

一种移动无线传感器网络的节点位置预测方法

夏扬波¹ 杨文忠^{1,2} 张振宇² 王庆鹏¹ 石 研¹

(新疆大学软件学院 乌鲁木齐 830046)¹ (新疆大学信息科学与工程学院 乌鲁木齐 830046)²

摘 要 针对目前移动无线传感器网络中现有位置预测方法的预测精度较低以及需要依靠大量的历史运动路径数据的不足,提出了一种基于不确定性支持向量机的“角度-分类”(A-USVC)位置预测方法。该方法利用节点收集的节点隶属度向量来构建归类预测模型,根据所构建的预测模型和计算的移动节点偏转方向来确定未知节点所在的区域,从而完成对移动未知节点的位置预测。仿真实验表明:在精度方面,该方法相比于传统的马尔科夫模型预测方法提高了 35%,相比于神经网络预测方法提高了 19%。A-USVC 位置预测方法有效地提高了位置预测的精度,且计算量小,在小样本的情况下依然能保持良好的预测能力。

关键词 不确定性支持向量机,位置预测,移动无线传感网,节点隶属度向量

中图分类号 TP393 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.08.020

Node Position Prediction Method for Mobile Wireless Sensor Networks

XIA Yang-bo¹ YANG Wen-zhong^{1,2} ZHANG Zhen-yu² WANG Qing-peng¹ SHI Yan¹

(College of Software, Xinjiang University, Urumqi 830046, China)¹

(College of Information Science and Technology, Xinjiang University, Urumqi 830046, China)²

Abstract In view of the defects that the prediction accuracy of the existing position prediction method is low and a large number of historical movement path data need to be relied on in mobile wireless sensor network, this paper proposed an A-USVC position prediction method based on uncertain supporting vector machines. This method uses the node membership vector collected by nodes to construct classification prediction model. On the basis of the constructed prediction model and the calculated moving deflecting direction of mobile node, the location of unknown node is determined. Therefore, the position of unknown mobile node can be predicted. The simulation tests show that the proposed method improves the accuracy by 35% compared with the traditional Markov model prediction method, and improves the accuracy by 19% compared with the neural network prediction method. The A-USVC position prediction method can improve the position prediction accuracy effectively, which has low computational complexity and can also maintain good prediction ability in the case of small samples.

Keywords Uncertain support vector machines, Position prediction, Mobile wireless sensor network, Node membership vector

1 引言

近年来,移动无线传感器网络(Mobile Wireless Sensor Network, MWSN)快速发展,被广泛应用于各个领域,例如牧区牲畜的监测、动物行为习性研究的监测等^[1]。在上述应用场景中,移动无线传感器网络主要负责采集与传输数据,在收集相关信息的过程中其各节点的自身位置信息也至关重要。目前,国内外许多研究学者在前人的研究成果上纷纷提出了对移动节点的下一位置进行预测的方法。位置预测具有深远的现实意义,如动物迁徙的研究、牧区牲畜防走失找回和井下

矿难救援位置预测等,其对于基于位置的路由建立也具有一定的参考价值。常用的位置预测方法有基于马尔科夫模型的位置预测^[2-4]、基于机器学习神经网络模型的位置预测^[5-7]以及近几年新提出的利用数据挖掘的相关技术进行位置预测的方法^[8-9]等,但是这些方法通常需要移动对象的大量历史运动轨迹。本文主要研究由人或动物携带传感器节点的移动传感器网络节点位置预测。为了简化计算,不考虑由人体或动物携带所带来的各种干扰因素,将移动对象直接看作移动传感器网中可移动的节点来进行位置预测。

Mathew 等^[10]提出了一种基于隐马尔科夫模型的混合方

到稿日期:2017-07-14 返修日期:2017-12-30 本文受国家自然科学基金项目(U1603115,61262087),国家 973 计划项目(2014CB340500),新疆高校教师科研计划重点资助项目(XJEDU2012I09)资助。

夏扬波(1992—),男,硕士生,CCF 会员,主要研究方向为网络安全、移动无线传感器网络;杨文忠(1971—),男,博士,副教授,CCF 会员,主要研究方向为物联网、网络安全,E-mail:ywz_xy@163.com(通信作者);张振宇(1964—),男,博士,教授,CCF 会员,主要研究方向为机会网络、移动社会网络;王庆鹏(1990—),男,硕士生,主要研究方向为舆情分析、信息安全;石 研(1991—),女,硕士生,主要研究方向为软件工程技术、移动无线传感网。

法来预测移动对象运动的轨迹,将历史位置数据相对集中的位置集合成一个关键点,然后提取相应的定位特征,最后训练出一个位置预测的隐马尔科夫模型;该方法的不足在于需要大量的历史运动轨迹来提取相应特征。Manjith等^[11]通过对移动节点的位置进行跟踪与预测来减少移动节点在接入新网络链路切换的过程中产生的切换延迟;通过位置跟踪和数据挖掘来预测移动节点的移动,在位置跟踪过程中监视移动节点的移动,在移动节点位置预测中采用数据挖掘技术对移动节点的历史路径进行搜索,并利用该信息预测移动节点未来的移动路径;同时,结合NG剪枝排除预测过程中不可能访问到的位置。但该预测方法存在计算量大且需要大量历史路径的数据集等问题。李幸超等^[12]提出了一种基于循环神经网络的位置预测算法,通过待预测位置与已访问位置之间可能存在的某种关联关系,将离散化的重要位置索引序列作为模型的输入,提取位置的特征向量和位置之间的相关性进行下一位置的预测。但该方法存在模型训练时间长以及算法容易陷入局部最优值从而导致建模失败的问题。

由上文可知,尽管目前的移动节点位置预测方法不尽相同,但都存在一定的局限性。为了在小样本运动轨迹的情况下有效地预测移动节点下一时刻的运动位置,本文提出了基于不确定性支持向量机的A-USVC预测方法。该方法在未知节点运动速度半径圆与所预测归属的信标节点通信半径圆的相交部分取值,再结合移动节点偏转方向来进一步减少未知节点的位置取值个数,去除错误位置点的影响,取剩余位置点的均值作为最终的预测结果。

最后,本文使用Matlab进行仿真实验,将所提方法与文献[3]提出的马尔科夫位置预测方法以及文献[6]提出的神经网络位置预测方法进行了性能对比和验证。实验结果表明,本文提出的A-USVC位置预测方法相比于传统的隐马尔科夫模型预测法的精度提高了35%,比神经网络预测法的精度提高了19%,整体上有效提高了位置预测的精度,且预测能力在小样本的情况下依然适用,计算量相对较小。

2 不确定性 SVM 及遗传算法概述

不确定性支持向量机是在支持向量机的基础上,因应用领域含有不确定性信息而提出,它能有效地处理不确定性信息条件下的模式分类、回归预测、聚类分析和有序回归等问题。遗传算法是根据达尔文生物进化论提出的一种启发式优化算法,与传统的非凸优化算法相比,由于其从问题解的串集开始搜索,覆盖面积大,利于全局择优;而传统非凸优化算法是从单个初始值迭代求解,容易陷入局部最优。

2.1 不确定性支持向量机

支持向量机(Support Vector Machine, SVM)是由Vapnik与其领导的贝尔实验室的研究小组一起研发出来的一种新的机器学习技术^[13]。不确定性支持向量机(Uncertain Support Vector Machine, USVM)是在支持向量机的基础上,在其应用领域含有不确定性信息的前提下建立的^[14],"不确定性信息"一般指隶属度、百分比等。由于现实世界中,能够进行精确描述的问题只占较少一部分,而大多数问题是不确定的,因此不确定性支持向量机具有广泛的应用领域。不确

定性支持向量分类(Uncertain Support Vector Classifier, USVC)根据给定的训练样本 H 求出各类样本点之间的最佳分类超平面,并使其分类间隔最大,从而不但能将未知样本点正确分类,还能使错误率降至最低。

假定现有训练样本集 H 为:

$$\{(x_i, s_1), (x_i, s_2), \dots, (x_i, s_{n-1}), (x_i, s_n), i=1, 2, \dots, n\}$$

其中, $x_i \in R^n$ 为样本类别, $s_i \in [0, 1]$ 表示第 i 个样本点对于某一类别的隶属度。USVC问题就是希望找到最合适的分类超平面 $\{(\omega \cdot x) + b = 0 | x \in G, \omega \in G, b \in R\}$ 来使各类样本都能区分开来,其中 ω 是一个垂直于超平面的向量, b 为分类超平面的阈值, G 是内积空间。在线性可分的条件下构建最优分类超平面,相应地就转化为求解以下二次规划问题,即:

$$\begin{cases} \min_{\omega, \xi, b} \frac{1}{2} \langle \omega \cdot \omega \rangle + C \sum_{i=1}^l s_i \xi_i \\ \text{s. t. } y_i (\omega \cdot x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i=1, 2, \dots, l \end{cases} \quad (1)$$

其中, $C > 0$ 为惩罚参数,表示对错误分类样本点的惩罚程度, C 越大则惩罚越重。 ξ_i 为松弛变量, $\xi = (\xi_1, \xi_2, \dots, \xi_l)^T$ 。上述问题是一个二次规划问题,其最优解为Lagrange函数的鞍点。对于含有不等式约束的优化问题,其最优解还应满足Karush-Kuhn-Tucker条件,最后求得的线性最优分类函数为:

$$f(x) = \text{sgn}[\langle \omega^* \cdot x_i \rangle + b^*], x_i \in R^n \quad (2)$$

其中, $\omega^* = \sum_{i=1}^l \alpha_i^* y_i x_i, b^* = y_j - \sum_{i=1}^l y_i \alpha_i (x_i \cdot x_j), j \in \{j | 0 < \alpha_j^* < s_j C\}$; $\text{sgn}[\cdot]$ 为符号函数。

对于非线性问题,引入核函数 $K(x, y)$ 即可解得其最优分类函数。选择不同的核函数会产生不同的支持向量机,核函数的类型较多,常用的核函数如下^[15]。

- 1) 线性核: $K(x, y) = \langle x \cdot y \rangle$;
- 2) 多项式核: $K(x, y) = [\langle x \cdot y \rangle + c]^d, c \geq 0$;
- 3) 高斯(径向基函数或RBF)核:

$$K(x, y) = \exp\left\{-\frac{\|x - y\|^2}{2g^2}\right\}$$

- 4) 二层神经网络核:

$$K(x, y) = \tanh[k \langle x \cdot y \rangle + \delta], k > 0$$

本文在建模过程中使用RBF核函数的主要原因有:

- 1) RBF核函数适用于非线性的样本集且参数只有 g ,参数的数量直接影响着模型的复杂程度;
- 2) RBF核函数的核值范围在 $(0, 1)$ 之间,这会使得计算过程变得相对简单,减少了运算量,加快了计算速度。

特别地,式(1)中的惩罚参数 C 和高斯核函数中的核参数 g 是求解过程中两个未确定的参数,它们与训练样本一起共同确定了最优分类平面。为了使分类效果达到最佳,本文采用启发式遗传算法同时优化这两个未知参数。

2.2 启发式遗传算法

遗传算法(Genetic Algorithm, GA)是模拟自然界自然选择和遗传机制随机搜索的全局优化算法^[16],其基本思想是利用遗传算子对解空间内的每个个体进行"进化和变异"操作,从而产生更优的一代个体,直到达到终止条件。遗传算法主要由以下几个部分组成:基因编码、种群初始化、适应度函数、遗传操作和终止条件等。

- 1) 基因编码

遗传算法不能直接处理问题空间的参数,必须将它们转

换成遗传空间的由基因按一定结构组成的染色体或个体。实数编码比二进制编码的精度更高,适应性更强,因此对此优化问题的解(C, g)采用实数编码,每个可行解作为一个染色体或个体。

2) 种群初始化

为了不盲目设置初始种群中的个体,本文采用 USVM 中的交叉验证策略来产生初始种群样本(C, g)。重复多次采集,使种群的初始个数达到预设值 20。

3) 适应度函数

遗传算法中的适应度函数也称评价函数。本文模型的评价标准是预测位置越接近实际位置越好。将个体的适应度函数选为对同一测试集的均方误差 (Mean Squared Error, MSE), MSE 越小,适应度值越大,反之越小。均方误差可以很好地评价预测模型的预测效果。

$$MSE = \frac{1}{n} \sum_{i=1}^n (observed_i - predicted_i)^2 \tag{3}$$

4) 遗传操作

遗传操作包括以下 3 个基本遗传算子:选择、交叉和变异。使用遗传选择算子操作之前,首先必须根据个体适应度函数进行概率选择,即适应度值大的个体被选中产生下一代的概率较大,可以采用正态几何排序方法来确定,第 i 个个体被选中的概率 p_i 的计算式为:

$$p_i = q(1 - q^{r-1}) / [1 - (1 - q)^p]$$

其中, p 为个体的总数, q 为选中最优个体的概率, r 为个体的排序等级。遗传交叉算子采用顺序交叉算子,交叉点位置是随机指定的。因为基因编码采用的编码方式是实数编码,所以遗传变异算子采用与基因编码相对应的实值变异。

5) 终止条件

当最优个体(C, g)和训练数据所确立的预测模型计算出的预测位置与实际位置之间的均方误差 MSE 小于设定的 0.01,或者迭代的次数 N 达到预设的 100 时,算法终止。

3 基于不确定性 SVM 的节点位置预测

本文提出的 A-USVC 位置预测方法是在前人对不确定性支持向量机深入研究的基础上提出的,结合了启发式遗传算法来辅助建模过程中的参数寻优,并利用移动节点偏转方向计算来筛选取值点,提高预测精度。信标节点均匀分布在矩形区域中,位置固定,未知节点在区域内随机运动,区域中每一个信标节点都被看成不同的类,类标签为 ID 号。对于未知节点位置的预测,首先以单位时间内(实验设置单位时间间隔为 1min)移动节点运动的最大速度 v 为半径作圆,随机采样 m 个可能的位置点;其次,利用训练好的归类预测模型根据未知节点收集的节点隶属度向量值的变化,预测未知节点下一时刻将要接近哪个信标节点,并将其归属为所接近的信标节点,未知节点所在的位置为节点最大运动速度半径圆与所归属信标节点通信半径圆之间的相交区域;然后,利用移动节点的偏转方向进一步缩小未知节点所在的区域,排除不可能的坐标位置点,从而减小错误位置点对最终预测结果的影响;最后,取剩余可能位置点的均值作为位置预测的结果。

3.1 传感器网络模型及数据集

本文的应用场景为同构式二维移动传感器网络,网络中

随机均匀分布着 200 个信标节点 S,任意时刻信标节点都知道自己所在位置且固定。各节点的通信半径 R 相同且未覆盖全网络,每个节点仅能与在其通信半径内的节点通信。每个节点上均有信号接收装置用于接收和测量其他节点到自身节点的距离 d 的信号强度。令 P_r(d)表示接收者 j 在距离信号源 i 的距离为 d 的位置处接收到的信号强度(假设信号在自由空间传播的过程中不受反射、散射或者遮蔽等干扰),则它们之间的关系可以用 Friis 公式表示为:

$$P_r(d) = \left(\frac{\lambda}{4\pi d}\right)^2 P_t G_t G_r \tag{4}$$

其中, P_t 为信号源的传输功率, G_t 和 G_r 分别代表天线在发送和接收信号时的增益, λ 为电磁波的波长。假设信号源信标节点 i 自身测量的信号强度的大小为 P_i,则有:

$$A[P_i, P_j] = \frac{P_r(d)}{P_i} \tag{5}$$

其中, A[P_i, P_j]为未知节点 j 隶属于信标节点 i 的隶属度,该隶属度表示节点 j 处所接收到信标节点 i 的信号强度大小与信标节点 i 自身信号强度大小的比值。由此,可以建立节点隶属度向量:

$$\vec{B} = \{ID, (x_i, y_i), A[P_i, P_1], A[P_i, P_2], \dots, A[P_i, P_{n-1}], A[P_i, P_n], A \in (0, 1)\}$$

其中, ID 表示第 i 个信标节点的编号,在分类中作为分类标签;(x_i, y_i)是信标节点 i 的坐标位置。由于未知节点处于运动的状态,因此其收集的节点隶属度向量 B 中的每一个值 A 在时刻变化,即 A[P_i, P_j]越接近于 1,两个节点靠得越近,根据 A 值的变化规律便可预测出未知节点的运动位置。A ~ [0, 1]简化了直接使用信号强度来进行计算的复杂度,提高了计算效率。

3.2 移动节点偏转方向的计算

由于移动节点的运动状态具有马尔科夫过程性质,即下一时刻节点的运动状态完全依赖于节点运动的上一时刻,因此特意截取移动节点的前两个时刻的运动状态。根据节点运动的前两个时刻的位置以及偏转角度 α,可以计算出移动节点在下一时刻的大概运动偏转方向。得到移动节点上两个时刻的坐标位置后,将移动节点相对于上一时刻运动状态所偏转的角度设为 θ, v 为移动节点的速度大小,在某一短暂时间内可以认为节点的运动轨迹为直线运动。现假设移动节点下一时刻将要运动到点 C,点 C 的坐标位置在以移动节点速度 v 为半径的圆内取得,如图 1 所示。




图 1 移动节点偏转方向的计算

Fig. 1 Calculation of deflecting direction of mobile node

依据角度计算公式,有:

$$\theta = \arccos\left(\frac{\vec{AB} \cdot \vec{BC}}{|\vec{AB}| \cdot |\vec{BC}|}\right) \quad (6)$$

其中, $\vec{AB} = (x_{i-1} - x_{i-2}, y_{i-1} - y_{i-2})$, $\vec{BC} = (x_i - x_{i-1}, y_i - y_{i-1})$ 。由于并不知道点 C 的具体坐标 (x_i, y_i) , 令 \vec{AB} 所在的方向为新坐标系 x 轴所在的方向, 则有:

$$(x_i, y_i) = (x_{i-1}, y_{i-1}) \cdot \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \quad (7)$$

若 y_i 为正数, 则点 C 相对于上一时刻 B 点位置向左运动, 反之向右。其中, α 的值可以经过测量粗略得出, 即移动节点上一时刻 B 相对于上上一时刻 A 运动方向偏转的角度。在移动节点偏转方向的计算式中可以求解出未知点 C 的坐标, 但由于角度 α 的不精确性以及新坐标系的不断变化, 本文仅将计算结果 y_i 作为排除错误位置点的条件依据, 从而提高位置预测的精度。根据未知节点单位时间内最大运动速度半径圆与预测所归属信标节点通信半径圆相交的区域, 再结合移动节点偏转方向, 缩小未知节点坐标的取值区域, 减少错误位置取值点, 从而提高位置预测的精度。未知节点预测位置的区域如图 1 中的阴影部分所示。

3.3 A-USVC 位置预测方法的描述

1) 模型训练阶段

在 A-USVC 预测方法归类预测模型的训练阶段, 本文将收集一定数量的节点隶属度向量 \vec{B} , 随机抽取 1/4 作为测试集, 3/4 作为训练集, 由汇聚节点进行模型的训练。在模型训练的过程中, 采用启发式全局优化算法 GA 来优化模型的惩罚参数 C 和核函数参数 g , 不断对模型进行修正和调整, 以达到给定的适应度 MSE 值小于或等于预设值 0.01 或者达到最大的循环代数 100, 此时的 (C, g) 即为最优的 C 和 g , 构建的模型相对而言也是最佳的。

2) 位置预测阶段

在位置预测阶段, 首先以移动未知节点单位时间内的最大运动速度 v 作为半径作圆, 并在圆内随机采样 m 个位置点; 然后将未知节点收集的节点隶属度向量 \vec{B} 作为 A-USVC 预测模型的输入, 相应地, 根据变化的节点隶属度向量值来预测未知节点下一时刻所接近的信标节点, 并将其归属为所靠近的信标节点, 输出信标节点的 ID 以及相对应的坐标位置 (x_i, y_i) 。未知节点位置所在的区域在以当前位置点为圆心、最大运动速度为半径的圆和所预测归属信标节点的通信半径圆的相交区域内。

3) 位置修正阶段

在位置修正阶段, 根据式(7)对移动节点偏转方向进行计算, 进一步缩小未知节点可能存在的区域, 过滤掉错误的位置取值点, 减小错误位置点对最终预测结果的影响, 最后取剩余可能位置点的加权平均值 $(\bar{x}, \bar{y}) = \frac{1}{k} \sum_{i=1}^k (x_i, y_i)$ 作为未知节点下一时刻所在的可能位置。

A-USVC 模型的流程如图 2 所示。

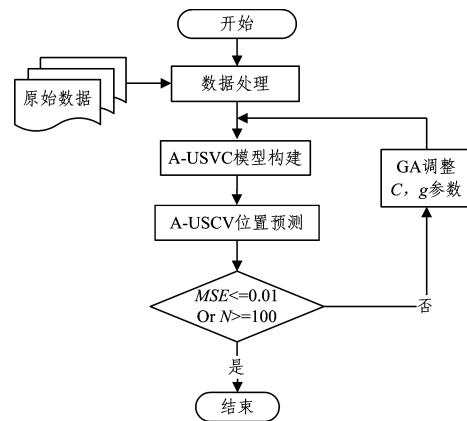


图 2 A-USVC 模型的流程图

Fig. 2 Flowchart of A-USVC model

4 实验仿真与结果分析

在 Matlab 实验仿真环境下, 将本文提出的位置预测方法与文献[3]提出的马尔科夫位置预测方法以及文献[6]提出的神经网络位置预测方法进行性能比较和验证。

4.1 实验参数设置

本文仿真实验是在 Matlab 2016b 平台下采用 faruto 改装的加强版工具箱 libsvm-3.1-[FarutoUltimate3.1Mcode]版本进行的, 使用的个人电脑配置为: Intel CORE i7-4790 CPU, 3.6 GHz, 8 GB 内存。仿真环境中, 移动无线传感器网络节点的分布设置为 $50 \text{ m} \times 50 \text{ m}$ 的二维网格区域, 网络中信标节点的参数个数设为 200, 未知节点的参数个数也设置为 200, 如图 3 所示。随机抽取区域中 100 个节点所收集的信号强度数据集构成实验数据, 其中包含 78 个信标节点、22 个未知节点。为了防止遗传算法无限期循环, 设置最大遗传代数为 100, 初始种群数量为 20, 适应度值为 0.01。




图 3 移动无线传感器网络的节点随机分布图

Fig. 3 Random distribution diagram of nodes in mobile wireless sensor network

本文从位置预测模型的位置预测精度以及主要影响位置预测效果的信标节点占比、节点通信半径和节点移动速度等几个方面进行了分析和验证。位置预测精度主要考查预测模型的预测效果, 节点移动速度可能影响位置预测精度, 而信标节点占比和节点通信半径主要影响预测模型的有效构建。

4.2 实验结果分析

本文从网格区域中选取了 100 个节点所搜集的节点隶属度向量 \vec{B} 作为样本点, 并将它们根据上述方式分为两组, 其中

训练集包含 75 个节点,测试集包含 25 个节点。训练集用于模型训练,测试集用于测试所训练模型的归类效果。结合 3.3 节所述的预测方法进行仿真实验,SVC 预测模型和 A-USVC 预测模型的测试节点效果如图 4、图 5 所示。




图 4 SVC 预测模型的测试节点效果

Fig. 4 Rendering of test nodes of SVC model




图 5 A-USVC 预测模型的测试节点效果

Fig. 5 Rendering of test nodes of A-USVC model

为了最大限度地减少实验误差,将每组数据重复实验 20 次并取它们的平均值作为最终的实验结果。从图 4、图 5 可以看出,相比直接采用 SVC 分类预测模型将所归属信标节点的位置作为未知节点下一时刻的位置,A-USVC 模型的预测效果明显优于 SVC;且经过小样本训练得到的预测模型效果还是比较可观的,它可以较真实地预测出未知节点下一时刻的位置。由于采用了 GA 遗传算法辅助寻优,因此在最优化惩罚参数 C 和高斯核参数 g 时其快速收敛并且避免了建模过程中容易陷入局部最优解的问题,从而明显改善了模型的归类预测效果。最终,经过预测模型计算得出的预测位置与真实位置之间的均方根误差只有 $4.5256e-05$,并且相关系数的平方可以达到 0.97,较真实地反映了未知移动节点的实际位置。

为了达到更好的预测效果,本文使用了具有良好泛化性的径向基核函数(Radial Basis Function,RBF),并且采用了启发式算法 GA 参数寻优作为对比。GA 参数寻优过程如图 6 所示,GA 寻优方法与其他寻优方法的对比结果如表 1 所列。




图 6 GA 参数寻优过程

Fig. 6 GA parameter optimization process

表 1 参数寻优算法对比
Table 1 Comparison of parameter optimization algorithms

参数寻优方式	Bestc	Bestg	均方误差 (MSE)	相关系数的平方
启发式算法 GA 寻优	45.8791	0.0095368	$4.5256e-05$	0.971062
Grid 网格寻优	5.89334	0.01	$9.20357e-02$	0.971416
PSO 粒子群算法寻优	16	0.189465	$1.10186e-01$	0.969108

表 1 列出了 3 种不同的寻优方法的结果,其中均方误差 (MSE)和相关系数的平方是依据预测值与真实值之间的相关计算公式计算得出的,Bestc 和 Bestg 为在均方误差和相关系数的平方下相对应的取值。从表 1 中可以看出,比较启发式 GA 算法、Grid 网格寻优和 PSO 粒子群算法 3 种寻优算法,在建模过程中 PSO 粒子群算法寻优的效果最不理想,原因可能是在寻优过程中得到的参数 C 和 g 是局部最优值,而不是全局最优值;Grid 网格寻优构建的位置预测模型的效果虽然优于 PSO 粒子群算法,且均方误差达到了所设定的小于或等于 0.01 的标准,但 Grid 网格寻优类似于穷举法,并不是较好的选择;启发式 GA 算法则明显优于其他两种算法。

为了更好地验证本文所提出的 A-USVC 位置预测方法的位置预测效果,将其与文献[3]中的马尔科夫位置预测方法以及文献[6]中的神经网络位置预测方法进行了比较。

如图 7 所示,当信标节点个数相对较少时,A-USVC 预测模型、Markov 预测模型和神经网络模型都因为没有足够的样本量,导致模型的训练效果不理想,预测值偏差较大。随着信标节点的增多,提供的样本量增多,A-USVC 模型训练所需要的训练集达到最佳数量时,将不再需要更多的信标节点提供训练集,A-USVC 模型的 MSE 快速下降,这也是 A-USVC 相比于其他两种预测模型更适合小样本的原因。




图 7 不同位置预测模型的效果对比

Fig. 7 Effect comparison of different position predicting models

移动传感网中信标节点密度对未知节点位置预测具有关键作用,图 8 给出了不同信标节点数以及不同节点通信半径对预测模型预测效果的影响。在信标节点数量相同的情况下,随着节点通信半径 R 的增大,训练数据的维数增大,模型的预测效果更好。当通信半径一定时,随着信标节点数的增大,训练数据集增大,预测模型的训练效果更好。




图 8 节点通信范围 R 及信标节点个数 N 对 A-USVC 位置预测的影响

Fig. 8 Effect of node communication range R and number beacon node N on A-USVC position prediction

如图9所示,设置不同的节点移动速度参数对 A-USVC 预测模型的预测效果并无太大影响,主要原因是 A-USVC 预测方法的主体思想是通过确定并缩小未知节点可能存在的区域来进行未知节点位置的预测,节点的运动速度大小并不影响归属模型的构建,因此,当节点的移动速度取不同值时, A-USVC 预测模型依然能取得良好的预测效果,说明本文提出的位置预测方法同时具有一定的鲁棒性。




图9 节点移动速度 V 对 A-USVC 预测模型预测精度的影响

Fig. 9 Effect of node moving speed V on prediction precision of A-USVC model

结束语 本文针对移动传感器网络中传统位置预测方法预测精度低且需要依靠大量历史运动路径数据的问题,提出了一种基于不确定性支持向量机的“角度-分类”(A-USVC)位置预测方法。该方法结合了不确定性支持向量机以及遗传算法各自的优点,利用计算出的移动节点偏转方向作为辅助筛选条件,来进行位置预测。实验结果表明, A-USVC 位置预测方法在保持较好的预测精度的同时依然适用于小样本的情况,并且计算量相对较小,适合能量有限的移动节点位置预测,在牧区牲畜监测方面以及基于位置的路由建立方面也具有一定的参考价值。本文研究中,假设节点均匀分布于区域中,忽略了实际情况下信号强度传播的路径损耗问题,下一步需要研究网络节点空洞下的移动节点位置预测并提高位置预测模型的鲁棒性。

参考文献

[1] FENG Q U, YANG H, WANG L J, et al. Application of Wireless Sensor Networks[J]. Journal of Sichuan Ordnance, 2013, 9(2): 287-291.

[2] MATHEW W, MARTINS B. A comparison of first- and second-order HMMs in the task of predicting the next locations of mobile individuals[C]// ACM Sigspatial International Workshop on Mobile Geographic Information Systems. ACM, 2012: 73-79.

[3] GAMBS S, BASTIEN, KILLIJIAN M O, et al. Next place prediction using mobility Markov chains[C]// EUROSYS 2012 Workshop on Measurement, Privacy, and Mobility, 2012.

[4] YANG J, XU J, XU M, et al. Predicting next location using a

variable order Markov model[C]// ACM Sigspatial International Workshop on Geostreaming. ACM, 2014: 37-42.

- [5] CADGER F, CURRAN K, SANTOS J, et al. Opportunistic Neighbour Prediction Using an Artificial Neural Network[J]. International Journal of Advanced Pervasive & Ubiquitous Computing, 2015, 7(2): 38-50.
- [6] BHATTACHARYA P P, BHATTACHARYA M. Artificial Neural Network Based Node Location Prediction for Applications in Mobile Communication [J]. International Journal of Computer Applications in Engineering Sc, 2011, 1(2): 2231-4946.
- [7] KADHIM D J, ALI T M, MUSTAFA F A, et al. Location Prediction in Cellular Network Using NEURAL Network[J]. International Journal of Computer Engineering & Technology, 2013, 4(4): 321-332.
- [8] AOUDJIT R, BELKADI M, DAOUI M, et al. Mobility Prediction Based on Data mining[J]. International Journal of Database Theory & Application, 2013, 6(2): 71-78.
- [9] ZENG C C. Mobile behavior prediction based on Data Mining [D]. Wuhan: Huazhong University of Science and Technology, 2011. (in Chinese)
- 曾灿灿. 基于数据挖掘的移动行为预测[D]. 武汉: 华中科技大学, 2011.
- [10] MATHEW W, RAPOSO R, MARTINS B. Predicting future locations with hidden Markov models[C]// ACM Conference on Ubiquitous Computing. ACM, 2012: 911-918.
- [11] MANJITH B C, SHIJIN C S. Mobility Prediction for Delay Reduction in WLAN using Location Tracking and Data Mining[J]. International Journal of Computer Applications, 2012, 52(21): 6-10.
- [12] LI X C. The Research of Location Prediction Based on Recurrent Neural Network[D]. Hangzhou: Zhejiang University, 2016. (in Chinese)
- 李幸超. 基于循环神经网络的轨迹位置预测技术研究[D]. 杭州: 浙江大学, 2016.
- [13] ADANKON M M, CHERIET M. Support Vector Machine[J]. Computer Science, 2002, 1(4): 1-28.
- [14] 杨志民, 刘广利. 不确定性支持向量机[M]. 北京: 科学出版社, 2012.
- [15] FENG G H. Parameter optimizing for Support Vector Machines classification[J]. Computer Engineering and Applications, 2011, 47(3): 123-124. (in Chinese)
- 奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用, 2011, 47(3): 123-124.
- [16] 周明. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999.