

基于支持向量机的无线传感器网络节点定位算法

毛科技 范聪玲 叶 飞 王 鹏 陈庆章

(浙江工业大学计算机科学与技术学院 杭州 310023)

(qzchen@zjut.edu.cn)

Node Localization Algorithm in Wireless Sensor Networks Based on SVM

Mao Keji, Fan Congling, Ye Fei, Wang Peng, and Chen Qingzhang

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023)

Abstract Machine learning, as a learning method, uses the experience to improve its performance. The support vector machine (SVM), as a new model of the machine learning, is good at dealing with the condition of small sample size, nonlinear and high dimensional pattern recognition. The node localization algorithm based on SVM can locate the nodes in wireless sensor networks, WSN depending on the characteristics of machine learning algorithms. The basic idea is dividing the network area into several small aliquots of grids and each represents a certain class of machine learning algorithm. And when the machine learning algorithm learns the classes corresponding to the known beacon nodes, it will classify the unknown nodes' localization and then further determine the position coordinates of the unknown nodes. For the SVM "one against one" location algorithm, the simulation results show that it has higher location accuracy and better tolerance of the ranging error, which is suitable for the network environment where the beacon nodes are sparse as it doesn't require a high beacon node ratio. For the SVM decision tree location algorithm, the results show that it is not affected seriously by the coverage holes, which is applicable for the network environment where nodes distribution is uneven or the coverage holes exist.

Key words wireless sensor networks (WSN); node localization; support vector machine (SVM); region classification; coverage hole

摘 要 机器学习是利用经验来改善自身性能的一种学习方法,而支持向量机(support vector machine, SVM)作为机器学习中的一种新模式,在解决小样本、非线性及高维模式识别等方面有着其特有的优势.基于支持向量机的节点定位算法利用机器学习算法的特性,实现无线传感网络节点定位.其基本思路是将网络区域划分为若干个等分的小格,每一小格代表机器学习算法中一个确定的类别,机器学习算法在学习了已知的信标节点对应的类别后,对未知节点所处位置进行分类,从而进一步确定未知节点的位置坐标.仿真实验表明,“一对一”节点定位算法有较高的定位精度,对测距误差的容忍性较好,同时对信标节点的比例要求并不高,比较适合用于信标节点稀疏的网络环境中;而“决策树”节点定位算法受覆盖空洞的影响并不大,比较适合应用于节点分布不均匀或者存在覆盖空洞的网络环境中.

关键词 无线传感器网络;节点定位;支持向量机;区域分类;覆盖空洞

中图法分类号 TP393; TP212

收稿日期:2013-07-25;修回日期:2013-10-21

基金项目:国家自然科学基金项目(61379023);浙江省自然科学基金项目(LY12F02036);浙江省科技计划基金项目(2011C21014)

通信作者:陈庆章(qzchen@zjut.edu.cn)

在无线传感器网络(wireless sensor networks, WSN)中,位置信息对传感器网络的监测活动是非常重要的,节点定位已成为近年的研究热点^[1].机器学习作为一种利用经验来改善系统自身性能的方法,近十几年得到大力发展,在算法、理论和应用等方面都取得了巨大成功^[2].为建立一种高效、精确和鲁棒的节点自定位方法,本文将机器学习的思想引入到节点定位技术中,在深入研究支持向量机(support vector machine, SVM)学习算法的基础上,设计并实现了基于测距的“一对一”节点定位算法和无需测距的“决策树”节点定位算法.

1 机器学习在节点定位方面的应用

1.1 机器学习在节点定位方面的研究现状

关于机器学习在无线传感器网络节点定位方面的应用,目前已有不少研究成果.文献[3]提到机器学习方法已经被广泛应用到无线传感网络领域中,诸如解决能源感知通信、传感器节点优化部署和节点定位,以及无线传感网络中的任务调度等问题.该文献还指出,未来的研究将着重于无线传感网络的分布式学习的框架,而不是仅仅单纯地应用机器学习算法来解决某一个具体问题.

文献[4]提出了一种基于机器学习的蜂窝网络节点定位算法,主要解决了困扰基于信号参数的定位技术的边界问题与集中洞问题.

文献[5]设计了一种基于向量机的 WSN 移动节点定位算法,其在锚节点较少、节点运动速度较快的情况下能保持较低的定位错误率.

文献[6]提出了到达时间/到达时间差(time of arrival/time difference of arrival, TOA/TDOA)数据测量模型,并基于最小二乘 SVM 对定位算法作出改进,给出了基于 SVM 的数据融合定位算法,把定位问题转换为函数估计问题.该文献指出,计算复杂性和输入数据维数并无直接关联.因此,SVM 的数据融合技术可用于无线传感网络的数据处理.

文献[7]将未知节点的定位问题作为分类问题,提出了训练阶段和定位阶段.在训练阶段中参考节点的接收信号强度作为机器学习的输入,位置信息的离散值作为多类 SVM 的分类信息;在定位阶段,由多类 SVM 的判定函数来估计未知节点的位置.

文献[8]对无线传感网络中的目标跟踪问题提出了 2 种算法:基于最小二乘支持向量回归算法和基于 Platt 提出的后验概率回归算法,并比较了它们在精确性方面的性能.在室内环境中任意布置若

干节点,采用运动机器人小轮车作为发声源,实验目的即为通过节点来追踪其运动轨迹,将节点读取的感知声音数据作为输入,将所要求取的声源的实际位置作为输出.实验结果表明,基于最小二乘支持向量回归算法具有更好的精确性,更能符合物体实际运动的轨迹.

1.2 机器学习算法与节点定位

针对机器学习算法需要训练数据作为经验值的特性,可将信标节点之间的位置关系看作训练数据,而将未知节点与信标节点之间的位置关系看作测试数据.对训练数据提取特征,生成特征向量用于训练机器学习算法.机器学习算法可选择 Boosting、贝叶斯决策、神经网络等.由于一些机器学习算法本质上是两类别分类器,而定位问题从本质上是多类别分类,需要选择一种决策方法来构造多类决策问题,可选择决策树、“一对一”或“一对多”^[9]等决策准则.

机器学习算法一般由训练过程和测试过程组成.大多数机器学习算法的训练过程算法较为复杂,需要花费较多的资源,在资源受限的传感器节点中进行分布式处理需要较长的时间,可能会导致定位时间过长.因此,训练过程由计算能力较强、硬件资源较充分的汇聚节点集中完成.机器学习算法的测试过程也就是节点的定位阶段,测试过程算法相对简单,普通传感器节点完全可以胜任,即采用分布式处理方法.

SVM^[10]是一种新的机器学习模式识别方法,它在解决小样本、非线性和高维模式识别问题中具有其独特的优势,本文选取 SVM 作为节点定位的机器学习算法.

1.3 基于机器学习的节点定位基本思路

1) 建立网络模型.网络模型是根据定位机制来建立的.我们在建立网络模型(二维模型或三维模型)时,若网络中存在着一部分位置已知的信标节点,每个节点能够接收到部分在其通信范围内的信标节点的信号,则采用基于测距的定位机制,如图 1 所示;若网络中存在若干节点,但在其通信范围内没有任何的信标节点,则采用无需测距的定位机制,如图 2 所示.将整个网络区域划分为若干个等分的小格,每一个小格代表一个机器学习算法中确定的类别;机器学习算法在学习了已知信标节点所对应的类别后,对未知节点所处位置进行分类,那么机器学习算法的定位过程就是确定未知节点位于网络中的哪个小格;然后,用该小格的质心作为未知节点的位置坐标.




Fig. 1 Location-based positioning mechanism.

图1 基于测距的定位机制




Fig. 2 No ranging positioning mechanism.

图2 无需测距的定位机制

2) 提取特征向量. 在机器学习算法模型中, 特征向量的提取需要根据定位机制来确定. 如果采用基于测距的定位机制, 则采用节点之间的距离值来组成特征向量; 如果采用无需测距的定位机制, 则采用节点之间的跳数来组成特征向量.

3) 根据网络计算方式将网络通信过程分为 3 个阶段: 训练阶段、广播阶段和定位阶段. 训练阶段在信标节点之间进行, 使用底层单播路由协议来确定相互之间的位置信息, 然后汇总到汇聚节点, 在汇聚节点上运行机器学习训练算法, 计算相关参数; 广播阶段时, 由汇聚节点将机器学习算法模型广播给每个节点; 在定位阶段, 每个未知节点根据自己与信标节点位置关系来估算自己的位置坐标.

2 基于测距的 SVM“一对一”节点定位算法

2.1 SOAOLA 算法的设计

SVM 的基本理论是针对 2 类别分类问题提出的, 但在实际的应用领域中往往遇到的是多类别分

类问题. 求解多类别分类问题的一个途径就是构造一系列 2 类别问题, 并建立相应的 SVM 子分类器, 然后由这些子分类器对输入样本 x 的判定结果推断出 x 的所属类别. 在分类应用时文献[11]采用“投票法”来进行判决, 由此提出一种基于测距的 SVM“一对一”节点定位算法 (range-based SVM one against one location algorithm, SOAOLA).

2.1.1 建立网络模型

假设有 N 个节点 $\{S_1, S_2, \dots, S_N\}$ 的无线传感网络分布在二维区域 $[0, D] \times [0, D]$ 中, 有 k ($k < N$) 个信标节点 $\{S_1, S_2, \dots, S_k\}$ 其坐标位置信息已知, 其余的节点 $\{S_{k+1}, S_{k+2}, \dots, S_N\}$ 其坐标位置未知, 需要通过定位算法来估计. 假设节点的通信半径为 R , 每个节点仅能与在其无线射程范围内的信标节点通信.

2.1.2 SVM 建模

在传感网络区域中, 每一个节点估计自身到所有信标节点之间的距离 (包括不在其无线射程范围内的节点, 即不可达信标节点), 并在节点内生成一个距离向量 $[d(S_i, S_1), d(S_i, S_2), \dots, d(S_i, S_k)]$ ($i=1, 2, \dots, N$), 将所有信标节点所生成的距离向量作为 SVM 的训练特征向量, 未知节点所生成的距离向量作为测试特征向量.

分别将上述二维区域的水平、竖直方向等分为 M 段, 各形成 M 个类别. 这样 X 轴方向存在 M 个类 $\{cx_0, cx_1, \dots, cx_{M-1}\}$, 我们假定每个分类 cx_i 包含横坐标在 $[i \times D/M, (i+1) \times D/M]$ 内的传感器节点; 同理, Y 轴方向存在 M 个类 $\{cy_0, cy_1, \dots, cy_{M-1}\}$, 每个分类 cy_j 包含纵坐标在 $[j \times D/M, (j+1) \times D/M]$ 内的传感器节点, 每个类代表一个固定的区间长度. 此时, 已经将该二维无线传感网络区域划分为 M^2 个等分的区域小格, 每一个小格代表机器学习算法中一个确定的类别.

对每个维度方向均需使用 SVM 对信标节点的距离向量进行训练, 然后再对未知节点的距离向量进行分类. X 轴方向的 SVM 根据 X 轴的坐标类别和信标节点所生成的距离向量构成该 SVM 的训练数据 $\{cx_i, [d(S_i, S_1), d(S_i, S_2), \dots, d(S_i, S_k)]\}$.

SVM 对训练数据进行训练后可得到 SVM 的 3 个参数, 分别是支持向量 x_{ix} 、对应于该支持向量的 Lagrange 乘子 α_i^* 、分类阈值 b^* . 将未知节点内的距离向量作为测试数据 x , 采用“投票法”进行分类就可得到未知节点的 X 轴坐标类别; Y 轴方向的 SVM 训练和测试过程亦是如此.

经过测试后,当 SVM 判断未知节点 S 的坐标类别为 $[cx_i, cy_j]$ 时,就可得出 S 位于 $[i \times D/M, (i+1) \times D/M] \times [j \times D/M, (j+1) \times D/M]$ 的小格中;然后,将该小格的质心坐标 $[(i+1/2) \times D/M] \times [(j+1/2) \times D/M]$ 作为该未知节点 S 的估计位置坐标。

如果机器学习定位算法能正确判断出一个未知节点 S 处于某个小格,即区域分类正确,那么节点 S 的最大位置误差是 $\frac{\sqrt{2}}{2}D/M$ 。

2.2 SOAOLA 算法的过程描述

2.2.1 训练阶段

网络中的每个节点对在其无线通信范围内的信标节点发送一个 HELLO 信息包;而对不在其通信范围内的信标节点设为不可达。因此,每个节点(包括信标节点)都可知它与所有信标节点的距离,并生成距离向量存于该节点中。每个信标节点向汇聚节点发送一个 INFO 信息包: $\{ID, [x_i, y_i], [d(S_i, S_1), d(S_i, S_2), \dots, d(S_i, S_k)] (i=1, 2, \dots, N)\}$, 该 INFO 信息包包括信标节点的 ID 号、节点自身的坐标信息以及存于该节点内的距离向量。在汇聚节点中分别执行 X 轴和 Y 轴的 SVM 训练算法,计算出所有分类 $\{cx_0, cx_1, \dots, cx_{M-1}, cy_0, cy_1, \dots, cy_{M-1}\}$ 所对应的 SVM 参数信息 $\{x_{ix}, \alpha_{ix}^*, b_x^*\}, \{x_{iy}, \alpha_{iy}^*, b_y^*\}$ 。

2.2.2 广播阶段

汇聚节点将训练阶段计算出的 SVM 参数信息 $\{x_{ix}, \alpha_{ix}^*, b_x^*\}$ 和 $\{x_{iy}, \alpha_{iy}^*, b_y^*\}$ 广播给网络区域中的所有节点。

2.2.3 定位阶段

未知节点收到 SVM 参数信息后,根据自身生成的距离向量在节点内进行 SVM 分类,对其区域类别进行估计,并将该区域小格的质心坐标 $(x'(S_i), y'(S_i))$ 作为估计得到的位置坐标。

2.3 SOAOLA 算法的仿真实验及分析

本文仿真实验在 matlab 环境下进行,假设所有节点随机分布在 $50\text{ m} \times 50\text{ m}$ 的二维网络区域中,将该二维平面区域等分成 $10\text{ m} \times 10\text{ m}$ 的区域小格,则每个方向的类别数为 $M=5$ 。为得到更精确的实验结果,在同一网络参数设置下重复 50 次实验,最后取 50 次实验的均值。每次实验所有节点都被重新随机均匀布设。无线传感器网络节点定位算法的性能优劣会直接影响其应用,因此我们重点考虑该算法在定位误差、分类正确率及测距误差等方面的性能。

实验 1. 验证不同的信标节点比例和节点通信半径(图 3 中记为 R ,下同)对该定位算法的分类正

确率以及定位误差的影响。仿真结果如图 3 和图 4 所示:




Fig. 3 Beacon nodes proportions and R impact on the classification accuracy.

图 3 信标节点比例及 R 对分类正确率的影响




Fig. 4 Beacon nodes proportions and R impact on the positioning errors.

图 4 信标节点比例及 R 对定位误差的影响

如图 3 所示,在相同的通信半径下,分类正确率随信标节点比例的增大而增大;而在相同的信标节点比例下,通信半径越大分类正确率越高。通信半径越大、信标节点比例越高时,节点通信范围内覆盖的信标节点数就越多,定位算法在训练阶段所生成的距离向量更能准确反映节点的位置信息,因此分类正确率越高。

如图 4 所示,在相同的信标节点比例下,通信半径越大定位误差越小。在相同的通信半径下,定位误差随信标节点比例的增大而有所减小,但变化并不大,说明该算法对信标节点的比例要求并不高。因此,我们得出结论:该定位算法比较适合于信标节点稀疏的网络环境中。

实验 2. 比较在不同的信标节点比例(图 5 中用 BNP 表示)的情况下,测距误差对该定位算法的分类正确率及定位误差的影响. 固定通信半径取值为 20 m 进行仿真实验,仿真结果如图 5 和图 6 所示:




Fig. 5 Ranging errors influence on the correct rate of classification.

图 5 测距误差对分类正确率的影响




Fig. 6 Ranging errors influence on the positioning errors.

图 6 测距误差对定位误差的影响

图 5 显示在相同的测距误差条件下,信标节点比例越大分类正确率越高;而在同一信标比例下,分类正确率随着测距误差的增大而减小. 图 6 显示在同一测距误差下,信标节点比例越大定位误差越小. 在相同的信标节点比例下,定位误差的变化幅度并不大,说明该定位算法对测距误差的容忍性较好.

综合实验结果可知,该定位算法对信标节点的比例要求并不高;而分类正确率以及定位误差对测距误差变化的容忍性较好,比较适合于信标节点稀疏和测距误差较大的网络环境中;此外,算法的可靠性高,具有较强的鲁棒性和灵活性.

3 无需测距的 SVM“决策树”节点定位算法

在现有的很多定位技术中,要求待定位节点在多个信标节点的通信范围内^[12]. 在本文接下来的论述中,我们不需要这些严格的要求,认为每个节点可以通过单跳或多跳的方式与其他节点进行通信,这使得无需测距的 SVM“决策树”节点定位算法(rang-free SVM decision tree location algorithm, SDTLA)能够适用于更多类型的传感器网络.

在本节中,网络模型的建立与第 2 节即基于测距的 SVM“一对一”节点定位算法的过程大致类似,在此不再详述.

3.1 SVM 建模

将二维无线传感网络区域 $[0, D] \times [0, D]$ 的水平方向(即 X 轴方向)等分为 $M-1$ 个类别, $M=2^m$. 因此, X 轴方向存在 $M-1$ 个分类 $\{cx_1, cx_2, \dots, cx_{M-1}\}$, 在这里我们假定每个分类 cx_i 包含横坐标 $x \geq i \times D/M$ 的传感器节点; Y 轴方向存在 $M-1$ 个分类 $\{cy_1, cy_2, \dots, cy_{M-1}\}$, 每个分类 cy_j 包含纵坐标 $y \geq j \times D/M$ 的传感器节点.

首先,我们分别对所有 2 类别分类器进行训练;然后,把每个维度的 2 类别分类器组成一棵二叉决策树,同时把这些分类分配给树节点. 我们重点讨论 X 轴的情况, Y 轴类似. X 轴的二叉决策树如图 7 所示:




Fig. 7 X axis binary decision tree.

图 7 X 轴的二叉决策树

在图 7 中,每个树节点 cx_i 都是 X 轴的一个分类,节点的 2 个分支表示对该类的分类判定结果,“0”表示不属于该类,“1”表示属于该类. 针对这样的二叉决策分类树,我们就可以通过图 8 的算法来确定每一个未知节点 S 的 X 轴坐标信息. 同理可得 Y 轴坐标信息.




Fig. 8 SDTLA algorithm flowchart.
图8 SDTLA 算法流程图

若 X 轴 SVM 判断它属于 cx_i 类、不属于 cx_{i+1} 类,而 Y 轴 SVM 判断它属于 cy_j 、不属于 cy_{j+1} 类,即可得该未知节点 S 位于 $[i \times D/M, (i+1) \times D/M] \times [j \times D/M, (j+1) \times D/M]$ 的区域小格中,然后将该小格的质心坐标 $[(i+1/2) \times D/M] \times [(j+1/2) \times D/M]$ 作为该未知节点 S 的估计位置坐标。

3.2 SDTLA 算法过程描述

3.2.1 训练阶段

训练阶段将所有信标节点之间的位置关系作为训练数据. 首先,计算所有节点与信标节点之间的最小跳数,通过使用典型的距离矢量交换协议,节点之间相互交换信息. 每个信标节点发送一个 HELLO 信息包给网络中的所有节点,为防止信息包在网络区域中不断的循环转发,接收节点只记录距离每个信标节点最小跳数的信息包,并且丢弃来自同一信标节点的较大跳数的信息包,最终每个节点都可获得它与网络区域中所有信标节点之间的最小跳数距离,并生成距离向量 $[h(S_i, S_1), h(S_i, S_2), \dots, h(S_i, S_k)] (i=1, 2, \dots, N)$,存于该节点中。

然后,每个信标节点发送一个 INFO 信息包给汇聚节点,包格式如下:

$$\{ID, [x_i, y_i], [h(S_i, S_1), h(S_i, S_2), \dots, h(S_i, S_k)]$$

$$(i=1, 2, \dots, k)\}.$$

(1)

这样,汇聚节点包含了每个信标节点的 ID 号、坐标信息以及与其他信标节点之间的跳数距离等. 信标节点所处的类别是已知的. 在汇聚节点中,分别执行 X 轴及 Y 轴的 SVM 训练算法,计算出所有分

类 $\{cx_1, cx_2, \dots, cx_{M-1}, cy_1, cy_2, \dots, cy_{M-1}\}$ 所对应的 SVM 参数信息 $\{x_{ix}, \alpha_{ix}^*, b_x^*\}, \{x_{iy}, \alpha_{iy}^*, b_y^*\}$.

3.2.2 广播阶段

在广播阶段,汇聚节点把前一阶段计算出的 SVM 分类参数信息 $\{x_{ix}, \alpha_{ix}^*, b_x^*\}, \{x_{iy}, \alpha_{iy}^*, b_y^*\}$ 广播给网络区域中的各节点。

3.2.3 定位阶段

未知节点在收到汇聚节点广播的 SVM 分类参数信息后,将与各信标节点的跳数向量(最小跳数距离)作为测试数据,通过“决策树”进行分类,判断区域类别,从而得出未知节点的估计位置坐标 $(x'(S_i), y'(S_i))$ 。

3.3 误差分析

SVM 在分类过程中会出现分类错误的情况,如图 9 和图 10 所示. 我们假设节点 S 的实际坐标




Fig. 9 Analysis of the classification error when $3D/4 \leq x(S) \leq D$.

图9 当 $3D/4 \leq x(S) \leq D$ 时的分类错误情况分析

$x(S) \geq D/2$, 令 $x = x_1 x_2 \cdots x_m$ 为节点 S 在决策树上实际分类的正确路径(图 9、图 10 里的路径 A), 而 $x' = x'_1 x'_2 \cdots x'_m$ 为定位算法预测的决策树分类路径(图 9、图 10 中的路径 B).




Fig. 10 Analysis of the classification error when $D/2 \leq x(S) \leq 3D/4$.

图 10 当 $D/2 \leq x(S) \leq 3D/4$ 时的分类错误情况分析

定义 ϵ 为机器学习算法在分 $M-1$ 个类别时的最高分类错误率, 一般情况下决策准则均由多个独立的分类步骤组成, 因为该定位算法需要 m 个独立的分类步骤, 定义 i 为分类错误的次数, $p(i)$ 为发生 i 次分类错误的概率, 则有:

$$p(i) = C_m^i \epsilon^i (1-\epsilon)^{m-i}. \quad (2)$$

同时, 我们定义 $e_i(x) = |x' - x|$ 为当发生 i 次分类错误时计算得到的误差最大值, 其中 x 为正确分类路径, x' 为错误分类路径. 由此计算可得节点在 X 轴方向上的定位误差期望上界为

$$E_X^f = \sum_{x=M/2}^{M-1} e_X(x) f(x) = \frac{D}{M} \left(\frac{1}{2} + \sum_{x=M/2}^{M-1} \sum_{i=1}^m p(i) e_i(x) f(x) \right), \quad (3)$$

其中, $f(x)$ 是在 $x(S) \geq D/2$ 内节点被分为正确路径 x 的概率. 对于均匀分布的传感器网络, $f(x) = 1/(M/2) = 1/2^{m-1}$. 由此, E_X^f 也可写为

$$E_X^u = \frac{D}{M} \left(\frac{1}{2} + \sum_{x=M/2}^{M-1} \sum_{i=1}^m p(i) e_i(x) / 2^{m-1} \right). \quad (4)$$

对计算出的 E_X^u 进行推导与演算, 可证明:

$$E_X^u = D \left(\frac{3}{4} + \frac{1}{2^m} + \left(\frac{2^m - 4}{2^{m+3}} \right) (1-\epsilon)^m + \frac{(2-\epsilon)^m}{2^m} + \frac{(4-3\epsilon)^m}{2^{2m+3}} \right). \quad (5)$$

因此, 对于均匀分布的传感器网络, 则可得到节点 S 在多个方向轴上的平均定位误差界为 $E^u =$

$\sqrt{2} E_X^u = \sqrt{2} E_Y^u$ (二维情况) 或 $E^u = \sqrt{3} E_X^u = \sqrt{3} E_Y^u$ (三维情况).

由式(5)可知, 影响定位误差的参数为 ϵ 和 m , ϵ 与选择的机器学习算法有关. 固定 ϵ 值, 通过控制 m 值的变化可以减小定位误差界. 分析参数 ϵ 和 m 取不同值时对定位误差的影响, 可以得出 m 的取值一般不应大于 8. 如图 11 所示:




Fig. 11 Positioning error expectation figure.

图 11 定位误差期望图

3.4 SDTLA 算法仿真与分析

实验假设所有节点被随机分布在 $50 \text{ m} \times 50 \text{ m}$ 的二维无线传感器网络区域(在图 12、图 14、图 15 中的节点分布图中用 $Length \times Width$ 来表示二维空间), 针对在无覆盖空洞^[13]的网络区域和有覆盖空洞的网络区域 2 种情况, 通过对该定位算法与其他定位算法比较, 来分析定位误差.

实验 3. 在无覆盖空洞的网络环境中, 将该定位算法下的定位误差与其他定位方法进行比较, 固定节点通信半径取为 10 m, 仿真结果如图 12 和图 13 所示:




Fig. 12 Random distribution.

图 12 随机分布图




Fig. 13 Beacon nodes proportional impact on the positioning errors.

图 13 信标节点比例对定位误差的影响

如图 13 所示,SDTLA 算法的定位效果明显好于 DV-HOP^[14] 及 Amorphous^[15] 定位算法. DV-Hop 定位算法的基本思想是未知节点首先计算与参考节点的最小跳数,然后计算平均每跳距离,利用最小跳数和平均每跳距离的乘积来得到未知节点与参考节点之间的估计距离,最后利用三边定位法或极大似然估计法来计算未知节点的位置坐标. Amorphous 定位算法假设单个节点的连通度已知,要求在网络部署前离线计算平均每跳距离,待定位节点收集相邻节点的梯度值,计算关于某个参考节点的局部梯度平均值,带定位节点使用局部梯度平均值与每跳距离的乘积来计算与每个参考节点间的距离.最后应用多边测量法可以计算出未知节点的位置.随着信标节点比例的增大,3 种定位算法的定位精度都有所提高,但 SDTLA 算法所代表的折线下降坡度更大,定位更精确.可见,SDTLA 算法比较适合于对定位精度要求较高的网络环境中.

实验 4. 在网络区域中,分别以点(12.5,12.5)、点(37.5,12.5)、点(24.5,37.5)这 3 处为圆心,设置以 7.5 m 为半径的覆盖空洞.针对有覆盖空洞的网络区域,对该定位算法与其他定位方法比较定位误差的大小,固定节点通信半径为 10 m,仿真结果如图 14~16 所示.

通过综合分析,如图 13 和图 16 所示,当覆盖空洞存在时,虽然 SDTLA 算法的定位精度有所降低,但受覆盖空洞的影响并不大;DV-HOP 和 Amorphous 的定位精度却急剧下降.我们认为 SDTLA 定位算法较适用于节点分布不均匀或者存在覆盖空洞的环境中.




Fig. 14 The laid diagram nodes when coverage holes nodes exist.

图 14 有覆盖空洞时的节点布设图




Fig. 15 Neighbor nodes layout diagram.

图 15 节点布设邻居关系图




Fig. 16 Beacon nodes proportional impact on the positioning errors.

图 16 信标节点比例对定位误差的影响

从图 16 可以看出,SDTLA 算法较之于 DV-HOP 及 Amorphous 有更好的定位效果,定位误差更小.

4 结 论


本文将机器学习的思想引入到无线传感器网络节点定位技术中,将信标节点之间的位置关系作为训练数据,而将未知节点与信标节点之间的位置关系作为测试数据.算法在对训练数据进行训练后,将SVM参数信息广播给网络中的所有节点,未知节点收到后根据自身与信标节点间的距离关系来进行节点自定位.仿真结果表明,SOAOLA定位算法对测距误差的容忍性较好,比较适合用于信标节点稀疏的网络环境;而SDTLA算法的定位性能受覆盖空洞的影响并不大,算法稳定性较高,适合应用在节点分布不均匀或存在覆盖空洞的网络环境中.

参 考 文 献


- [1] Li Jianzhong. Foreword special issue in wireless sensor networks [J]. Journal of Software, 2007, 18(8): 1077-1079 (in Chinese)
(李建中. 无线传感器网络专刊前言[J]. 软件学报, 2007, 18(8): 1077-1079)
- [2] Yu Kai, Jia Lei, Chen Yuqiang, et al. Deep learning: Yesterday, today, and tomorrow [J]. Journal of Computer Research and Development, 2013, 50(9): 1799-7804 (in Chinese)
(余凯, 贾磊, 陈雨强, 等. 深度机器学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-7804)
- [3] Di M, Joo M. A survey of machine learning in wireless sensor networks from networking and application perspectives [C] //Proc of the 6th Int Conf on Information, Communications & Signal Processing. Piscataway, NJ: IEEE, 2007: 1-5
- [4] Wang Luda, Gao Shouping, Fang Fang, et al. Research of the node localization algorithm based on machine learning for cellular networks [J]. Computer Engineering & Science, 2010, 32(8): 56-59 (in Chinese)
(王鲁达, 高守平, 方芳, 等. 基于机器学习的蜂窝网络节点定位算法研究[J]. 计算机工程与科学, 2010, 32(8): 56-59)
- [5] Tang Wenhua, Fu Ming. Localization algorithm of mobile nodes in WSN based on SVM [J]. Computer Engineering, 2012, 38(22): 76-83 (in Chinese)
(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): 76-83)
- [6] Wang W, Huang T L, Liu H, et al. Localization algorithm based on SVM-data fusion in wireless sensor networks [C] //Proc of the 3rd Int Conf on Genetic and Evolutionary Computing. Piscataway, NJ: IEEE, 2009: 447-450
- [7] Liu H B, Xiong S W, Chen Q. Localization in wireless sensor network based on multi-class support vector machines [C] //Proc of the 5th Int Conf on Wireless Communication Networking and Mobile Computing. Piscataway, NJ: IEEE, 2009: 1-4
- [8] Kim W, Park J, Kim H. Support vector learning approaches for object localization in acoustic wireless sensor network [C] //Proc of the 5th Int Conf on Intelligent Systems. Piscataway, NJ: IEEE, 2010: 485-489
- [9] Bian Zhaoqi, Zhang Xuegong. Pattern Recognition [M]. 2nd ed. Beijing: Tsinghua University Press, 2008 (in Chinese)
(边肇祺, 张学工. 模式识别[M]. 2版. 北京: 清华大学出版社, 2008)
- [10] Deng Naiyang, Tian Yingjie. Support Vector Machine—Theory, Algorithms and Expand [M]. Beijing: Science Press, 2009 (in Chinese)
(邓乃扬, 田英杰. SVM——理论、算法与拓展[M]. 北京: 科学出版社, 2009)
- [11] Vapnik V. The Nature of Statistical Learning Theory [M]. 2nd ed. Berlin: Springer, 2000
- [12] Yu Hongyi, Li Ou, Zhang Xiaoyi, et al. Wireless Sensor Networks Theory, Technique and Implementation [M]. Beijing: National Defense Industry Press, 2008 (in Chinese)
(于宏毅, 李鸥, 张效义, 等. 无线传感器网络理论与实现[M]. 北京: 国防工业出版社, 2008)
- [13] Li Xiaowei. Technique for Wireless Sensor Networks [M]. Beijing: Beijing Institute of Technology Press, 2007 (in Chinese)
(李晓维. 无线传感器网络技术[M]. 北京: 北京理工大学出版社, 2007)
- [14] Niculescu D, Nath B. DV based positioning in ad hoc networks [J]. Telecommunication Systems, 2003, 22(1/2/3/4): 267-280
- [15] Nagpal R, Shrobe H, Bachrach J. Organizing a global coordinate system from local information on an ad hoc sensor network [C] //Proc of the 2nd Int Workshop on Information Processing in Sensor Networks. Berlin: Springer, 2003: 333-348



Mao Keji, born in 1979. PhD in Zhejiang University of Technology. His main research interests include wireless sensor networks and data mining.



Fan Congling, born in 1989. Master in Zhejiang University of Technology. Her main research interests include wireless sensor networks and application.



Wang Peng, born in 1987. Master in Zhejiang University of Technology. His main research interests include machine learning and data mining.



Ye Fei, born in 1989. Master candidate in Zhejiang University of Technology. His main research interests include machine learning and data mining.



Chen Qingzhang, born in 1955. Professor and PhD supervisor in Zhejiang University of Technology. Senior member of China Computer Federation. His main research interests include wireless sensor network, data mining and education technology.

研发动态

氮化镓植于石墨烯可制成弯曲 LED 材料

由韩国首尔大学伊圭哲教授领导的研究小组将微型的氮化镓棒植于石墨烯薄膜表面,制成了一种可弯曲和伸缩的 LED 材料,这意味着可弯曲变形的显示器等 LED 产品或许将广泛出现在我们的生活之中.为了真正用氮化镓在石墨烯基板上制造出微型 LED,研究小组使用了一种于 2002 年自主发明的无催化剂的有机金属化学气相沉积法(MOCVD).这项技术的关键是要在维持高结晶度的情况下控制掺杂,使其形成异质结构和量子结构并垂直对齐生长于底层基板上.随后,研究小组将特制而成的氮化镓 LED 细棒植入石墨烯表面进行了测试,结果发现,这种能弯曲的 LED 在通电后具有优异且可靠的发光能力,甚至在 1000 次弯折测试后,材料的发光性能依旧没有明显的退化.这项成果无疑是一项重大技术突破,也为下一代电子和光电器件找到了大规模、低成本工业化生产的可能手段.而石墨烯薄膜在材料领域的广泛应用也将会催生更多强强联合的卓越材料,拉近我们与新时代的距离(摘自:<http://www.stdaily.com/>,2014-09-28,科技日报).

欧洲研究团队成功合成二维材料锗烯

艾克斯-马赛大学的一个欧洲联合研究团队成功合成石墨烯的又一“表亲”,即二维材料锗烯(germanene).该材料是由单层锗原子构成,具备表现出色的电学和光学性质,未来有可能被广泛集成在各种电子设备中.这种二维材料最早于 2009 年被提出,但截至目前,研究人员仍然难以将其实现.而自那时起石墨烯已被进一步开发,其他的二维材料如硅烯(silicene)已被合成出.用于合成这种方法类似于硅烯,在超高真空中,单个锗原子在高温下沉积成一层基底.研究人员已经将该材料合成到铂金基板上.将锗原子沉积于铂金基底后,研究人员通过光谱测量和密度泛函理论(DFT)计算,检测该材料的电子结构,实际上能够确认其是锗烯.并且,采用隧穿显微镜扫描该材料,揭示出其 2D 材料的特性蜂窝结构.其独特的性质可能使之成为坚固的二维拓扑绝缘体,特别是在室温下,这将开启使用该材料进行量子计算的可能性(摘自:<http://www.stdaily.com/>,2014-09-15,科技日报).

英国政府以“数字市场”替代“云商城”

英国政府拟于 2014 年 9 月底关闭“云商城”(CloudStore).届时,“数字市场”将成为“政府云”(G-Cloud)用户获取服务的唯一途径.“政府云”是英国政府“云优先”(Cloud First)战略的核心部分,向公共机构提供一系列云服务,以减少各部门复杂的投标及采购过程.英国内阁办公室将逐步推行这项“数字市场”计划.英国政府数字服务部门(Government Digital Service,GDS)数字商业服务的负责人马吉克称:在推广“数字市场”的第一阶段,我们致力于让购买者更便捷地获得服务;目前,则致力于为供应商完善“数字市场”的各项功能.供应商将根据内阁办公室的要求列出各项云服务的特征,以便用户能在多重标准下对服务进行筛选和比较(摘自:<http://www.echinagov.com/>,2014-10-09,国脉电子政务网).

日本拟用大数据分析海外局势强化情报收集能力

日本防卫省将从 2015 年开始正式研讨将互联网上累积的“大数据”运用于海外局势的分析.这一举措作为自卫队海外活动扩大背景下的新方案,旨在强化情报收集能力.日本防卫省中由情报总部负责关于海外恐怖活动和国际争端的情报收集和分析工作.以往对网络信息进行分析的过程中难以证实真伪,分析耗时长等工作效率低下成为主要问题.为此,日本防卫省在 2015 财年预算概算申请中计入了为开发能高效分析大数据的软件所需的调查费等 500 万日元(约合人民币 28.5 万元).情报总部还将增加负责分析的人员数量以强化应对能力(摘自:<http://www.echinagov.com/>,2014-09-17,国脉电子政务网).