

DOI:10.19651/j.cnki.emt.2210501

# 基于 KNN 和 XGBoost 的室内指纹定位算法<sup>\*</sup>

卢海钊<sup>1</sup> 彭慧豪<sup>1</sup> 唐滔<sup>2</sup> 王守峰<sup>2</sup> 张烈平<sup>1</sup>

(1. 桂林理工大学机械与控制工程学院 桂林 541004; 2. 桂林理工大学南宁分校电气与电子工程系 南宁 532100)

**摘要:** 针对 KNN 算法定位精度有待提高以及定位稳定性较差的问题,本文提出了一种基于 KNN 算法和 XGBoost 算法的室内指纹定位算法。该算法首先将样本集划分为训练集和测试集,将训练集中 AP 的 RSSI 数据作为特征,坐标作为标签,使用 XGBoost 算法进行建模。其次,融合 KNN 模型,将 KNN 算法寻找到的近邻集合引入 XGBoost 模型中,再结合单独 XGBoost 算法的预测结果,以实现坐标定位。最后,在实际环境下研究了算法的 K 值、回归树数量、决策树深度和学习率对误差的影响,确定算法的相关参数。通过搭建的实际实验环境进行了测试,实验结果表明,本文提出算法的平均定位误差为 1.55 m,较于 KNN 算法和 XGBoost 算法分别减少了 24.76% 和 11.93%,并且累积分布函数曲线的收敛速度更快,具有较好的定位性能。

**关键词:** 室内指纹定位;KNN;XGBoost;WiFi 定位

**中图分类号:** TP181 **文献标识码:** A **国家标准学科分类代码:** 520.2

## Indoor fingerprint localization algorithm based on KNN and XGBoost

Lu Haizhao<sup>1</sup> Peng Huihao<sup>1</sup> Tang Tao<sup>2</sup> Wang Shoufeng<sup>2</sup> Zhang Lieping<sup>1</sup>

(1. School of Mechanical and Control Engineering, Guilin University of Technology, Guilin 541004, China;

2. Department of Electrical and Electronic Engineering, Guilin University of Technology at Nanning, Nanning 532100, China)

**Abstract:** This paper proposes an indoor fingerprint localization algorithm based on KNN and XGBoost algorithm to address the problems that the localization accuracy of KNN algorithm needs to be improved and the stability of localization is poor. The algorithm first divides the sample set into a training set and a test set, RSSI data of AP in training set was used as features and coordinates were used as labels, and XGBoost algorithm was used for modeling. Secondly, the KNN model is integrated, the nearest neighbor set found by KNN algorithm is introduced into XGBoost model, and combined with the prediction results of individual XGBoost algorithm to achieve coordinate positioning. Finally, the effects of the algorithm's K-value, number of regression trees, decision tree depth and learning rate on the error are investigated in a practical setting to determine the relevant parameters of the algorithm. The experimental results show that the average localization error of the proposed algorithm is 1.55 m, which is 24.76% and 11.93% less than that of the KNN algorithm and XGBoost algorithm, respectively, and the cumulative distribution function curve converges faster and has better localization performance.

**Keywords:** indoor fingerprint localization;KNN;XGBoost;WiFi localization

## 0 引言

随着 5G 通讯技术和物联网技术的飞跃发展,基于位置服务的室内定位技术在大型商超、机场、火车站等大型室内场景中发挥了至关重要的作用<sup>[1]</sup>。目前常用的室内定位技术有 RFID、超声波、UWB、WiFi 等。在这些定位技术中,由于 WiFi 信号具有传输距离远、成本低、保真度高的优势,在大多数环境中 WiFi 布置比较完善,容易获取 WiFi 信

号。因此,Wi-Fi 室内定位技术已成为如今课题研究的热点。与传统的几何定位技术不同,指纹定位技术能很好地利用反射折射形成的信号信息,建立测量接收信号强度(received signal strength, RSS)与位置关系的数据库,通过匹配待定位点指纹信息来实现定位<sup>[2]</sup>。研究发现,基于 WiFi 的指纹定位算法对复杂环境有较好的适应性,尤其是在室内定位存在大量非视距场景的情况下,算法具有定位精度高、复杂度低的优势<sup>[3]</sup>。

收稿日期:2022-06-28

<sup>\*</sup> 基金项目:国家自然科学基金(61741303);广西空间信息与测绘重点实验室基金(19-185-10-08)项目资助

近些年来,机器学习技术得到了飞快的发展,机器学习所具备独特的高纬度的建模能力,解决了很多经典定位模型在一些复杂场景下难处理的问题<sup>[4]</sup>。吴泽泰等<sup>[5]</sup>改进相似度计算公式,针对 KNN 算法在应用过程中计算量较大的问题,将 KNN 和聚类思想进行融合优化。吴耿楠<sup>[6]</sup>对指纹定位中离线阶段对数据进行整理以及对数据的特征进行重构,对于多分类模型和二分类模型,分别提出了 KNN 修正框架和 Stacking 融合的方法来进行优化。Yadav 等<sup>[7]</sup>引入了一种用于智能手机的具有传感器和蓝牙低功耗 (bluetooth low energy, BLE) 信标的新型定位系统。系统的可信 K 近邻贝叶斯估计 (trusted K nearest Bayesian estimation, TKBE) 集成了 BLE 信标和行人航位推算定位以提高定位精度。卢一帆等<sup>[8]</sup>根据 WiFi 信号强度在不同位置分布不同的原理,并根据该特性使用 XGBoost 算法来对信号源进行定位。潘维蔚等<sup>[9]</sup>利用线性判别算法在低维情况下进行排列组合,对所得的若干个概率值求和,通过门限设置约束,以提高相邻网格定位的准确率。Bundak 等<sup>[10]</sup>在定位研究中,使用了聚类方法优化 MF (magnetic field, MF) RPs (reference points, RPs) 数据库,将每个训练的 RP 和其他附近的 RP 在一定距离处聚集在一起后创建了一个等级聚类算法,将具有最近欧几里德距离的前 10 个等级 RP 与带有 RP 聚类的 TP 进行匹配,采用平均欧几里得算法来找到最终的估计位置。周楚霖等<sup>[11]</sup>在改进 WiFi 和 PDR 定位的基础上,提出使用无迹粒子滤波融合定位方法,并对粒子滤波进行抗差自适应优化,提高定位精度。

综上所述,机器学习算法应用在室内指纹定位中,在使用时极为便利,只需要依赖信号强度等信息,就能预测出目标位置的坐标值。但是,目前研究的算法普遍采用单一的机器学习算法来实现室内定位预测,在进行定位时,易受到噪声信号以及信号间的相互干扰,导致定位精度的降低,定位性能仍有待提高<sup>[12]</sup>。针对这些问题,本文提出了一种基于 KNN 和 XGBoost 的室内指纹定位算法,可以在不增加数据采集样本的前提下,改善室内定位精度,有效提高室内定位的性能。

## 1 KNN 算法和 XGBoost 算法介绍

### 1.1 KNN 算法

K 近邻 (K nearest neighborhood, KNN) 算法,是一种不需要训练参数的智能分类算法。假设在指纹定位的离线阶段,共布置了 L 个指纹点,即这 L 个指纹可被记为  $\{F_1, F_2, \dots, F_L\}$ , 另外这 L 个指纹对应的坐标被记为  $\{L_1, L_2, \dots, L_L\}$ 。指纹库建立完成后,把待测位置的指纹记为 S, 为所有的 AP 多次测量后所取得的 RSS 的平均值,即  $S = \{s_1, s_2, \dots, s_n\}$ 。在存储的过程中,指纹都采取了  $F_i = \{r_1^i, r_2^i, \dots, r_n^i\}$  的形式,其中分别表示为第 i 个指纹中分别采取的第 1~n 个 AP 点的值。通过采用如式(1)所示的欧氏距离或者如式(2)所示曼哈顿距离,可以得到待测

位置的指纹 S 的坐标与离线指纹库中收集到的数据之间的距离差。

$$\omega_1 = \sqrt{\sum_{i=1}^n (s_i - r_i)^2} \quad (1)$$

$$\omega_2 = \sum_{i=1}^n |s_i - r_i| \quad (2)$$

其中, n 表示第 n 个 AP,  $s_i$  为预测值,  $r_i$  为实际值。

在完成上述步骤以后,可以根据距离的大小,选取其中的最小值来作为估算位置,求取其平均值来得到最终的结果,如式(3)如下:

$$L = (\hat{x}, \hat{y}) = \frac{1}{K} \sum_{i=1}^k (x_i, y_i) \quad (3)$$

其中, K 表示取得 K 个近邻点,  $(x_i, y_i)$  表示 K 个近邻点的每个点的标。

利用 KNN 算法对目标样本做预测时,需要对目标样本和所有训练样本之间的距离进行计算<sup>[13]</sup>。当训练样本较大时, KNN 法会因为巨大的计算量而产生较大的误差。而 XGBoost 梯度提升树模型具有可解释性强,计算简单,可以较好的处理有缺失属性值的样本的特点,可以应用到 KNN 邻近集合的优化。

### 1.2 XGBoost 算法

极限梯度提升 (extreme gradient boosting, XGBoost) 是陈天奇提出的一种以梯度提升为框架,从 GBDT 发展而来的集成算法<sup>[14]</sup>。主要思想是:通常一个基模型很难保障预测精度,通过集成的思想将多个树的预测结果集成后输出, XGboost 算法的主要思想如下:

假如一个模型中共有 k 棵决策树,每个决策树上都会设定一个叶子权重的参数,使用过程中一般用  $f_k(x_k)$  或者  $\omega_j$  来表示, XGBoost 模型在样本 i 上的预测结果如式(4)所示。

$$\hat{y}_i^{(k)} = \sum_{k=1}^K f_k(x_i) \quad (4)$$

其中,  $f_k(x_k)$  表示为某棵树上的回归取值,  $x_i$  表示为样本 i 对应的特征向量,  $f_k$  表示为第 k 棵决策树。XGBoost 集成学习算法的主要步骤如下:

目标函数一般表达为如式(5)所示的形式,在式(5)中包括了正则化和训练损失两部分。

$$\Phi = \sum_{i=1}^n l(y_i, \hat{y}_i) + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (5)$$

在式(5)中,  $\sum_{i=1}^n l(y_i, \hat{y}_i)$  为损失函数, n 为样本数量。

公式中的后半部分  $\gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2$  表示的是 XGBoost 模型中的正则化部分,决定了树的深度 (max\_depth)。其中在正则化部分,  $\gamma$  表示正则化参数,即叶子数量增加时被去掉的惩罚项;  $\frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2$  表示叶子节点权重的最小平方误差,其中  $\lambda$  表示正则化参数; T 表示叶子节点的个数;  $\omega_j$  表示第 j 个叶子节点的叶子权重。

式(6)中的  $\hat{y}_i^{(k-1)}$  是所有树的迭代结果。故在第  $k$  次迭代时,  $\hat{y}_i^{(k)}$  可以等同为  $\hat{y}_i^{(k-1)} + f_k(x_i)$ 。因此,该模型的目标函数  $\phi_{(k)}$  如式(6)所示。

$$\phi_{(k)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(k-1)} + f_k(x_i)) + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (6)$$

其中,  $f_k(x_i)$  表示为树第  $k$  次迭代的结果。

将目标函数泰勒展开后,可以将目标函数可以简化为如式(7)的形式:

$$\phi_{(k)}^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j}{H_j + \lambda} + \gamma T \quad (7)$$

式中:  $G_j = \sum_{i=I_j} g_i, H_j = \sum_{i=I_j} h_i$ 。  $I_j$  代表第  $j$  棵树的每个样本集合。

在 XGBoost 建树的过程,还使用了贪心算法来遍历树模型的所有分裂子节点,挑选分裂后目标函数增益最大的叶子节点再进行分裂。假如设置  $I_L$  和  $I_R$  是在进行分枝后,分枝两边的子枝点含有的数据集,分裂前的目标函数如式(8)所示。

$$Obj_1 = -\frac{1}{2} \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} + \gamma \quad (8)$$

分裂后的目标函数如式(9)所示。

$$Obj_2 = -\frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} \right] + 2\gamma \quad (9)$$

分裂后的增益如式(10)所示。

$$Gain = \frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (10)$$

综上所述,树的数量、深度和学习率的选择都会对最后的预测结果有很大的影响。

## 2 基于 KNN 和 XGBoost 的室内指纹算法

### 2.1 算法设计思想

针对不同算法在不同场景中的预测效果往往存在较大的差异,提出了一种充分利用不同算法优势的融合模型,来提高模型的精度和泛化能力<sup>[15]</sup>。KNN 算法在处理样本数量差距较大的时候,只计算样本数量较多的类的邻居节点,忽略了样本数量少的节点信息,会出现数据丢失的情况,导致误差变大<sup>[16]</sup>。而梯度提升树模型具有:计算简单,可解释性强的优点,比较适合处理有缺失属性值的样本,适用于复杂多变的室内环境。因此,提出了同时保留 KNN 和 XGBoost 各自优势的 KNN+XGBoost 算法。首先将样本集划分为训练集和测试集,将训练集中各个 AP 的 RSSI 数据作为特征,将坐标作为标签,使用 XGBoost 算法对进行建模。随后,融合 KNN 模型,将 KNN 算法寻找到的近邻集合引入到 XGBoost 模型中,进而纠正单独 XGBoost 算法的预测结果,以提高坐标定位的性能,算法思想如图 1 所示。

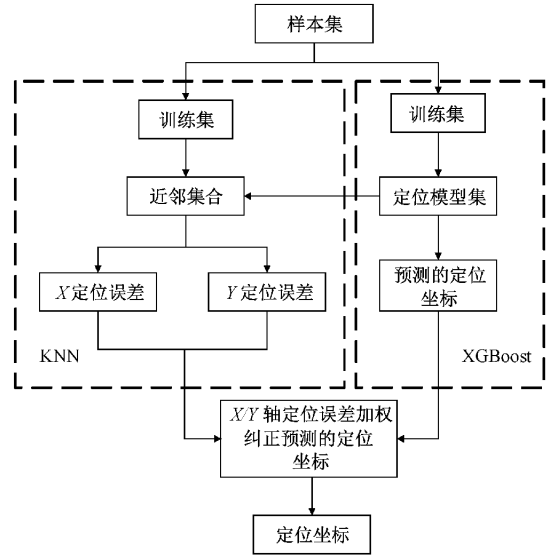


图 1 基于 KNN 和 XGBoost 的算法融合模型

### 2.2 算法步骤

基于 KNN 和 XGBoost 的室内指纹定位算法,具体步骤如下:

步骤 1)在离线阶段,首先需要收集指纹信息,建立数据库。在实验场景中共布置了  $n$  个指纹采集点。在室内环境下,第  $i$  个 RP 第  $j$  次采集 AP 发出的信号强度值可以建立一条指纹数据,其 AP 特征可被记作如式(11)所示的形式:

$$r^{ij} = (RSSI_{i1}, RSSI_{i2}, \dots, RSSI_{ij}) \quad (11)$$

其中,  $r^{ij}$  为第  $i$  个 RP 采集  $j$  次共采集到的 RSSI 值。由  $n$  个指纹参考点的 RSSI 信号所组成的原始指纹数据库为:

$$S = (r^1, r^2, \dots, r^n) \quad (12)$$

其中,  $r^i = (r^{i1}, r^{i2}, \dots, r^{ij})$ , 表示第  $i$  个 RP 所采集到的所有指纹数据信息。

步骤 2)对收集到的数据进行预处理,将离线指纹数据库中的数据进行归一化处理,如式(13)所示。然后通过高斯滤波处理收集到的离线指纹数据库。

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

步骤 3)采用 XGBoost 作为基础模型,分别使用各个 AP<sub>i</sub> 的数据进行建模,根据建立的模型可以得到一个最初的坐标的估计值。如式(14)所示,并分别计算 XGBoost 下的模型在测试样本上的坐标预测值  $(\hat{x}, \hat{y})$ 。

$$C_i = f_i(AP_{ij}, x, y) \quad (14)$$

步骤 4)采用 KNN 算法训练测试样本集中的每一个样本,从而找到每个样本的近邻集合 K,然后再根据 XGBoost 算法建立的基模型,在近邻集合中进行预测,完成对 KNN+XGBoost 模型的搭建。通过式(15)计算出模型集合在 KNN 上的 X、Y 的训练误差  $\epsilon_x = \{\epsilon_1, \epsilon_2, \dots, \epsilon_n\}, \epsilon_y =$

$\{\epsilon_1, \epsilon_2, \dots, \epsilon_n\}$ 。

$$E = KNN(f_1, f_2, \dots, f_n) \quad (15)$$

步骤 5) 预测模型集合是  $P = \{P_1, P_2, \dots, P_m\}$ , 对于每个要预测的  $Y_i$ , 在邻近集合应用模型进行预测识别训练误差。随后, 使用训练误差对于各个预测模型赋予权重,

$$w_i = 1/RMSE_i \quad (16)$$

其中, RMSE 是基于选定的近邻数据集计算的。

步骤 6) 根据在步骤 5) 中获得的权重值, 再融合不同 XGBoost 模型的预测结果, 最终返回到坐标预测值  $(\hat{x}, \hat{y})$ 。

### 3 实验与结果分析

#### 3.1 实验环境

实验采用 MERCURY-MW305R 路由器作为发射端, 一台安装自主开发的 RSSI 信息采集软件的手机作接收器, 电脑 CPU 为 Intel Core i5-6300HQ, 操作系统为 Windows 10 专业版。模拟实验中使用的实验室区域面积约为  $5\text{ m} \times 10\text{ m}$ , 在定位区域内, 部署 5 个距离地面高度约为  $0.8\text{ m}$  的 AP 位置如图 2 箭头所示。把实验区域网格化, 实验环境内分布有 100 个参考点, 在每个节点分别采集 5 个 WiFi 热点的 RSSI 值, 对 RSSI 值高斯滤波处理后求均值, 建立指纹数据库。


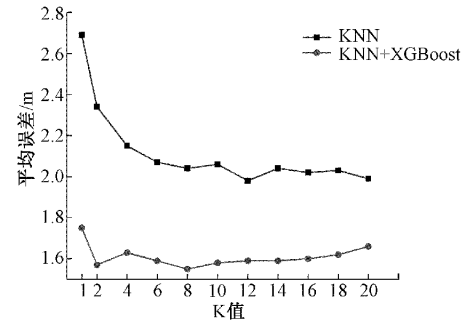


图 2 实验环境实景图

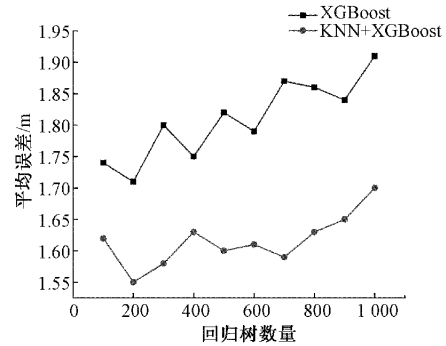
#### 3.2 算法参数研究及优选

不同的参数对算法的效果影响不同, 基于各个参数的经验区间。研究了模型的 K 值、回归树数量、决策树深度和学习率对误差的影响, 分别在实验中进行了 50 次实验, 并选取了其中的平均值进行分析, 具体实验结果如图 3 所示。


在图 3(a)中, K 值在 1~20 之间变化时, KNN 算法的平均定位误差在范围  $1.98 \sim 2.69\text{ m}$  之间波动, 整体波动 26.39%。KNN 和 XGBoost 算法的平均定位误差在范围  $1.55 \sim 1.75\text{ m}$  之间波动, 整体波动 11.43%, 较于 KNN 算法, 稳定性提高了 14.96%。在图 3(b)中, 回归树数量的值在  $100 \sim 1\,000$  之间的变化时, XGBoost 算法的平均定位误差在范围  $1.71 \sim 1.91\text{ m}$  之间波动, 整体波动 10.47%, KNN 和 XGBoost 的指纹定位算法的平均定位误差在范围  $1.55 \sim 1.70\text{ m}$  之间波动, 整体波动 8.82%, 较于 KNN 算



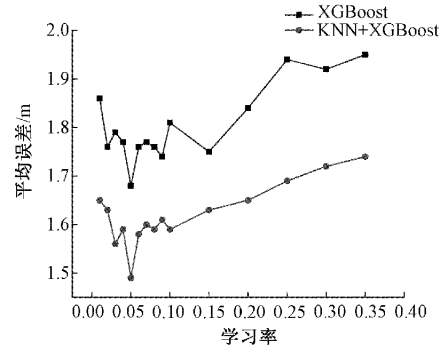
(a) K 值对误差的影响



(b) 树的数量对误差的影响



(c) 树的深度对误差的影响



(d) 学习率对误差的影响

图 3 不同参数对平均误差的影响

法, 稳定性提高 1.65%。在图 3(c)中, 决策树深度的值在 3~10 之间的变化时, XGBoost 算法的平均定位误差在范围  $1.72 \sim 1.88\text{ m}$  之间波动, 整体波动 8.51%。KNN 和 XGBoost 算法的平均定位误差在范围  $1.54 \sim 1.66\text{ m}$  之间波动, 整体波动 7.23%, 较于 KNN 算法, 稳定性提高 1.28%。在图 3(d)中, 学习速率的值在  $0.01 \sim 0.35$  之间的

变化时,XGBoost算法的平均定位误差在范围1.68~1.95 m之间波动,整体波动13.85%,KNN和XGBoost算法的平均定位误差在范围1.49~1.74 m之间波动,整体波动14.37%,较于KNN算法,KNN+XGBoost算法的整体误差有很明显减小,但在稳定性方面二者基本相同,相差0.52%。因此,对于KNN算法、XGBoost算法以及KNN+XGBoost算法的基本参数设置,算法参数分别在K值为12、学习速率为0.05、决策树深度为5、回归树数量为200的时候,算法的定位误差最小,算法总体性能最好。具体参数设置如表1所示。

表1 不同算法的参数设置

算法	参数	参数具体数值
KNN	K	12
	n_estimators	200
XGBoost	max_depth	5
	learning_rate	0.05
	K	12
KNN+XGBoost	n_estimators	200
	max_depth	5
	learning_rate	0.05

### 3.3 定位误差与实验分析

按照算法步骤将本文提出的KNN+XGBoost定位算法,与文献[17]提出的KNN定位算法以及文献[18]提出的XGBoost定位算法进行对比。由图4可以看出,在训练样本数量一定的情况下,KNN定位算法的定位误差在范围2.05~2.15 m之间,XGBoost定位算法的平均定位误差在范围1.70~1.88 m之间。而KNN+XGBoost定位算法的平均定位误差在范围1.53~1.62 m之间。较于KNN算法的定位误差减小了0.43~0.63 m,即相对误差减少了20.98%~29.3%;较于XGBoost算法的定位误差减小了0.08~0.35 m,即相对误差减少了4.71%~18.62%,并且相对于KNN算法和XGBoost算法波动较小,稳定性更高。由图5中累计分布函数图可以看出,基于KNN+XGBoost的室内指纹定位算法在定位误差为5.4 m左右时,就已经实现100%的准确预测室内测试点的实际位置坐标。而KNN算法的概率在这时仅有92%左右,XBoost算法的概率分布定位误差在这时为87%左右。精准定位的概率均低于基于KNN和XGBoost的室内指纹定位算法。且KNN+XGBoost的室内指纹定位算法的CDF曲线具有更快的收敛速度,即该算法在定位时具有相对更小的误差,应用时具有相对更好的性能。

3种算法的平均定位误差的训练结果如表2所示。在训练样本数量一定的情况下,KNN指纹定位算法的平均定位误差为2.06 m,XGBoost指纹定位算法的平均定位误差为1.76 m。而KNN+XGBoost的指纹定位算法的平均定

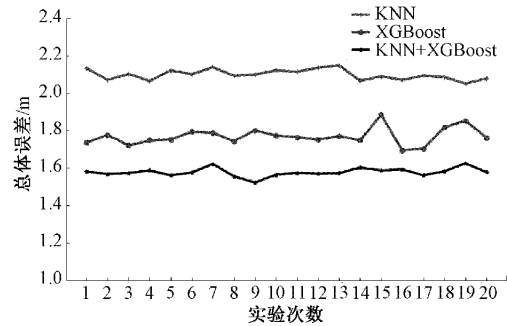


图4 不同算法的总体训练误差图

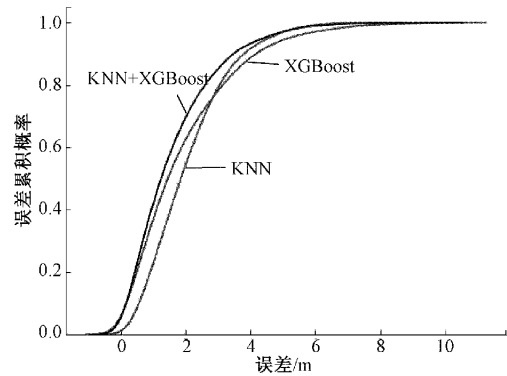


图5 累计分布函数对比图

位误差为1.55 m,较于KNN算法的平均定位误差减小了0.51 m,即相对误差减少24.76%。较于XGBoost算法的平均定位误差减小了0.51 m,即相对误差减少了11.93%。KNN+XGBoost定位算法在处理邻近集合时,采用了XGBoost算法能减少数据缺失的特性,来提高定位精度,加权融合后再纠正XGBoost算法的预测,使最终的预测坐标具有更好的泛化能力。由以上实验可以得出,相对于KNN算法和XGBoost算法,KNN+XGBoost定位算法在定位精度和稳定性方面有一定的优势,在实际应用中有更好的实用性。

表2 不同算法的训练结果

算法	平均误差/m	训练样本数量
KNN	2.06	1 000
XGBoost	1.76	1 000
KNN+XGBoost	1.55	1 000

## 4 结 论

本文提出了一种基于融合思想的KNN+XGBoost的室内指纹定位算法。该算法将XGBoost的特性应用到KNN邻近集合的优化,对两种模型的预测结果纠正后得到样本位置坐标,再分析了算法中K值、回归树数量、决策树深度、学习速率对室内指纹定位精度的影响,并根据这些参数与其他室内定位算法进行了仿真对比。最后,实验结果

验证了本算法的定位精度比传统 KNN 算法和 XGBoost 算法有所提高, KNN + XGBoost 算法的平均定位误差为 1.55 m, 较于单独的 KNN 算法减少 24.76%, 较于单独的 XGBoost 算法减少了 11.93%。同时算法的 CDF 曲线能够更快收敛, 在定位时具有更好的稳定性。能有效提高室内 WiFi 指纹定位的性能。下一步研究的目标是保持高精度并缩短算法在定位时所需的时间。

### 参考文献

- [1] 李新春, 赵忠婷, 于洪仕. 基于局部线性嵌入和梯度提升决策树的信道状态信息室内指纹定位算法研究[J]. 激光与光电子学进展, 2022, 59(2): 400-410.
- [2] 朱清山, 王伟. 基于 SAGA-BP 神经网络室内定位算法[J]. 电子测量技术, 2021, 44(9): 100-104.
- [3] 潘琢金, 郑玮, 杨华. 一种改进的 WiFi 指纹定位算法[J]. 沈阳航空航天大学学报, 2021, 38(5): 66-72.
- [4] 秦飞翔, 朱革兰. 基于 LSTM-CNN 机器学习的配电网故障定位方法[J]. 广东电力, 2021, 34(11): 27-34.
- [5] 吴泽泰, 蔡仁钦, 徐书燕, 等. 基于 K 近邻法的 WiFi 定位研究与改进[J]. 计算机工程, 2017, 43(3): 289-293.
- [6] 吴耿楠. 基于机器学习和 Wi-Fi 信号的室内商铺定位研究[D]. 广州: 广东工业大学, 2019.
- [7] YADAV R K, BHATTARAI B, GANG H S, et al. Trusted K nearest Bayesian estimation for indoor positioning system [J]. IEEE Access, 2019, 7: 51484-51498.
- [8] 卢一帆, 柳伟, 叶福田. 基于 XGBoost 的客户所在店铺 WiFi 定位技术研究[J]. 计算机测量与控制, 2019, 27(7): 141-145.
- [9] 潘维蔚, 康凯, 张武雄, 等. 基于 WiFi 的室内定位准确率改进算法[J]. 计算机工程, 2020, 46(2): 207-213.
- [10] BUNDAK C, RAHMAN M, KARIM M, et al. Fuzzy rank cluster top k euclidean distance and triangle-based algorithm for magnetic field indoor positioning system-Science Direct [J]. Alexandria Engineering Journal, 2021, 61(5): 3645-3655.
- [11] 周楚霖, 陈敬东, 黄凡. 基于无迹粒子滤波的 WiFi-PDR 融合室内定位技术[J]. 计算机科学, 2022, 49(S1): 606-611.
- [12] 郝利军, 张丽杰. 改进 WKNN 结合最大熵 CQKF 的室内定位方法[J]. 电子测量技术, 2020, 43(23): 46-50.
- [13] 向文平, 马毅, 梁瑜, 等. 基于熵定权的 KNN 建筑内定位算法研究[J]. 现代雷达, 2021, 43(7): 32-37.
- [14] WANG Y, LEI Y, ZHANG Y, et al. A robust indoor localization method with calibration strategy based on joint distribution adaptation[J]. Wireless Networks, 2021, 27(3): 1739-1753.
- [15] 党小超, 马平川, 郝占军. 基于 CSI 的改进 KNN 室内定位方法[J]. 传感器与微系统, 2019, (10): 51-53.
- [16] 刘培栋, 刘立巍, 李明, 等. 基于 KNN 和 RF 结合的供热机组热负荷预测研究[J]. 全球能源互联网, 2021, 4(6): 595-601.
- [17] 杨军华, 李勇, 程伟. 基于最邻近相关系数的指纹室内定位新算法[J]. 西北工业大学学报, 2017, 35(4): 676-682.
- [18] 郑建滨, 艾廷华, 晏雄锋, 等. 基于 XGBoost 的多建筑 WiFi 位置指纹室内定位方法[J]. 测绘地理信息, 2019, 44(2): 65-68.

### 作者简介

卢海钊, 硕士研究生, 主要研究方向为传感器与智能信息处理技术。

E-mail: 726997100@qq.com

彭慧豪, 硕士, 主要研究方向为无线传感器网络技术。

E-mail: 747277573@qq.com

唐滔, 硕士研究生, 主要研究方向为传感器与智能信息处理技术。

E-mail: 1027319511@qq.com

王守峰, 硕士, 主要研究方向为传感器与智能信息处理技术。

E-mail: 452482123@qq.com

张烈平(通信作者), 博士, 教授, 主要研究方向为传感器与智能信息处理技术。

E-mail: 1994023@glut.edu.cn