边长门限 T ,则将该子区域确定为最终子区域。

步骤 5 根据最终子区域范围和定位精度要求,选择合适的网格边长,对最终子区域进行网格划分。

步骤 6 根据式(13)~(16),计算每个网格点对应的代价函数 $\lambda_{\max}(\hat{\mathbf{B}})$ 。随后找出所有网格对应代价函数的最大值,将最大值对应的网格中心点作为干扰源位置的估计值 $\hat{\mathbf{q}}$ 。

2.4 复杂度分析

本文所提干扰源定位方法的计算量是 M 级全连接神经网络分类的计算量与在最终子区域内使用 DPD 方法的计算量之和。对于结构为 $[L, h_1, \dots, h_D, 1]$ 的 FNN 网络,其计算复杂度为 $O(\sum_{l=1}^D (h_{l-1} \cdot h_l))$ 。仿真实验中最终选取的 FNN 结构为 $[4, 8, 16, 1]$,因此 M 级分类处理的计算复杂度为 $O(128M)$ 。DPD 方法的复杂度主要取决于网格数 G 和接收序列采样点数 N ,计算量来源于每个网格计算 1 次矩阵 $\hat{\mathbf{B}}$,并对其进行特征值分解,找出最大特征值。DPD 方法的总计算复杂度为 $O(G(LN^2 + L^3 + L))$ 。计算可知本文仿真实验中 DPD 方法的计算复杂度(10^7 数量级)远大于 M 级分类处理的计算复杂度(10^3 数量级),所以本文所提方法的计算复杂度主要取决于最终子区域内 DPD 方法的计算复杂度, M 级 FNN 二分处理的复杂度可忽略。

执行 M 级二分处理后,最终子区域大小降为初始区域大小的 $1/2^M$,因此当划分的网格大小相同时,完全使用 DPD 方法的计算复杂度为 $O(2^M G(LN^2 + L^3 + L))$,理论上本文方法复杂度降为 $1/2^M$ 。

3 仿真实验及结果分析

本节通过计算机仿真实验对所提出方法的定位性能和计算开销进行验证。对比方法有:①结合小波去噪处理的基于 TDOA 参数的 Chan 氏两步定位方法^[24];②整个初始定位区域内使用 1.2 节 DPD

方法。初始定位范围设置为边长 4 000 m 的正方形区域,将 4 个接收机(即 $L=4$)分别布置在区域的 4 个顶点。同一参数配置下共进行 K 次独立的定位实验,假设 $\mathbf{q}_k = (x_k, y_k)$ 和 $\hat{\mathbf{q}}_k = (\hat{x}_k, \hat{y}_k)$ 分别为第 k 次实验得到的干扰源真实位置和估计位置,则用两者的均方根误差(root mean square error, RMSE)来衡量各方法的定位误差,其表达式为

$$E_{\text{RMS}} = \sqrt{\frac{1}{K} \sum_{k=1}^K [(x_k - \hat{x}_k)^2 + (y_k - \hat{y}_k)^2]} \quad (17)$$

3.1 各方法定位误差与单次定位计算开销对比

设置网格边长为 20 m,在自由空间大尺度衰落和瑞利衰落下仿真了 3 种方法的定位均方根误差(每种方法进行 1 000 次蒙特卡罗实验)以及各方法进行 1 次源定位所需的时间。仿真配置为 Intel(R) Core(TM) i7-8700 CPU @ 3.20 GHz, Matlab R2019a。瑞利衰落的均值为 1.25,标准差为 0.43。自由空间大尺度衰落模型为

$$F_L = 20\lg(d) + 20\lg(f_j) + 32.4 \quad (18)$$

式中: d 为干扰源与定位接收机之间的距离,km; f_j 为干扰信号频率,MHz。

不同方法的定位误差和单次定位时间对比分别如图 3 和表 2 所示。可以看出,结合小波去噪处理的基于 TDOA 参数的 Chan 氏两步定位方法性能明显低于使用了 DPD 的方法,这说明两步定位法的定位性能取决于参数估计精度。当干噪比大于 20 dB 时,本文所提方法与 DPD 方法有相近的定位精度,且 DPD 方法的定位时间约为本文方法(最终子区域边长 500 m 时)的 44 倍,可见本文方法大幅降低了定位的计算复杂度。这里与理论上的 64 倍有所出入的原因是在软件仿真中神经网络分类处理占用了一定的时间以及两种方法划分网格各自占用了不同




图 3 不同方法的定位误差对比

Fig. 3 Comparison of positioning errors of different schemes

的时间。

表 2 不同方法的单次定位时间对比

Table 2 Comparison of single positioning time of different schemes

含噪声项训练集进行网络训练不符合本文的定位需求。

方法	单次定位时间/s
两步定位法	0.15
DPD 方法	6.14
本文方法(最终子区域边长 500 m)	0.14
本文方法(最终子区域边长 250 m)	0.09

3.2 最终子区域边长对定位精度的影响

所提方法的定位性能由第 1 步多级子区域定位准确率以及第 2 步 DPD 方法定位精度共同决定。若第 1 步将干扰源划分到了错误的子区域,则会直接导致比较大的定位误差,第 2 步 DPD 方法几乎无法有效纠正。因此,本文方法要获得好的性能,前提是保证第 1 步子区域定位具有极高的准确率。

本节通过仿真考察不同最终子区域范围内的子区域识别准确率。设置最终子区域范围分别为 4 000 m×2 000 m、2 000 m×1 000 m、1 000 m×500 m、500 m×250 m 和 250 m×125 m。图 4 中上方 5 条曲线为这 5 种情况下的 FNN 分类准确率(训练集不含噪声项),从图 4 中可以看出,干噪比越高,准确率越高。某固定干噪比下,最终子区域范围越小准确率越低,这是因为最终子区域范围越小则划分出错的可能性也越大。当干噪比大于 15 dB 时,各范围配置下的准确率均为 95% 以上,当干噪比大于 25 dB 时,各范围配置下的准确率均接近于 1。对于压制式干扰源来说,其干噪比通常在 25 dB 以上^[25],因此该实验结果说明,在本次仿真的场景设置下子区域门限设置为 250 m 以上时,便可以实现对压制式干扰的高精度子区域划分,同时还可以将整个定位过程的计算复杂度降低 44 倍。

为了对比说明采用不含噪声的样本集训练神经网络的必要性,图 4 中蓝色曲线给出了采用等比例加入干噪比分别为 15、20、25 和 30 dB 的噪声项的样本集训练神经网络时,可获得的分类准确率测试结果。其中最终子区域范围为 4 000 m×2 000 m,每个干噪比下产生 400 组测试数据。可以看出,此时 FNN 确定子区域的准确率不随干噪比的升高而降低,各个干噪比下均低于相同配置下用不含噪声项的样本训练出的网络的准确率。这是因为在采用不同干噪比的有噪样本进行混合训练时,训练误差不能收敛到一个较低值。这也进一步说明,采用包




图 4 不同最终子区域范围内 FNN 分类准确率

Fig. 4 Classification accuracy of FNN in different final sub-areas

图 5 给出了定位误差随最终子区域边长变化曲线。设置 DPD 方法搜索网格边长为 25 m,最终子区域边长分别为 2 000 m、1 000 m、500 m、250 m,各参数配置下分别进行 1 000 次定位实验。从图 5 中可以看出,随着最终子区域边长减小,定位误差逐渐增加。这正是最终子区域边长减小会导致第 1 步子区域定位准确度降低所造成的现象。这种定位精度的损失,在低干噪比条件下更加明显,干噪比越高,最终子区域边长减小带来误差增幅也越小。这也说明,在干扰信号功率很高时,适当增加级数 M 来追求更低的定位复杂度,此时定位精度的损失较小。




图 5 定位误差随最终子区域边长变化曲线

Fig. 5 Graph of positioning error changing with the side length of the final sub-areas

3.3 DPD 方法网格边长对定位精度的影响

本文所提方法的定位精度与最终子区域内执行 DPD 方法时选定网格边长有关。固定最终子区域

边长为 500 m,干噪比为 25 dB,分别设置网格边长为 50 m、25 m、10 m、5 m,对本文方法和完全 DPD 方法进行 1 000 次定位实验,定位误差随网格边长变化曲线如图 6 所示,不同网格边长下的单次定位时间见表 3。从图 6 中可以看出,随着网格边长减小,本文方法和 DPD 方法的定位精度逐渐增加,本文方法相比于 DPD 方法定位精度损失也越小。从表 3 还可以看出,随着网格边长减小,本文方法单次定位时间长度相比于 DPD 方法的降低程度也越大。这说明,相比于 DPD 方法,本文方法更适合于对定位精度要求高且对计算复杂度限制也高的场景。




图 6 定位误差随网格边长变化曲线

Fig. 6 Graph of positioning error changing with the side length of the grid

表 3 不同网格边长下的单次定位时间

Table 3 Single positioning time under different side length of the grid

方法	单次定位时间/s			
	50 m	25 m	10 m	5 m
DPD 方法	0.89	3.17	73.63	904.51
本文方法	0.08	0.11	0.35	1.25

4 结 论

本文针对面向 GNSS 接收机的单干扰源场景提出了一种利用神经网络逐级缩小定位区域的低复杂度多级干扰源直接定位方法——首先利用训练好的多级 FNN 网络逐步缩小干扰源所在区域,得到一个更小的干扰源待定位范围;然后采用 DPD 方法在最终子区域内进行干扰源精确定位。该方法结合了神经网络高精度分类和 DPD 方法高精度定位的技术特点,在干噪比大于 20 dB 时可在定位精度损失很小的情况下,大幅降低直接采用 DPD 方法的计

算开销。本文方法单次定位时间与传统两步定位方法接近,但是其定位性能远优于两步法。此外,本文的低复杂度定位框架也适用于其他存在网格遍历搜索过程的 DPD 方法^[8]。先缩小定位范围再进行精细定位的思想也可扩展到传统两步定位系统,在通过逐级二分类获得干扰源存在的较小可能区域后,再利用该区域附近离目标较近的传感器节点来估计定位参数,便可实现更准确的定位。为了避免在高随机开阔环境下神经网络训练所需的样本数据难以获得的难题,也可以将本文方法第 1 步处理替换为非监督方法,例如支持向量机与决策树结合的方法等,这也是本文后续研究主要关注的问题。

参考文献:

[1] 纪惠,郭恒恒,孙鹏,等. 卫星干扰源定位方法综述 [C]//第十五届卫星通信学术年会论文集. 北京: 中国通信学会, 2019: 327-334.

[2] DEMPSTER A G, CETIN E. Interference localization for satellite navigation systems [J]. Proceedings of the IEEE, 2016, 104(6): 1318-1326.

[3] 张威,马宏,吴涛,等. 一种基于泰勒级数展开的卫星 FDOA 地面干扰源定位算法 [J]. 无线电通信技术, 2019, 45(4): 385-390.

ZHANG Wei, MA Hong, WU Tao, et al. A location algorithm of ground interference sources using satellites FDOA measurements based on Taylor series expansion [J]. Radio Communications Technology, 2019, 45(4): 385-390.

[4] 王珊珊,刘峥,谢荣,等. 有源欺骗干扰环境下的 DOA 估计 [J]. 电子与信息学报, 2019, 41(5): 1040-1046.

WANG Shanshan, LIU Zheng, XIE Rong, et al. DOA estimation under active deception jamming environment [J]. Journal of Electronics & Information Technology, 2019, 41(5): 1040-1046.

[5] DOU Huijing, LEI Qian, CHENG Jun, et al. Research on TDOA parameters estimation for satellite interference localization [C]// Proceedings of the 2012 11th IEEE International Conference on Signal Processing. Piscataway, NJ, USA: IEEE, 2012: 259-262.

[6] ZHU Wenping, HOU Shujuan, YUAN Yuan. A novel wavelet denoising pre-processing algorithm for TDOA localization [C]// Proceedings of the 2019 IEEE/CIC International Conference on Communications in China (ICCC). Piscataway, NJ, USA: IEEE, 2019: 266-270.

[7] CHEN Zengmao, WANG Shijian. An improved meth-

- od of wavelet threshold denoising for satellite signal [C]//Proceedings of the 2018 8th International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC). Piscataway, NJ, USA: IEEE, 2018: 1774-1777.
- [8] WEISS A J. Direct position determination of narrow-band radio frequency transmitters [J]. IEEE Signal Processing Letters, 2004, 11(5): 513-516.
- [9] WEISS A J. Direct geolocation of wideband emitters based on delay and Doppler [J]. IEEE Transactions on Signal Processing, 2011, 59(6): 2513-2521.
- [10] WEISS A J, AMAR A. Direct geolocation of stationary wideband radio signal based on time delays and Doppler shifts [C]//Proceedings of the 2009 15th IEEE/SP Workshop on Statistical Signal Processing. Piscataway, NJ, USA: IEEE, 2009: 101-104.
- [11] AMAR A, WEISS A J. Direct position determination (DPD) of multiple known and unknown radio-frequency signals [C]//Proceedings of the 2004 12th European Signal Processing Conference. Piscataway, NJ, USA: IEEE, 2004: 1115-1118.
- [12] 陈芳香. 分布式雷达多辐射源直接定位算法研究 [D]. 成都: 电子科技大学, 2019.
- [13] 赵高峰, 陈若迅, 李营营, 等. 基于分布式无人机监测的干扰源直接定位 [J]. 太赫兹科学与电子信息学报, 2021, 19(4): 628-634, 641.
ZHAO Gaofeng, CHEN Ruoxun, LI Yingying, et al. Direct location of interference sources based on distributed UAV monitoring [J]. Journal of Terahertz Science and Electronic Information Technology, 2021, 19(4): 628-634, 641.
- [14] ZHANG Xin, ZHANG Guomei, WANG Hua, et al. Two-stage neural network based combined interference classification and recognition for a GNSS receiver [C]//Proceedings of the 2020 China Satellite Navigation Conference (CSNC); Volume III. Berlin, Germany: Springer, 2020: 623-633.
- [15] TOHIDI S, MOSAVI M R. Effective detection of GNSS spoofing attack using a multi-layer perceptron neural network classifier trained by PSO [C]//Proceedings of the 2020 25th International Computer Conference. Piscataway, NJ, USA: IEEE, 2020: 1-5.
- [16] ZHONG Yanru, YUAN Zhixiang, LI Yiyuan, et al. A WiFi positioning algorithm based on deep learning [C]//Proceedings of the 2019 7th International Conference on Information, Communication and Networks (ICICN). Piscataway, NJ, USA: IEEE, 2019: 99-104.
- [17] LIU Yuting, CHEN J J, TSENG Y C, et al. Combining auto-encoder with LSTM for WiFi-based fingerprint positioning [C]//Proceedings of the 2021 International Conference on Computer Communications and Networks (ICCCN). Piscataway, NJ, USA: IEEE, 2021: 1-6.
- [18] SONG Xudong, FAN Xiaochen, XIANG Chaocan, et al. A novel convolutional neural network based indoor localization framework with WiFi fingerprinting [J]. IEEE Access, 2019, 7: 110698-110709.
- [19] 孟伟. GNSS接收机中基于深度神经网络的欺骗式干扰检测与识别算法研究 [D]. 西安: 西安交通大学, 2019.
- [20] 王璐, 吴仁彪, 王文益, 等. 基于多天线的GNSS压制式干扰与欺骗式干扰联合抑制方法 [J]. 电子与信息学报, 2016, 38(9): 2344-2350.
WANG Lu, WU Renbiao, WANG Wenyi, et al. Joint GNSS interference mitigation approach for jamming and spoofing based on multi-antenna array [J]. Journal of Electronics & Information Technology, 2016, 38(9): 2344-2350.
- [21] 陈鑫, 王鼎, 唐涛, 等. 阵列模型误差条件下直接定位性能分析及偏差修正方法 [J]. 电子学报, 2019, 47(8): 1633-1642.
CHEN Xin, WANG Ding, TANG Tao, et al. Performance analysis and deviation correction method of direct position determination in the presence of array modeling errors [J]. Acta Electronica Sinica, 2019, 47(8): 1633-1642.
- [22] CHEN Xin, WANG Ding, YIN Jiexin, et al. A direct position-determination approach for multiple sources based on neural network computation [J]. Sensors, 2018, 18(6): 1925.
- [23] CHEN C S. Artificial neural network for location estimation in wireless communication systems [J]. Sensors, 2012, 12(3): 2798-2817.
- [24] 赵宏旭, 杨文帅. 基于TDOA的Chan算法和Taylor算法的分析与比较 [J]. 电子世界, 2017(9): 176-177.
ZHAO Hongxu, YANG Wenshuai. Analysis and comparison of Chan algorithm and Taylor algorithm based on TDOA [J]. Electronics World, 2017(9): 176-177.
- [25] 刘磊. 卫星导航抗压压制式干扰性能分析及仿真验证 [D]. 西安: 西安电子科技大学, 2017.

(编辑 武红江 刘杨)