

基于三维 Voronoi 图划分的加权混合回归定位算法

李芬芳¹, 党小超^{1,2}, 郝占军^{1,2}

(1. 西北师范大学计算机科学与工程学院, 甘肃 兰州 730070; 2. 甘肃省物联网工程研究中心, 甘肃 兰州 730070)

摘要: 随着无线通信技术和感知技术的发展, 基于无线传感器网络的各种技术应运而生, 这些技术被广泛应用在智慧农业、智慧交通、消防救援等领域。节点定位技术是无线传感器网络的基础技术之一, 位置信息是感知数据的一部分, 它决定了下一步要采取的具体措施。由于三维空间定位环境的复杂性, 将平面上的定位方法应用在三维空间会有一定的局限性。针对以上问题, 研究了基于三维空间 Voronoi 图的加权混合回归定位算法 WMR-SKR。该定位算法分为离线训练和在线测试两个阶段。根据网络中的锚节点对定位空间进行三维 Voronoi 图划分, 离线训练阶段将锚节点和 Voronoi cell 顶点的坐标组成的序列作为训练集进行训练。在线测试阶段通过训练好的定位模型对网络中未知节点的坐标进行预测。仿真实验结果表明, 所提算法可有效降低三维空间中的节点定位误差, 同时有效提高节点定位速度。

关键词: 节点定位; Voronoi 图划分; 加权混合回归; WMR-SKR

中图分类号: TP391.9

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2022.00273

Weighted mixed regression localization method based on three-dimensional Voronoi diagram division

LI Fenfang¹, DANG Xiaochao^{1,2}, HAO Zhanjun^{1,2}

1. College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China

2. Gansu Province Internet of Things Engineering Research Center, Lanzhou 730070, China

Abstract: With the development of the wireless communication technology and sensing technology, various technologies based on wireless sensor networks are applied. These technologies are widely used in the fields of intelligent agriculture, intelligent transportation, fire rescue and so on. Node localization technology is one of the basic technologies of wireless sensor networks. Location information is a part of the sensing data, which determines the specific measures to be taken in the next step. Due to the complexity of the three-dimensional (3D) space localization environment, the application of the plane positioning method in 3D space will have some limitations. Aiming at above problems, the weighted hybrid regression localization algorithm WMR-SKR based on a 3D Voronoi diagram was studied. The localization algorithm was divided into two stages: offline training and online testing. The 3D space was divided into Voronoi diagrams according to the anchor nodes in the network. In the offline training stage, the sequence composed of the coordinates of the anchor nodes and Voronoi cell vertices was used as the training set for training. In the online test stage, the coordinates of unknown nodes in the network were predicted through the trained localization model. Simulation results show that the WMR-SKR algorithm can effectively reduce the node localization error and improve the node localization speed in 3D space.

Key words: node localization, Voronoi diagram, weighted mixed regression, WMR-SKR

收稿日期: 2021-10-13; 修回日期: 2022-05-01

通信作者: 党小超, dangxc@nwnu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61762079); 甘肃省科技重点研发项目 (No.20YF8GA048); 甘肃省科技创新基地和人才计划项目 (No.20JR10RA096); 西北师范大学青年教师科研能力提升计划项目 (No.NWNU-LKQN2019-28)

Foundation Items: The National Natural Science Foundation of China (No.61762079), The Key Science and Technology Development Program of Gansu Province (No.20YF8GA048), The Science and Technology Innovation Base and Talent Plan Program of Gansu Province (No.20JR10RA096), The Young Teachers' Scientific Research Ability Improvement Program of Northwest Normal University (No. NWNU-LKQN2019-28)

0 引言

无线传感器网络 (WSN, wireless sensor networks) 是现阶段普遍应用的信息采集终端, 传感器网络将传感器节点作为载体进行信息采集, 对传感器网络节点的位置监测、跟踪和反馈, 这些功能直接影响着网络的精准度和实效性^[1-2]。在许多应用中, 传感器网络采集的信息与节点的位置息息相关, 因此寻找高精度的节点定位技术是一个重要的问题^[3]。一般在传感器网络中, 节点被分为锚节点和普通节点, 锚节点性能比普通节点好, 其坐标已知。传感器网络节点定位通过锚节点的坐标来计算未知节点的坐标^[4-7]。在复杂环境下, 通过人工将节点部署到指定区域存在较大的困难, 且耗费人力, 所以, 对网络中所有节点实现精准部署存在较大困难^[8-9]。现阶段人们尝试在网络中配置少量坐标已知的锚节点, 再通过锚节点定位未知节点。节点通过随机部署的方式被撒到定位区域中, 这有时会带来节点分布不均匀的问题, 导致模型定位误差较大。针对这些问题, 人们为了提高定位精度, 进行了不同程度的研究。

多年来, Cell-ID 定位技术和全球定位系统 (GPS, global positioning system) 等室外定位技术为人们提供了很多方便。例如, 在复杂的山地和森林等环境中, 如果能够快速定位到火灾等发生的地点, 就可以引导人们以最快的速度进行救援。正是这些需求和应用的不断涌现, 更加体现出了位置信息在感知任务中的重要性^[10]。定位算法根据划分特征不同, 被分成不同类别。根据定位场景不同, 把定位技术分为室内定位和室外定位; 根据信号特征不同, 分为基于接收信号强度 (RSS, received signal strength) 指示的定位、基于 Wi-Fi 的定位、基于毫米波的定位, 或者基于几种定位的结合^[11]。针对不同的定位场景和信号特征, 人们引入图论、机器学习和深度学习等技术来提高节点定位精度。

在一般的网络中, 节点被分为锚节点和普通节点, 当网络中锚节点比例较大时, 人工部署会带来更大的定位代价, 所以, 需要其他信息进行协助定位^[12]。本文基于结合算法优点、规避缺点的需求, 为了使模型更适应现实环境, 在引入三维 Voronoi 图划分^[13]的基础上, 提出了一种基于支持向量回归 (SVR, support vector regression)^[14]和 K 近邻回归 (K -nearest neighbor regression, KNR)^[15]的加权

混合回归 (WMR, weighted mixed regression) 定位算法 WMR-SKR。SVR 是 SVM 的重要应用分支。SVR 与 SVM 的区别在于: SVR 所寻求的最优超平面是使所有的样本点离超平面的总偏差最小, 而不是使两类或多类样本点分的“最开”。同样, KNR 即使用 K 最近邻 (KNN, K -nearest neighbor) 模型做回归的情况。KNR 通过找出一个样本的 k 个最近邻居, 将这些邻居某些属性的平均值赋给该样本, 就可以得到该样本对应属性的值。本文定位算法分为离线训练和在线测试两个阶段。通过三维空间 Voronoi 图划分将定位区域分割成若干个以锚节点为中心的多面体, 离线训练阶段将锚节点和 Voronoi cell 的顶点坐标之间的距离信息作为训练集进行训练, 对 SVR 和 KNR 两个回归模型分别进行多次训练, 按照定位结果选择适应两个定位模型的权重系数, 得到加权混合回归模型 WMR-SKR。在线测试阶段, 将测试集数据在 WMR-SKR 模型上对节点坐标信息进行预测。实验结果表明, 该算法在保证较低定位误差的同时, 能够有效地延长网络的寿命。

1 室内定位相关研究

多年来, 针对无线传感器网络的节点定位问题, 研究人员进行了诸多的探索。经典的传感器网络节点定位代表方法有质心定位算法、凸规划法、MDS-MAP 算法、DV-Hop 算法、APIT 算法、DV-Distance 定位算法等。这些经典算法通过计算锚节点围成的平面质心的坐标和未知节点与锚节点之间的接收信号强度。将计算的平面的质心坐标作为距离未知节点最远的锚节点的坐标。因此, 就缩小了锚节点围成的平面的面积, 最后采用不断迭代的方法来提高节点定位精度。

在经典定位算法的基础上, 人们试图将图论的方法引入节点定位模型, 如基于 Voronoi 图和 Delaunay 三角剖分的定位方法, 这些方法取代了将定位区域划分为基于规则形状的定位, 以期在更加普通的场景下应用。文献[16]提出了一种结合节点模糊几何信息与 Delaunay 三角剖分的节点定位算法, 该算法首先应用三角剖分将定位区域划分成若干个三角形区域, 然后通过节点之间的方向角和俯仰角信息计算节点最终位置。与文献[16]类似, 文献[17]提出了基于 Voronoi 图划分的节点定位算法, 该算法首先采用 Voronoi 图划分将定位区域划分,

划分出的每个 Voronoi cell 只包含一个锚节点,每个 Voronoi cell 内有多个未知节点。该方法首先按照 RSS 从高到低排序,然后计算每个锚节点的 Voronoi cell 的坐标,将所有 Voronoi cell 交集的质心作为定位结果。文献[18]提出了一种在二维平面基于 Voronoi 图划分的节点定位方法,该算法在 Voronoi 图划分的基础上对节点之间的 RSS 值进行筛选,最后通过锚节点和未知节点之间的方向角和俯仰角信息计算节点的最终位置。文献[19]提出一种基于半对称镜面的定位算法,在该算法通过一种新的方法确定节点的定位区域,并引入了 Voronoi 图来缓解无法定位的传感器节点的问题。文献[20]提出一种在室内环境应用 Voronoi 图进行定位的方法,该方法基于广义的 Voronoi 图(GVD, generalized Voronoi diagram),提出并评估基于 GVD 交会点周围的几何约束的简洁描述,同时采用隐马尔可夫模型(HMM, hidden Markov model)进行推理。文献[21]提出一种基于三维空间 Voronoi 图的序列定位算法(SL3V, sequence localization algorithm based on 3D Voronoi diagram),该算法首先使用 3D-Voronoi 图划分定位空间,然后使用多面体顶点作为虚拟锚节点,并构建虚拟信标节点的等级序列列表,最后进行定位。图论知识能够更贴近的表达网络中的节点分布,不再只是规则的划分定位区域,在划分区域的同时,网络中增加了更多的可参考位置坐标。随着机器学习和深度学习技术的应用,人们开始尝试将这些技术应用在传感器网络节点定位方法中,这些方法的共性是应用机器学习“离线训练+在线测试”的模式实现定位,离线阶段在大量数据集上训练,在线测试阶段在训练好的模型上预测节点坐标。分类和回归是机器学习里面的两个概念,他们的主要区别在于输出变量的类型。分类的输出是有限个离散的值,回归模型的输出在一定范围内是连续的。文献[22]研究了多变定位的聚类分析改进算法,首先采用 K -means 聚类方法筛选误差较大的距离信息,筛选后,对剩余距离信息使用多边定位法进行定位求解。文献[23]提出了一种基于支持向量机(SVM, support vector machine)的 WSN 移动节点定位算法,该算法通过 SVM 方法建立节点的测量向量与其位置之间的关系,引入了节点运动方向预测的措施。文献[24]提出了一种基于改进加权最小二乘支持向量机(WLS-SVM, weighted least squares support vector machine)的 UWSN 定位方法,引入

WLS-SVM 的同时,通过改进的多类别模式识别方法对节点进行快速分类,提高定位精度与算法鲁棒性,并降低区域大小对定位精度的影响。文献[25]提出一种根据邻居节点局部网络块的节点定位算法,与机器学习领域中的降维方法相结合,有效解决了在锚节点密度较低情况下的节点定位精度低的问题。文献[26]提出了基于快速 SVM 的大规模定位算法,通过引入相似性度量来构造最小跨度,然后进行分类。文献[27]提出一种基于 SVM“一对一”的节点定位算法,通过引入分类思想来解决节点稀疏环境下的节点定位。文献[28]提出了一种基于 Voronoi 图划分的 SVM 节点定位算法,将图论知识和机器学习方法结合来提高节点定位精度。文献[29]提出了一种基于核化 K -means 和 SVM 的定位算法。该算法首先采用核化 K -means 算法对预处理后的 RSS 聚类,然后通过 SVM 回归算法进行训练,得到一种最优拟合位置函数的数学模型。以上这些算法均在某一方面提高了节点定位精度,但缺乏对锚节点比例较低情况下的分析,在算法鲁棒性方面也考虑较少。

2 节点定位算法

学习算法有两个主要的知识来源,一个是数据,另一个是人工设计的内容,可能是组件、函数等。所以当有大量数据时,人工设计的内容就不太重要了,但是数据量很少时,只通过模型学习数据特征变得比较困难,所以,需要考虑将人类对问题本身的认知直接注入到问题里。本文模型将定位过程分为离线训练和在线测试两个阶段,离线阶段训练的模型会影响在线测试阶段的结果,离线训练阶段可以根据结果进行修正反馈,不断更新模型。本文模型引入了 Voronoi 图划分,减少了人工干预,属于非端到端的模式,不同于目前较流行的端到端模式,但是本文算法有效证明了非端到端模型在数据量较少和训练平台有限的情况下定位的优势。

定位流程如图 1 所示,本文将三维空间 Voronoi 图划分引入到无线传感器网络节点定位过程中,通过 Voronoi 图将定位空间分割成若干个以锚节点为中心的多面体 Voronoi cell,其中,锚节点的坐标是已知的,在每次 Voronoi 图划分后都可以获得每个多面体的顶点坐标。在获得锚节点坐标和 Voronoi cell 顶点坐标的基础上,结合其对应的物理位置分别训练 SVR 定位模型和 KNR 定位模

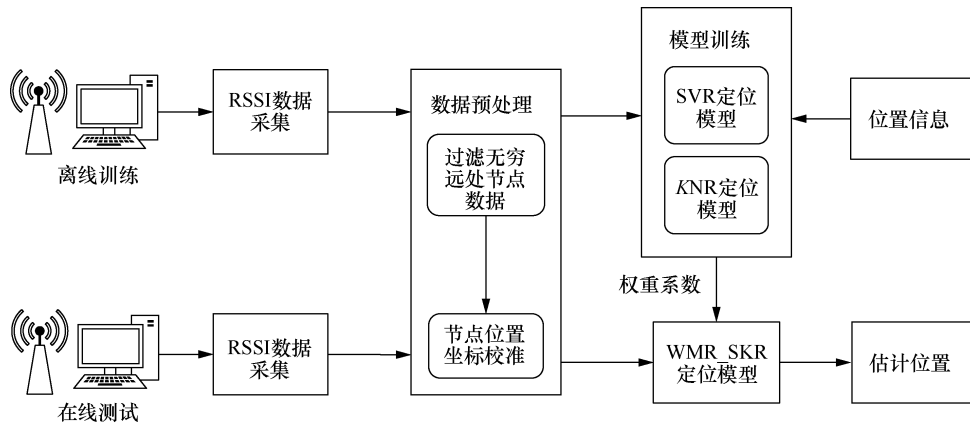


图 1 定位流程

型，并根据定位误差更新两种模型的权重系数，以获得混合回归模型最优的权重系数，得到混合 SVR 和 KNN 的 WMR-SKR 定位模型。在线测试阶段，将预处理后的 RSS 实时数据输入 WMR-SKR 定位模型中，进行位置估计。KNN 与 KNN 均属于无参数模型，本文在 SVR 的基础上引入 KNN 做回归，主要是考虑到了 KNN 算法简单清晰、无数据输入假定、准确度高、对异常数据不敏感、移植性好，因此该方法与其他预测方法相结合，能有效发挥组合模型的优势。同时，规避了其计算量大、样本不平衡的问题。

2.1 三维空间 Voronoi 图划分

由于锚节点的比例在定位算法中对定位性能有一定的影响，很多文献将定位空间划成立方体，真实的无线传感器网络并不是规则的立方体结构，统一划成立方体结构将影响网络的普适

性。Voronoi 图是图论中的一个比较重要的研究内容，在二维空间中，Voronoi 图也称为泰森 (Thiessen) 多边形。由于定位环境的复杂性，平面上的二维 Voronoi 图划分并不能很真实的表达空间中节点之间的关系。基于上述问题，本文考虑将三维 Voronoi 图划分引入接近真实定位环境的三维空间中。本文通过 Voronoi 图划分将监测区域分割成若干个多面体，每个多面体内有且只有一个锚节点，在进行 Voronoi 图划分时可以获得每个多面体的各顶点坐标，增加了网络中可参考的坐标数量。

三维空间 Voronoi 图划分及投影示例如图 2 所示，图 2 左图是三维空间以 20 个锚节点进行 Voronoi 图划分的结果，三维空间的 Voronoi 图划分能够帮助我们获得每个多面体的顶点坐标，图 2 右图是图 2 左图中被标记的 Voronoi cell 投影到二维平面的效果。




图 2 三维空间 Voronoi 图划分及投影示例

2.2 RSS 通信模型及节点筛选

RSS 定位算法的原理是将节点之间的信号强度转化为距离信息，进而得到未知节点的位置坐标，通常情况下，RSS 的值随着距离的远近而变化。RSS 易受到环境各类因素的影响，所以单一使用 RSS 定位将导致定位误差较大。大量研究表明，RSS 定位模型的路径损耗遵从对数距离损耗模型，如式(1)所示。

$$PL(d) = PL(d_0) - 10M \lg \frac{d}{d_0} + X_\sigma \quad (1)$$

其中， d 为节点间的距离， d_0 为参考距离； $PL(d)$ 和 $PL(d_0)$ 为信号传播距离 d 和 d_0 处的路径损耗； M 为路径损耗指数； X_σ 表示高斯随机噪声变量。则式(1)可简化为式(2)。

$$PL(d) = -[PL(d_0) + 10M \lg d] \quad (2)$$

则可得到节点间的距离 d 如式 (3) 所示。

$$d = 10^{\frac{-PL(d_0) - PL(d)}{10M}} \quad (3)$$

由式(3)可知，根据实际应用环境，可通过降低噪声干扰和路径损耗指数对信号的影响来提高 RSS 定位算法的精度。

在节点的通信过程中，信息是通过接收信号强度指标进行发送，传输时模拟信号的渐变模型如式(4)所示。

$$10 \lg \frac{RSS}{RSS_0} = -10\beta \lg \left(\frac{d}{d_0} \right) + X_{dB} \quad (4)$$

其中， X_{dB} 代表高斯随机变量，其平均值为 0， β 代表路径损耗因子。在式(4)中， X_{dB} 是高斯随机噪声，对结果的影响不大，一般可忽略，因此可以粗略地估计它，然后可以得出如式(5)的结论。

$$\frac{d}{d_0} \approx \left(\frac{RSS}{RSS_0} \right)^{-\frac{1}{\beta}} \quad (5)$$

假设要确定节点的位置，节点可得到周围 K ($1 \leq K \leq N$) 个锚节点的 RSS 值，然后根据接收到的 RSS 值假设 $RSS_{i1} \geq RSS_{i2} \geq RSS_{i3} \geq \dots \geq RSS_{ik}$ 。根据以上计算式则可得出如式(6)的结论。

$$\frac{d_{i1}}{d_{i2}} \approx \left(\frac{RSS_{i1}}{RSS_{i2}} \right)^{-\frac{1}{\beta}} < \frac{RSS_{i1}}{RSS_{i2}}, \frac{d_{i1}}{RSS_{i1}} < \frac{d_{i2}}{RSS_{i2}} \quad (6)$$

当网络中增加了 Voronoi cell 顶点作为参考坐标

协助定位后，网络中可参与定位的节点个数增加，为了降低以锚节点为核心划分 Voronoi 图后导致模型更大的定位误差，本文以每个 Voronoi cell 内的锚节点为中心，将 Voronoi 图划分之后的区域内通过高斯滤波^[30]排除小概率事件，具体方法如下。

假设一个未知节点在同一个位置收到的 RSS 信号值在矩阵 RSS_1 中保存，未知节点可以收到 n 个 RSS_1 值，则一定会有一些小概率的值出现。本文为了降低这些小概率值对定位精度的影响，使用高斯滤波模型排除这些小概率的值。用正态模型处理这些 RSS 值，设变量 x 表示 RSS 值，则有如式(7)~式(9)的计算^[31]。

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (7)$$

$$m = \frac{1}{n} \sum_{i=1}^n x_i \quad (8)$$

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2 \quad (9)$$

根据文献[32]，选择 0.6 作为阈值。当正态分布值大于 0.6 时，可以认为此时获得的 RSS 值是高概率数值，可以保存利用，反之舍弃。

$$0.6 \leq \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}} \leq 1 \quad (10)$$

因此，可以通过式(8)和式(9)获得期望值和方差。根据式(10)的选择，从矩阵 RSSI_1 中找出高概率出现的 RSS 值，并把这些数据保存到矩阵 RSS_2 中。最后根据式(11)计算出最终的 RSS 值 R 。

$$R = \frac{1}{n} \sum_{i=1}^n RSS_2[i] \quad (11)$$

2.3 WMR-SKR 回归算法精准定位

2.3.1 节点定位流程

假设网络中有 N 个节点 $\{S_1, S_2, \dots, S_n\}$ ，其中有 M 个锚节点 $\{S_1, S_2, \dots, S_m\}$ ，则未知节点个数为 $N - M$ 。经过 Voronoi 图划分后，假设共有 P 个顶点坐标 $\{S_1, S_2, \dots, S_p\}$ ，标记为每个锚节点所在的 Voronoi cell 多面体有 Q 个顶点坐标 $\{S_1, S_2, \dots, S_q\}$ 。

步骤 1: 将定位区域进行 Voronoi 图划分，通过 RSS 测距算法生成每个 Voronoi cell 内锚节点到所有 Voronoi cell 顶点的距离向量，形成训

练集。

步骤 2: 在三维空间建立三维坐标轴, 并对坐标轴按照区间等分。以 X 轴为例, 设该维度上存在 T 个区间, 其中每一区间包含 X 轴上, 坐标在 Voronoi cell 中的锚节点, D 为区域边长。同理 Y 轴与 Z 轴上的单一区间均包含 Y 、 Z 坐标在该区间的所有节点。记节点所在的区间为 $[x_u, y_v, z_w]$ 。

步骤 3: 分别在 3 个维度上利用锚节点和 Voronoi cell 顶点坐标的距离向量作为训练集来训练模型。

步骤 4: 根据离线阶段训练得到的模型, 将未知节点与所有锚节点之间的距离向量作为测试集来预测未知节点坐标。

步骤 5: 可得未知节点所在区间为 $[x_u, y_v, z_w]$ 。

2.3.2 数据预处理

1) 训练集数据

假定锚节点 $S_i (i=1, 2, \dots, k)$ 到它所在的 Voronoi cell 的顶点 $Q_j (j=1, 2, \dots, l)$ 的距离为 $h_{ij}(S_i, Q_j)$ 。则锚节点 S_i 到它所在的 Voronoi cell 所有的顶点的距离可以组成距离向量: $d_i[h_{i1}(S_i, Q_1), h_{i2}(S_i, Q_2), \dots, h_{ij}(S_i, Q_j)]$ 。对于三维环境节点坐标求解, 需要对 3 个维度上的坐标进行分别求取。因此, 需要在 X 、 Y 、 Z 轴 3 个方向分别建立 T 个区间的分类。因此 X 轴上存在 T 个可选区间 $\{x_0, x_1, \dots, x_{T-1}\}$ 。假定每一个区间包含该区间上的所有节点坐标。同理, Y 、 Z 上同样存在 T 个可选区间 $\{y_0, y_1, \dots, y_{T-1}\}$, $\{z_0, z_1, \dots, z_{T-1}\}$ 。因此各个定位区域被划分成若干个多面体, 每个多面体代表着算法中的一个节点的坐标。锚节点的坐标记为 $\{x_u, y_v, z_w\}$ 。锚节点的距离向量 d_i 与坐标构成训练集如式(12)所示。

$$\begin{aligned} T_x &= \{(d_i, x_u) | i=1, 2, \dots, l\} \\ T_y &= \{(d_i, y_v) | i=1, 2, \dots, l\} \\ T_z &= \{(d_i, z_w) | i=1, 2, \dots, l\} \end{aligned} \quad (12)$$

2) 测试集数据

根据模型在离线阶段训练集上训练的结果, 对所有锚节点训练样本所在 Voronoi cell 区间节点进行编号。

设未知节点 $S'_u (u=1, 2, \dots, N-M)$ 与锚节点之间的距离为 $L_i(S'_u, S_i) (i=1, 2, \dots, m)$, 获取未知节点 S'_u 与所有锚节点之间的距离向量 d'_u , 并将其作为测试集。

$$d'_u [L_1(S'_u, S_1), L_2(S'_u, S_2), \dots, L_m(S'_u, S_m)] \quad (13)$$

根据离线阶段训练的模型, 将测试集带入预测未知节点所在的区间, 将区间的坐标作为未知节点的坐标, 完成定位。

2.4 WMR-SKR 回归算法精准定位

2.4.1 SVR 算法

SVM 同时支持线性与非线性回归, 在大量的数据上进行训练, 可以得到节点之间 RSS 特征向量与位置坐标之间映射关系的数学模型^[33]。假设在各参考点通过节点位置数据生成的训练样本对为 (RSS_i, p_i) , p_i 为预测的坐标 (x_i, y_i, z_i) , 训练目标即分别构造 x 、 y 和 z 的线性估计函数 φ_x 、 φ_y 和 φ_z 。高维空间中的目标函数和约束条件如式(14)所示。

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}\|^2 + C \left(v\varepsilon + \frac{1}{m} \sum_{i=1}^m (\hat{\xi}_i + \xi_i) \right) \\ \text{s.t.} \quad & \begin{cases} (\mathbf{w}^T d_i + b) - c_i \leq \varepsilon + \xi_i \\ c_i - (\mathbf{w}^T d_i + b) \leq \varepsilon + \hat{\xi}_i \\ \xi_i, \hat{\xi}_i, \varepsilon \geq 0 \end{cases} \end{aligned} \quad (14)$$

其中, $\mathbf{w} \in \mathbf{R}^l$ 是表示函数方向的向量, $b \in \mathbf{R}$ 是表示其位置的常数, RSS_i 是 RSS 的向量, c_i 是位置坐标大小, 对于 φ_x 回归 c_i 为 x 坐标, 对于 φ_y 回归 c_i 为 y 坐标, 对于 φ_z 回归 c_i 为 z 坐标, ε 为误差范围, ξ_i 和 $\hat{\xi}_i$ 是松弛变量, 松弛变量是指超出 ε 的部分, C 是正则化常数。求解方程(14)得到如式(15)的近似函数。

$$f(\mathbf{D}) = \sum_{i=1}^m (\alpha_i - \hat{\alpha}_i) K(RSS_i, \mathbf{RSS}) + b \quad (15)$$

其中, α_i 和 $\hat{\alpha}_i$ 是拉格朗日乘子, $K(RSS_i, \mathbf{RSS})$ 是核函数, 本文采用目前应用较多的高斯核函数, 又名径向基函数(RBF, radial basis function)作为核函数。

$$K(x, x_k) = \exp\left(-\frac{\|x - x_k\|^2}{2\sigma^2}\right) \quad (16)$$

RBF 核函数可将样本映射到更高维的空间, 且具有较宽的收敛域, 以及唯一最佳逼近的特征。因此, RBF 函数针对不同维度与大小的样本均可实现较好的分类效果。

2.4.2 KNR 算法

KNN 常被用于离散数据的分类和标签预测, 当其用于回归时称为 KNR, KNR 可以用于对连续的

数据标签进行预测,符合本文对位置坐标的预测要求。本文通过节点之间的距离信息实现回归,通过未知节点的信号特征,计算该未知节点与距离最短的 k 个节点之间的欧几里得距离 d_i ,最后用计算加权均值的方法来计算节点位置。假设 $A=(x_a, y_a, z_a)$ 和 $B=(x_b, y_b, z_b)$ 是三维空间中的两个点,则它们之间的欧几里得距离如式(17)。

$$d(A, B) = \sqrt{(x_a - x_b)^2 + (y_a - y_b)^2 + (z_a - z_b)^2} \quad (17)$$

2.4.3 WMR-SKR 算法

在机器学习回归算法中,SVR 和 KNR 为最常用的算法^[34],本文基于结合算法优点,规避缺点的思想,将这两种回归算法结合起来实现节点定位,首先,在单独的 SVR 和 KNR 算法上进行训练,获得每个算法的定位误差,根据分析结果确定 SVR 和 KNR 两种算法各自的权值,得到一个加权回归模型 WMR-SKR。本文 WMR-SKR 算法实现过程如下。

步骤 1: 在获取的训练数据上分别训练并保存 SVR 和 KNR 两种回归模型。

步骤 2: 在测试集数据上应用步骤 1 的 KNR 和 SVR 的模型进行初步定位,获取初步定位结果 (x_1, y_1, z_1) 、 (x_2, y_2, z_2) 。

步骤 3: 由式(18)计算定位算法计算后的坐标与节点实际坐标 (x, y, z) 的定位误差。

$$\begin{aligned} \varepsilon_k &= \sqrt{(x_1 - x)^2 + (y_1 - y)^2 + (z_1 - z)^2} \\ \varepsilon_s &= \sqrt{(x_2 - x)^2 + (y_2 - y)^2 + (z_2 - z)^2} \end{aligned} \quad (18)$$

步骤 4: 根据定位误差,由式(19)计算 KNR 回归模型的权值 h_k 和 SVR 回归模型的权值 h_s ,其值满足 $h_k + h_s = 1$ 。

$$\begin{aligned} h_k &= \varepsilon_s / (\varepsilon_k + \varepsilon_s) \\ h_s &= \varepsilon_k / (\varepsilon_k + \varepsilon_s) \end{aligned} \quad (19)$$

步骤 5: 定位结果 (X, Y, Z) 通过式(20)计算得到。

$$\begin{aligned} X &= h_k x_1 + h_s x_2 \\ Y &= h_k y_1 + h_s y_2 \\ Z &= h_k z_1 + h_s z_2 \end{aligned} \quad (20)$$

3 实验分析

3.1 实验环境设置

本文在实验部分,首先对比了不同权重系数、不同核函数和两种独立与混合的回归模型的性能。其次,将本文提出的 WMR-SKR 算法与

NFIL-VD 算法^[18]、VD-SVM 算法^[28]、WSTA 算法^[24]和 K -means-SVM 算法^[29]在定位误差、未被定位节点个数和定位时间 3 个方面进行了对比实验,通过求同存异的思想分析模型的性能。NFIL-VD 和 VD-SVM 是基于 Voronoi 图划分的节点定位方法,NFIL-VD 是基于 Voronoi 图划分的模糊信息节点定位方法,VD-SVM 是基于 Voronoi 图划分的 SVM 分类定位方法。WSTA 和 K -means-SVM 是基于 SVM 的定位方法,WSTA^[24]是基于改进加权最小二乘 SVM 的定位方法,该方法根据多类别模式识别的分类方法对未知节点进行分类,判断未定位节点的分类信息,从而计算未知节点的坐标信息。 K -means-SVM^[29]算法结合了 K -means 和 SVM 两种方法,该算法首先采用核化 K -means 算法对预处理后的 RSS 信号聚类,然后通过 SVM 回归算法进行训练,得到一种最优拟合位置函数的数学模型。本文在 MATLAB2016b 环境下进行编程和仿真实验,仿真实验适用的参数见表 1。

表 1 仿真实验使用的参数

参数	值
仿真区域长、宽/m	1 000
仿真区域高/m	50
传感器网络节点总数 N	300
节点通信半径/m	50
锚节点占比	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
RBF 核函数参数	1

3.2 加权混合回归算法参数对定位结果的影响

为了对比本文模型和现有关于节点定位模型的性能,需要先确定本文模型中所需要的相关参数,分别在权重系数、核函数等方面进行了实验。

3.2.1 权重系数对 SVR 模型定位性能的影响

本文提出的节点定位模型融合了 SVR 和 KNR 两种经典回归算法,SVR 的权重系数 h_s 和 KNR 的权重系数 h_k 之和为 1,所以,关于两者的权重系数的选取会直接影响到定位的精确程度。为了寻求能使得模型获得最优定位效率的权重系数分配方法,本文通过大量实验分析 h_s 取不同值时的定位误差。SVR 的权重系数与平均定位误差的关系如图 3 所示,当 h_s 的值为 0.65 时,WMR-SKR 的平均定位误差最小,在后续实验过程中,设置 h_s 为 0.65、 h_k 为 0.35。




图 3 SVR 的权重系数与平均定位误差的关系

3.2.2 核函数对 SVR 定位性能的影响

在回归模型中对连续值进行离线训练和在线预测时，核函数的选取对回归任务也有不同程度的影响。本文为了提高节点定位效率，选择常见的多项式核函数、sigmoid 核函数和高斯核函数进行了实验和分析。高斯核函数对诱导空间的非线性关系有较强的表达能力，更适用于描述本文 RSS 信号特征与物理位置之间的非线性关系。为了验证高斯核函数在回归定位中的适用性，本文对比了 SVR 回归模型在 3 种常见的核函数下，对应的 WMR-SKR 的定位误差累积分布情况，用累积分布函数 (CDF, cumulative distribution function) 表示，SVR 采用不同核函数的定位误差 CDF 如图 4 所示。从图 4 可以发现采用高斯核函数的 SVR 定位模型的定位误差是最小的，在本文后续的实验中选择高斯核函数进行回归定位。




图 4 SVR 采用不同核函数的定位误差 CDF

3.2.3 3 种回归算法性能比较

为了验证本文算法能够有效融合 SVR 和 KNR 的优势，将本文模型与两种回归模型进行了相应实验。不同算法的定位误差 CDF 如图 5 所示。从实验结果看到，融合了 SVR 和 KNR 算法的模型优于单独的两种回归模型，SVR 算法性能优于 KNR 算法性能。从实

验结果看出，WMR-SKR 算法的定位误差在 1.5 m 以内的概率达到了 86%，而其他两种算法定位误差在 1.5 m 以内的概率都在 80% 以下。由此证明 WMR-SKR 模型结合了 SVR 算法适合小数量样本数据，可以解决高维问题，以及 KNR 算法对数据没有假设的优点，同时规避了 KNR 算法计算量大、样本不平衡的问题。




图 5 不同算法的定位误差 CDF

3.3 网络参数对误差率的影响

3.3.1 锚节点占比对定位误差率的影响

实验 3.2 分析了基于 WMR-SKR 模型的节点定位算法在实际应用中的相关参数。同样，在节点定位过程中，锚节点占比对网络性能影响也较明显。锚节点的位置是已知的，锚节点个数决定了网络的连通性，在本文算法中，锚节点个数也决定了 Voronoi 图划分获得的 Voronoi cell 多面体的个数。不同算法的未被定位节点个数如图 6 所示，分析了本文算法及对比算法定位误差随着锚节点占比增加的变化趋势。从图 6 可以看到，对于 5 种算法，随着锚节点比例增加，网络平均定位误差逐渐降低，应用了 SVM 算法的模型误差较采用 Voronoi 图划分的模型误差低，而本文在 Voronoi 图划分基础上引入加权混合回归模型更加精确的定位到了网络中节点的位置。在锚节点占比从 0.2 增加到 0.7 的过程中，5 种算法定位误差均出现了明显下降，且 WMR-SKR 模型的定位误差基本保持最低。在锚节点占比从 0.2 增加到 0.7 的过程中，NFIL-VD、VD-SVM、WSTA、K-means-SVM 和 WMR-SKR 5 种算法的误差分别下降了 3.09、3.12、3.38、2.97 和 3.11。随着锚节点比例的增大，划分得到的 Voronoi cell 多面体个数增加，划分到每个 Voronoi cell 中的未知节点个数减少，因此，未知节点到锚节点和 Voronoi cell 顶点坐标的平均距离变短，定位误差降低。在引入加权混合回归算法后，能够在 Voronoi 图划分的基

基础上有效结合 WMR 和 SKR 两种回归模型的优点，规避他们的缺点，因此定位更加精确。

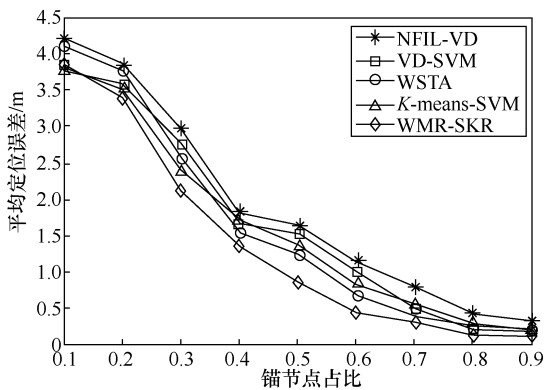


图6 不同算法的平均定位误差

3.3.2 网络中未被定位节点个数

网络中未被定位节点个数是反应模型定位性能的一个重要标志。本文对比了现有相关模型在不同锚节点占比时网络中的未被定位节点个数。本文设置网络节点总数为 300，节点通信半径为 50 m，从图 7 可以看到，在锚节点比例从 0.1 上升到 0.5 的过程中，未定位节点数量快速降低，在锚节点占比大于 0.5 以后逐渐变慢。锚节点占比为 0.1 时，NFIL-VD、VD-SVM、WSTA、K-means-SVM 和 WMR-SKR 5 种算法网络中未被定位节点个数分别为 136、128、130、123 和 125，随着锚节点数量增加，网络中未被定位的节点越来越少，在锚节点占比为 0.5 时，网络中未定位节点个数分别为 8、6、7、8 和 2。所以，从本实验可以得出一个结论，在实际应用中，为了降低网络的定位代价，应该选择合适的锚节点比例。同时，这也启发我们，在传感器网络节点定位的过程中，为了延长整个网络的寿命，在定位过程中，可以引入锚节点睡眠机制，通过轮休来降低网络功耗。

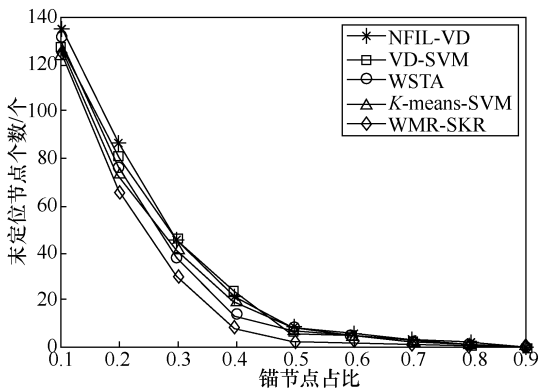


图7 不同算法的未被定位节点个数

3.3.3 不同算法定位时间比较

在分析上述性能的基础上，本文对比了不同算法的定位时间，如图 8 所示。从图 8 可以看出，在定位过程中，5 种模型的定位时间各有差异，随着锚节点占比增大，5 种模型定位时间大体上呈现出上升-下降-上升波动的趋势。在锚节点占比较低的情况下，网络连通性较低，网络中的未定位节点个数较多，定位过程很快结束，且定位误差较高。随着锚节点占比增加，网络连通性增强，对一个未知节点可以定位的锚节点序列增多，同时，也增加了整个网络的定位时间。从前期实验结果中我们可以得出，锚节点比例超过 0.5 时，锚节点占比增大对定位性能影响较小。同样在本实验中，锚节点个数增大到一定程度时，定位时间没有缩短反而有增加的趋势，所以，也验证了实验 3.3.2 中建议的锚节点轮休机制是可行的。本文设置的实验环境中，NFIL-VD、VD-SVM、WSTA、K-means-SVM 和 WMR-SKR 5 种模型的平均定位时间分别是 15 s、16 s、15 s、16 s、和 13 s。本文提出的算法定位耗时基本保持最低，而 VD-SVM 模型最高。也由此证明引入 KNR 能有效地提高定位效率。本文将 Voronoi 图划分获得的多面体顶点坐标作为节点定位过程中参考坐标的一部分，有效提高了节点定位效率，降低了定位所需要的时间。

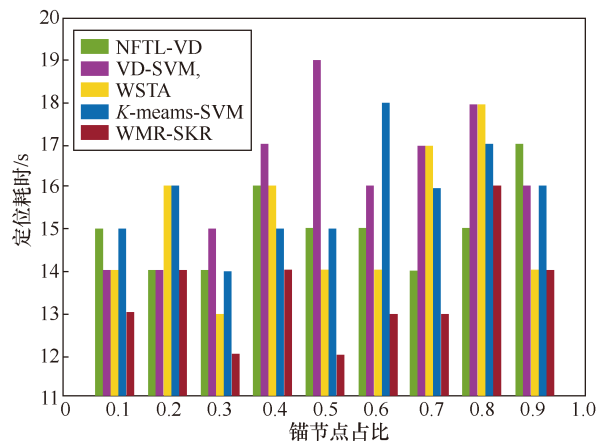


图8 不同算法的定位时间对比

4 结束语

为了有效解决节点定位问题中不同算法在定位环境中的适用问题，本文提出了基于三维 Voronoi 图划分的 WMR-SKR 加权混合回归定位算法，该算法首先将定位空间通过 Voronoi 图划分成若干个 Voronoi cell，同时，获取锚节点和 Voronoi cell 顶点

的坐标。在获取参考坐标的基础上, 将未知节点与锚节点和顶点坐标之间的 RSS 值作为离线训练阶段的训练数据, 然后, 在线测试阶段在离线训练得到的模型上对未知节点坐标进行预测。本文首先在模型参数上进行了相关的实验, 寻找适合 SVR 模型的核函数, 在确定模型参数后, 将 WMR-SKR 算法与现阶段基于机器学习和 Voronoi 图划分的算法相比, 实验结果表明, WMR-SKR 模型有效地结合了两种回归模型的优势, 规避了它们的缺陷, 本文方法在传感器网络节点定位方面具有一定的优势。

参考文献:

- [1] MOHAMED R E, SALEH A I, ABDELRAZZAK M, et al. Survey on wireless sensor network applications and energy efficient routing protocols[J]. *Wireless Personal Communications*, 2018, 101(2): 1019-1055.
- [2] 彭铎, 杨雅文, 高玉蔚, 等. 基于多通信半径和麻雀搜索的节点定位算法[J]. *传感技术学报*, 2021, 34(11): 1523-1529.
PENG D, YANG Y W, GAO Y W, et al. Node localization algorithm based on multi-communication radius and sparrow search algorithm[J]. *Chinese Journal of Sensors and Actuators*, 2021, 34(11): 1523-1529.
- [3] 徐莎莎, 周芳, 李杨剑, 等. 一种新的传感器节点分布式定位算法[J]. *西安电子科技大学学报*, 2022, 49(2): 1-9.
XU S S, ZHOU F, LI Y J, et al. New distributed positioning algorithm for sensor nodes[J]. *Journal of Xidian University*, 2022, 49(2): 1-9.
- [4] HAN G J, JIANG J F, ZHANG C Y, et al. A survey on mobile anchor node assisted localization in wireless sensor networks[J]. *IEEE Communications Surveys & Tutorials*, 2016, 18(3): 2220-2243.
- [5] 唐德红, 王一多, 马新国. 斯蒂芬森迭代改进 DV-Hop 的无线传感器节点定位[J]. *吉林大学学报(工学版)*, 2021: 1-7.
TANG D H, WANG Y D, MA X G. Sensor node localization mechanism based on improved DV-Hop algorithm[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2021: 1-7.
- [6] TOMIC S, BEKO M, DINIS R, et al. On target localization using combined RSS and AoA measurements[J]. *Sensors (Basel, Switzerland)*, 2018, 18(4): 1266.
- [7] HAN G J, YANG X, LIU L, et al. A disaster management-oriented path planning for mobile anchor node-based localization in wireless sensor networks[J]. *IEEE Transactions on Emerging Topics in Computing*, 2020, 8(1): 115-125.
- [8] 刘云萍. 无线传感网络中基于锚节点动态路径规划的节点定位算法研究[D]. 重庆: 重庆邮电大学, 2020.
LIU Y P. Research on node localization algorithm based on dynamic path planning of anchor node in wireless sensor networks[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2020.
- [9] LI Q Y, CHU B Y, WU Z, et al. RMDS: Ranging and multidimensional scaling-based anchor-free localization in large-scale wireless sensor networks with coverage holes[J]. *International Journal of Distributed Sensor Networks*, 2017, 13(8): 155014771772465.
- [10] ZHANG L P, YANG Z Y, ZHANG S L, et al. Three-dimensional localization algorithm of WSN nodes based on RSSI-TOA and single mobile anchor node[J]. *Journal of Electrical and Computer Engineering*, 2019: 4043106.
- [11] TABAAM, DIOUC, SAADANER, et al. LOS/NLOS identification based on stable distribution feature extraction and SVM classifier for UWB on-body communications[J]. *Procedia Computer Science*, 2014, 32: 882-887.
- [12] KUMARR, KUMARS, SHUKLAD, et al. Geometrical localization algorithm for three dimensional wireless sensor networks[J]. *Wireless Personal Communications*, 2014, 79(1): 249-264.
- [13] WU J Z, YUAN J M, RUAN Y J, et al. Optimal planning for energy stations and networks in distributed energy systems based on voronoi diagram and load characteristics[J]. *Applied Sciences*, 2021, 11(16): 7526.
- [14] 张勇, 黄杰, 徐科宇. 基于 PCA-LSSVR 算法的 WLAN 室内定位方法[J]. *仪器仪表学报*, 2015, 36(2): 408-414.
ZHANG Y, HUANG J, XU K Y. Indoor positioning algorithm for WLAN based on principal component analysis and least square support vector regression[J]. *Chinese Journal of Scientific Instrument*, 2015, 36(2): 408-414.
- [15] 陈飞彦, 田宇驰, 胡亮. 物联网中基于 KNN 和 BP 神经网络预测模型的研究[J]. *计算机应用与软件*, 2015, 32(6): 127-129, 202.
CHEN F Y, TIAN Y C, HU L. Study on KNN and BP neural network-based prediction model in IoT[J]. *Computer Applications and Software*, 2015, 32(6): 127-129, 202.
- [16] 党小超, 李芬芳, 郝占军. Delaunay 三角剖分的节点模糊信息三维定位方法[J]. *计算机工程与应用*, 2016, 52(23): 115-122, 243.
DANG X C, LI F F, HAO Z J. Method of node's fuzzy information localization about Delaunay triangulation in three-dimensional space[J]. *Computer Engineering and Applications*, 2016, 52(23): 115-122, 243.
- [17] 王继春, 黄刘生, 徐宏力, 等. 基于 Voronoi 图的无需测距的无线传感器网络节点定位算法[J]. *计算机研究与发展*, 2008, 45(1): 119-125.
WANG J C, HUANG L S, XU H L, et al. A novel range free localization scheme based on voronoi diagrams in wireless sensor networks[J]. *Journal of Computer Research and Development*, 2008, 45(1): 119-125.
- [18] 李芬芳, 党小超, 郝占军. 基于 Voronoi 图划分的节点模糊信息定位算法[J]. *计算机工程*, 2019, 45(1): 78-83, 90.
LI F F, DANG X C, HAO Z J. Node fuzzy information localization algorithm based on voronoi diagram partition[J]. *Computer Engineering*, 2019, 45(1): 78-83, 90.
- [19] LASLA N, DERHAB A, OUADJAOUT A, et al. Half-symmetric lens based localization algorithm for wireless sensor networks[C]//*Proceedings of 37th Annual IEEE Conference on Local Computer Networks*. Piscata-

- way: IEEE Press, 2012: 320-323.
- [20] SONG J, LIU M. A hidden Markov model approach for voronoi localization[C]//Proceedings of 2013 IEEE International Conference on Robotics and Biomimetics. Piscataway: IEEE Press, 2013: 462-467.
- [21] YANG X, LIU J. Sequence localization algorithm based on 3D voronoi diagram in wireless sensor network[J]. Applied Mechanics and Materials, 2014, 644/645/646/647/648/649/650: 4422-4426.
- [22] 孙大洋, 钱志鸿, 韩梦飞, 等. 无线传感器网络中多边定位的聚类分析改进算法[J]. 电子学报, 2014, 42(8): 1601-1607.
SUN D Y, QIAN Z H, HAN M F, et al. Improving multilateration algorithm by cluster analysis in WSN[J]. Acta Electronica Sinica, 2014, 42(8): 1601-1607.
- [23] 汤文华, 傅明. 基于 SVM 的 WSN 移动节点定位算法[J]. 计算机工程, 2012, 38(22): 76-79, 83.
TANG W H, FU M. Localization algorithm of mobile nodes in WSN based on SVM[J]. Computer Engineering, 2012, 38(22): 76-79, 83.
- [24] 蒋华, 蔡晨, 王慧娇, 等. 基于改进加权最小二乘支持向量机的 UWSN 定位[J]. 计算机测量与控制, 2021, 29(8): 250-254.
JIANG H, CAI C, WANG H J, et al. UWSN location based on improved weighted least squares support vector machine[J]. Computer Measurement & Control, 2021, 29(8): 250-254.
- [25] 吴艳玲. 一种基于局部信息最小二乘法的节点定位算法[J]. 吉林大学学报(理学版), 2017, 55(4): 952-956.
WU Y L. A node localization algorithm based on local information least square method[J]. Journal of Jilin University (Science Edition), 2017, 55(4): 952-956.
- [26] ZHU F, WEI J F. Localization algorithm for large scale wireless sensor networks based on fast-SVM[J]. Wireless Personal Communications, 2017, 95(3): 1859-1875.
- [27] 毛科技, 范聪玲, 叶飞, 等. 基于支持向量机的无线传感器网络节点定位算法[J]. 计算机研究与发展, 2014, 51(11): 2427-2436.
MAO K J, FAN C L, YE F, et al. Node localization algorithm in wireless sensor networks based on SVM[J]. Journal of Computer Research and Development, 2014, 51(11): 2427-2436.
- [28] 闫燕. 无线传感器网络三维定位精度优化方法研究[D]. 兰州: 西北师范大学, 2020.
YAN Y. An optimization method for three-dimensional location accuracy of wireless sensor network[D]. Lanzhou: Northwest Normal University, 2020.
- [29] 赵银龙, 安胜彪. 基于核化 K-means 和 SVM 分类回归的 Wi-Fi 室内定位算法[J]. 信息技术, 2018, 42(1): 113-117.
ZHAO Y L, AN S B. Wi-Fi indoor localization algorithm based on kernel K-means and SVM classification regression[J]. Information Technology, 2018, 42(1): 113-117.
- [30] FANG X M, JIANG Z H, NAN L, et al. Noise-aware localization algorithms for wireless sensor networks based on multidimensional scaling and adaptive Kalman filtering[J]. Computer Communications, 2017, 101: 57-68.
- [31] 曾碧, 毛勤. 改进的室内三维模糊位置指纹定位算法[J]. 山东大学学报(工学版), 2015, 45(3): 22-27.
ZENG B, MAO Q. Improved indoor 3-D fuzzy position fingerprint localization algorithm[J]. Journal of Shandong University (Engineering Science), 2015, 45(3): 22-27.
- [32] 王瑞. 基于模糊信息处理的传感器网络覆盖定位方法研究[D]. 西安: 西安电子科技大学, 2009.
WANG R. Study of coverage and localization methods based on fuzzy information processing in sensor networks[D]. Xi'an: Xidian University, 2009.
- [33] 石柯, 陈洪生, 张仁同. 一种基于支持向量回归的 802.11 无线室内定位方法[J]. 软件学报, 2014, 25(11): 2636-2651.
SHI K, CHEN H S, ZHANG R T. Indoor location method based on support vector regression in 802.11 wireless environments[J]. Journal of Software, 2014, 25(11): 2636-2651.
- [34] 周锦, 李炜, 金亮, 等. 基于 KNN-SVM 算法的室内定位系统设计[J]. 华中科技大学学报(自然科学版), 2015, 43(S1): 517-520.
ZHOU J, LI W, JIN L, et al. Indoor positioning system based on KNN-SVM algorithm[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2015, 43(S1): 517-520.

[作者简介]



李芬芳 (1990-), 女, 西北师范大学讲师, 主要研究方向为机器学习、无线网络定位技术和无线感知技术等。



党小超 (1963-), 男, 西北师范大学教授、硕士生导师, 主要研究方向为物联网、传感器网络、无线感知技术等。



郝占军 (1979-), 男, 博士, 西北师范大学教授、硕士生导师, 主要研究方向为位置服务、无线定位技术等。