

本文引用格式: 刘雅宁,卢浩,程彦汇.一种基于机器学习的无人机集群协同定位方法[J].自动化与信息工程,2025,46(2):32-37.

LIU Yaning, LU Hao, CHENG Yanhui. A cooperative localization method for unmanned aerial vehicle swarm based on machine learning[J]. Automation & Information Engineering, 2025,46(2):32-37.

一种基于机器学习的无人机集群协同定位方法

刘雅宁¹ 卢浩² 程彦汇³

(1.北京中电华大电子设计有限责任公司, 北京 102209

2.山东云海国创云计算装备产业创新中心有限公司, 北京 100095

3.北京智芯微电子科技有限公司, 北京 102200)

摘要: 针对无线定位技术受非视距误差等影响, 导致定位误差较大的问题, 提出一种基于机器学习的无人机集群协同定位方法。首先, 建立无人机集群定位模型, 并利用基于到达时间差(TDOA)的定位算法消除无人机与目标的时钟偏差; 然后, 采用支持向量机构建视距/非视距(LOS/NLOS)分类模型, 并通过分析接收信号特征参数, 分类 LOS 与 NLOS 信号; 最后, 根据分类结果, 利用基于特征选择的 NLOS 抑制算法筛选适合参与目标定位计算的样本。仿真结果表明, 该定位方法可以降低 NLOS 误差, 提升定位算法的鲁棒性。

关键词: 无人机集群; 协同定位; 机器学习; 非视距误差; 支持向量机; 到达时间差

中图分类号: TP391; TP212.9

文献标志码: A

文章编号: 1674-2605(2025)02-0005-06

DOI: 10.12475/aie.20250205

开放获取

A Cooperative Localization Method for Unmanned Aerial Vehicle Swarm Based on Machine Learning

LIU Yaning¹ LU Hao² CHENG Yanhui³

(1.CEC Huada Electronic Design Co., Ltd., Beijing 102209, China

2. Shandong Yunhai Guochuang Cloud Computing Equipment Industry Innovation Co., Ltd., Beijing 100095, China 3.Beijing Smartchip Microelectronics Technology Co., Ltd., Beijing 102200, China)

Abstract: To address the issue of significant positioning errors caused by non-line-of-sight (NLOS) propagation and other interference factors in wireless localization technologies, this paper proposes a machine learning based collaborative localization method for unmanned aerial vehicle (UAV) swarms. Firstly, a localization model for UAV clusters is established, and a time difference of arrival (TDOA) based localization algorithm is utilized to eliminate clock deviations between UAVs and the target. Then, a line-of-sight/non-line-of-sight (LOS/NLOS) classification model is constructed using a support vector machine (SVM), which distinguishes LOS and NLOS signals by analyzing characteristic parameters of received signals. Finally, based on the classification results, a feature selection based NLOS mitigation algorithm is applied to filter samples suitable for target localization calculation. Simulation results demonstrate that the proposed method effectively reduces NLOS induced errors and enhances the robustness of the localization algorithm.

Keywords: unmanned aerial vehicle swarm; collaborative localization; machine learning; NLOS error; support vector machine; time difference of arrival

0 引言

近年来, 无人机技术飞速发展, 因其具有低成本、高机动性等特点, 被广泛应用于目标跟踪、抢险救灾、

战场察打等领域。无人机集群编队通过机间信息协同交互, 能更精确、高效地执行复杂任务。无线定位技术无需携带复杂硬件, 机动性高、可扩展性强, 灵活

适配于各规模形态的无人机集群应用场景。

根据无人机定位所采用的接收信号特征参数不同,常用的无线定位算法分为:1) 基于到达时间(time of arrival, TOA)的定位算法,通过测量信号的传播时间来计算无人机与目标的距离,从而实现目标定位,但该算法的实现需确保收发两端保持严格的时间同步^[1]; 2) 基于到达角度(angle of arrival, AOA)的定位算法,通过测量无人机与目标的入射角来估计目标位置坐标,但该算法的前提是假设信号沿直线传播,不考虑信号发生折射或反射的情况,且对基础硬件要求严格,导致成本增加^[2]; 3) 基于到达时间差(time difference of arrival, TDOA)的定位算法,通过测量无人机与目标之间信号传播的时间差来计算距离,并利用多条双曲线的交点确定目标位置。该算法无需无人机与目标之间的时钟精确同步,消除了时钟偏差,解决了 TOA 定位算法需要收发两端严格的时钟同步问题;系统复杂度较低,相比 AOA 定位算法实现成本更低,可靠性更高;且便于观测、易组网,适合集群作战^[3]。为此,本文采用 TDOA 定位算法实现无人机集群定位。

但在实际应用中,建筑物和树木等障碍物会影响无线信号的直线传播,从而形成非视距(non-line-of-sight, NLOS)信号,影响目标定位精度。因此,如何准确识别 LOS 与 NLOS 信号,并对 NLOS 信号进行抑制或消除,是一个值得研究的课题。NLOS 信号的识别方法主要有:1) 基于统计特征的 NLOS 信号识别方法,文献[4]将基站与目标间的距离与 LOS/NLOS 信号概率分布相结合,利用误差的概率分布模型进行最大似然估计,提高了 NLOS 信号的识别准确率,但该方法依赖信号传输的先验数据,在实际应用中存在困难;2) 基于残差的 NLOS 信号识别方法,文献[5]通过基站的 TOA 和 AOA 定位算法估计目标位置,并与判决门限进行比较,从而判断是否包含 NLOS 信号,该方法不依赖于信号传输的先验数据,对 NLOS 信号的识别准确率较高,但计算量大,算法复杂度高;

3) 基于机器学习的 NLOS 信号识别方法,将 NLOS 信号识别看作分类问题,并采用机器学习的方法来求解,文献[6]提出一种基于卷积神经网络的 NLOS 信号识别方法,利用小波变换分析信号的时频域,能够较准确地识别 NLOS 信号,但计算复杂且不适用于移动场景;文献[7]通过提取接收信号的特征,利用支持向量机(support vector machine, SVM)对 LOS 与 NLOS 信号进行分类,分类准确率较高。

本文利用 SVM 对 LOS 与 NLOS 信号进行分类,并优先采用 LOS 信号进行目标定位。当 LOS 信号不足以实现精确定位时,可采用 Fisher Score 算法对 NLOS 信号进行特征选择与权值计算,最大限度地降低 NLOS 信号的影响,以保证目标的定位精度。

1 无人机集群定位模型

设一个无人机集群共包含 N 架无人机,坐标位置为 (x_i, y_i, z_i) , $i \in [0, N-1]$,目标坐标为 (x, y, z) ,则第 i 架无人机到目标的距离为

$$d_i = \sqrt{(x_i - x)^2 + (y_i - y)^2 + (z_i - z)^2} \quad (1)$$

假设该无人机集群中所有无人机的时钟同步,与目标有 Δt 的时钟偏差,那么第 i 架无人机发送信号至目标的时间为

$$t_i = \hat{t}_i + \Delta t \quad (2)$$

式中: t_i 为第 i 架无人机信号到达目标的实际时间, $\hat{t}_i$ 为第 i 架无人机信号到达目标的估计时间。

令第 i, j 架无人机分别为双曲线的两个焦点。根据双曲线上任意一点到两个焦点的距离差为固定值的特性,若目标位于双曲线上,就可以利用这一特性抵消 Δt 的影响。

$$d_j - d_i = c(\hat{t}_j + \Delta t) - c(\hat{t}_i + \Delta t) = c(\hat{t}_j - \hat{t}_i) \quad (3)$$

新增一架无人机 k ,与无人机 i 构成一组新的双曲线。在二维场景下,通过计算两组双曲线的交点即可确定目标位置。同理,在三维场景下,至少需要 4

架无人机，才能定位目标位置。

TDOA 定位算法虽然能够有效补偿系统硬件时钟偏差导致的 LOS 误差，但测量信号中若包含 NLOS 误差，则会导致定位精度大幅下降。因此，抑制或消除 NLOS 误差，是研究人员关注的重要课题。

2 LOS/NLOS 分类模型

目前，抑制 NLOS 误差的方法主要分为两类：一类是直接对测量数据进行补偿，使其更接近真实距离，以降低 NLOS 误差的影响；另一类是通过识别接收信号的某一特征参数，判断测量数据中是否包含带有 NLOS 误差的信号，并将其剔除，因此需对 LOS 与 NLOS 信号进行区分。本文利用 SVM 构建 LOS/NLOS 分类模型。

SVM 是一种常用的分类算法，适合解决小样本问题^[8]。其以统计学习理论为基础，以最小化结构风险为准则，在特征空间中构造一个最优超平面，使所有样本到达该平面的距离最大。

假设第 i 架无人机的特征向量 $\mathbf{s}_i$ 为 m 维，LOS 与 NLOS 样本的标签 y 分别为 1、-1，则期望求得一个最优超平面 $\mathbf{w}^T \mathbf{s} + b = 0$ ，使每个样本到达该平面的距离最大，即满足以下关系：

$$\begin{cases} \mathbf{w}^T \mathbf{s}_i + b \geq 1, y_i = 1 \\ \mathbf{w}^T \mathbf{s}_i + b \leq -1, y_i = -1 \end{cases} \quad (4)$$

即

$$y_i(\mathbf{w}^T \mathbf{s}_i + b) \geq 1 \quad (5)$$

则构造最优超平面可以看作求解如下问题：

$$\min \frac{1}{2} \|\mathbf{w}\|^2 \quad (6)$$

$$\text{s.t. } y_i(\mathbf{w}^T \mathbf{s}_i + b) \geq 1 \quad (7)$$

然而，并非所有的 LOS 与 NLOS 样本都是线性可分的，为此引入松弛变量 ξ_i ，则 SVM 的代价函数可重写为

$$J_{\text{SVM}}(\mathbf{W}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \quad (8)$$

求解代价函数(6)最小时的 $\mathbf{w}$ ，即

$$\min J_{\text{SVM}}(\mathbf{W}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \quad (9)$$

$$\text{s.t. } \hat{y}_i \cdot (\mathbf{w}^T \mathbf{s}_i) \geq 1 - \xi_i \quad (10)$$

$$\xi_i \geq 0 \quad (11)$$

公式(9)~(11)是一个凸二次规划问题，因此关于 $(\mathbf{w}, b, \xi)$ 的解是存在的。其拉格朗日函数为

$$L(\mathbf{w}, b, \xi, a, \gamma) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N a_i [1 - y_i (\mathbf{w}^T \mathbf{s}_i + b) + \xi_i] - \sum_{i=1}^N \gamma_i \xi_i \quad (12)$$

式中： a 、 γ 为拉格朗日乘子。

求解 $L(\mathbf{w}, b, \xi, a, \gamma)$ 对 $\mathbf{w}$ 、 b 、 ξ 的极小值，得到

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N a_i y_i \mathbf{s}_i = 0 \quad (13)$$

$$\frac{\partial L}{\partial b} = -\sum_{i=1}^N a_i y_i = 0 \quad (14)$$

$$\frac{\partial L}{\partial \xi} = C - a_i - \gamma_i = 0 \quad (15)$$

将公式(13)~(15)的计算结果代入拉格朗日函数公式(12)，并求其极大值，即得到原始问题的对偶问题：

$$\max -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (\mathbf{s}_i \cdot \mathbf{s}_j) + \sum_{i=1}^N a_i \quad (16)$$

$$\text{s.t. } \sum_{i=1}^N a_i y_i = 0 \quad (17)$$

$$0 \leq a_i \leq C, i = 1, 2, \dots, N \quad (18)$$

当拉格朗日乘子 a 有非唯一解时, 设 a^* 为其中一组解, 则可以求得对应的超平面参数为

$$w^* = \sum_{i=1}^N a_i^* y_i s_i \quad (19)$$

$$b^* = y_i - \sum_{i=1}^N a_i^* y_i (s_i \cdot s_j) \quad (20)$$

3 基于特征选择的 NLOS 抑制算法

LOS 与 NLOS 信号的无线信道特征(均值、标准差、最大振幅、偏度、峰均比和上升时间等)存在明显的差异。因此, 基于无线信道特征构建的特征向量, 可用于 LOS 与 NLOS 信号分类。然而, 特征向量维数过多会导致计算量过大, 延长训练时间; 还可能由于某些特征向量差异不明显对分类效果产生影响。因此, 本文利用 Fisher Score 算法筛选特征表现较强的无线信道特征, 构建特征向量。

Fisher Score 是一种特征选择算法, 其认为类内距离尽可能小, 类间距离尽可能大的特征具有较强的特征表现^[9]。

设 x^k 为样本集合 C 中样本 x 的特征向量的第 k 个特征值; x_i^k 为分类 i 的样本 x 的特征向量的第 k 个特征值; n_i 为分类 i 的样本数量; m^k 为所有样本的第 k 个特征值的平均值; m_i^k 为 i 类中所有样本的第 k 个特征值的平均值, 其中, i 为 0 和 1 分别表示 LOS 信号类和 NLOS 信号类, 那么, 第 k 个特征的类间方差为

$$S_B^k = \sum_{i=1}^C n_i (m_i^k - m^k)^2 \quad (21)$$

第 k 个特征的类内方差为

$$S_W^k = \sum_{i=1}^C (x_i^k - m_i^k)^2 \quad (22)$$

第 k 个特征的 Fisher 得分为

$$S_{\text{score}}(k) = \frac{S_B^k}{S_W^k} \quad (23)$$

将每个特征值的 Fisher 得分由大到小排序, 保留前 m 个特征值构建特征向量。此特征向量用于 SVM 分类模型训练及 NLOS 样本的筛选。

设 NLOS 样本的特征向量为 $[a_1, \dots, a_m]$, 第 k 个特征 a_k 与 LOS 样本的第 k 个特征值的均值 m_0^k 之差为

$$d_k = |a_k - m_0^k| \quad (24)$$

此 NLOS 样本得分为

$$a_{\text{score}} = \sum_{k=1}^m \lambda_k d_k \quad (25)$$

式中: λ_k 为加权系数, 其取值与 $S_{\text{score}}(k)$ 相关。

a_{score} 越小, 表示 NLOS 样本与 LOS 样本越接近。

对所有 NLOS 样本进行 Fisher 得分计算, 优先选择 a_{score} 较小的 NLOS 样本参与目标定位计算。

4 仿真结果及分析

本仿真利用基于特征选择的 NLOS 抑制算法筛选出参与目标定位计算的 NLOS 样本, 并通过 TDOA 算法计算目标的位置坐标。仿真测试环境: CPU 为 Intel(R) Core(TM) i5-10210U 1.60 GHz 处理器, Windows 11 64 位操作系统, MATLAB R2019a 仿真平台。

4.1 NLOS 样本占比对分类模型识别准确率的影响

LOS/NLOS 分类模型的作用是尽可能地将测量误差较大的 NLOS 信号分离出来, 以避免其参与目标定位, 因此分类误差越小越好。分类误差计算公式为

$$E_{\text{error_rate}} = \frac{FP + FN}{TP + TN + FP + FN} \quad (26)$$

式中: FP 、 FN 分别为 LOS 与 NLOS 样本被错误分类的个数, TP 、 TN 分别为 LOS 与 NLOS 样本被正确分类的个数。

在实际应用场景中, LOS 与 NLOS 信号是混合的, 因此仿真采用不同 LOS 与 NLOS 比例的测试样

本, 测试不同 NLOS 样本占比对识别准确率的影响。每组测试样本由目标 $\pm 40 \text{ m} \times 40 \text{ m}$ 区域内随机生成的 5 000 个坐标点组成。在初始状态下, 测试样本中不含 NLOS 样本。随着测试次数的增加, NLOS 样本占比以每次 2% 的梯度递增, 分别计算每组测试样本的识别准确率, 结果如图 1 所示。




图 1 NLOS 样本占比对分类模型识别准确率的影响

由图 1 可以看出, 随着测试样本中 NLOS 样本占比的增加, LOS/NLOS 分类模型的识别准确率总体呈下降趋势。这是因为 NLOS 样本占比越高, 被误判为 LOS 样本的概率就越大, 从而导致模型的整体识别准确率降低。

4.2 NLOS 样本占比对定位误差的影响

在参与目标定位计算的数据中, NLOS 样本占比会对定位误差产生较大影响。本文以累积分布函数 (cumulative distribution function, CDF) 为评估指标, 对 LOS/NLOS 分类模型的定位性能进行评价。

对离散数据而言, CDF 是概率密度函数 (probability density function, PDF) 求和的结果, 其定义为所有定位误差值小于等于某个门限值的数据出现的概率之和。

$$F_X(a) = P(X \leq a) \quad (27)$$

假设一个无人机集群中共有 10 架无人机, 其中

K 架无人机为 NLOS 样本, $10-K$ 架无人机为 LOS 样本。首先, 通过 LOS/NLOS 分类模型识别其中的 NLOS 样本; 然后, 利用基于特征选择的 NLOS 抑制算法筛选参与目标定位计算的 NLOS 样本; 最后, 采用 TDOA 定位算法得到目标定位坐标, 计算目标定位坐标与实际坐标的距离差, 即为距离估计误差。

无人机集群中 NLOS 样本占比不同时, 距离估计误差的 CDF 曲线如图 2 所示。




图 2 NLOS 样本占比不同时距离估计误差的 CDF 曲线

由图 2 可以看出, 随着 NLOS 样本占比的增加, 距离估计误差越小的样本在总样本量中的占比越低; 当 NLOS 样本占比分别为 10%、30%、60% 时, 距离估计误差小于 2 m 的样本占比分别为 79.6%、75.6%、64.3%, 表明当 NLOS 样本占比增加时, LOS/NLOS 分类模型的识别准确率会随之降低, 增加了 NLOS 样本被误判为 LOS 样本, 并参与目标定位计算的概率, 进而导致定位误差变大。

4.3 算法定位性能比较

当 NLOS 样本占比为 60% 时, 分别利用基于特征选择的 NLOS 抑制算法筛选的样本与随机抽取的样本进行目标定位计算, 对比两者的定位误差。仿真结果如图 3 所示。




图3 NLOS样本占比60%时不同算法的CDF曲线

由图3可以看出,当NLOS样本占比为60%时,利用基于特征选择的NLOS抑制算法(本文算法)、随机抽取样本进行目标定位计算的定位误差在15m内的样本占比分别为94.8%、60.4%,这是因为在NLOS样本占比较高时,随机抽取样本进行目标定位计算几乎无法有效避免NLOS样本的影响,因此对NLOS样本进行分类与筛选,可提升算法的定位精度。

5 结论

本文主要研究了无人机集群协同定位方法,选用TDOA算法构建无人机集群定位模型,利用SVM构建LOS/NLOS分类模型,采用Fisher Score特征选择方法筛选参与定位的样本。仿真结果表明,随着NLOS样本占比的增加,分类模型的识别准确率降低;定位误差增大,算法精度也相应下降。

本文在仿真过程中假设NLOS误差服从均匀分布,在训练及测试过程中使用的NLOS样本均基于此生成,是一种比较理想的状态。然而在实际应用场景中存在各种信号干扰,NLOS误差可能服从其他分布模型。因此,在后续的工作中,考虑通过采集的真实信号对定位算法进行优化。

作者简介:

刘雅宁,女,1989年生,硕士研究生,工程师,主要研究方向:无人系统及通信算法。E-mail: liuxiaoduoduo@qq.com

卢浩,男,1984年生,博士研究生,研究员,主要研究方向:无人系统、人工智能及信号处理。

程彦汇,男,1987年生,本科,工程师,主要研究方向:通信工程及电路设计。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

参考文献

- [1] PETUKHOV N, CHUGUNOV A, ZAMOLODCHIKOV V, et al. Synthesis and experimental accuracy assessment of Kalman filter algorithm for UWB ToA local positioning system[C]. 2021 3rd International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), 2021:1-4.
- [2] FOKIN G. AOA measurement processing for positioning using unmanned aerial vehicles[C]//2019 IEEE International Black Sea Conference on Communications and Networking (Black-SeaCom), 2019:1-3.
- [3] ZHAO K, ZHAO T, ZHENG Z, et al. Optimization of time synchronization and algorithms with TDOA based indoor positioning technique for internet of things[J]. Sensors, 2020,20(22): 6513-6513.
- [4] SHI X, MAO G, YANG Z, et al. Localization algorithm design and performance analysis in probabilistic LOS/NLOS environment[C]//2016 IEEE International Conference on Communications(ICC). IEEE, 2016:1-6.
- [5] HUA J Y, YE J Y, WEI D L, et al. NLOS identification and positioning algorithm based on localization residual in wireless sensor networks[J]. Sensors, 2018,32(18):1-12.
- [6] CUI Z C, GAO Y F, HU J, et al. LOS/NLOS identification for indoor UWB positioning based on Morlet wavelet transform and convolutional neural networks[J]. IEEE Communications Letters, 2020,25(3):879-882.
- [7] MARANÒ S, GIFFORD W M, WYMEERSCH H, et al. NLOS identification and mitigation for localization based on UWB experimental data[J]. in IEEE Journal on Selected Areas in Communications, 2010,28(7):1026-1035.
- [8] SAUNDERS C, STITSON M O, WESTON J. Support vector machine[J]. Computer Science,2002,1(4):1-28.
- [9] SUN L, WANG T, DING W, et al. Feature selection using Fisher score and multilabel neighborhood rough sets for multilabel classification[J]. Information Sciences, 2021,578:887-912.