

文章编号: 2095-4980(2020)04-0616-05

## 无人机辅助的基于前馈神经网络的节点定位算法

王冬梅

(驻马店职业技术学院 信息工程系, 河南 驻马店 463000)

**摘要:** 针对无线传感网络(WSNs)的节点定位问题, 提出无人机辅助的基于前馈神经网络的节点定位(UAV-NN)算法。UAV-NN算法利用无人机(UAV)作为锚节点, 并由UAV周期地发射beacon信号, 利用极端学习机(LEM)训练单隐藏前向反馈的神经网络(SLFN), 未知节点接收来自UAV发射的beacon信号, 并记录其接收信号强度指示(RSSI), 已训练的SLFN再依据RSSI值估计节点位置。仿真结果表明, 相比于传统的基于RSSI定位算法, 提出的UAV-NN算法无需部署地面锚节点; 相比其他传统的机器学习算法, UAV-NN算法通过引用ELM, 减少了定位误差。

**关键词:** 无人机; 定位; 单隐藏前向反馈的神经网络; 接收信号强度指示; 极端学习机

**中图分类号:** TN926

**文献标志码:** A

**doi:** 10.11805/TKYDA2019326

## UAV-assisted localization algorithm based on Feedforward Neural Network

WANG Dongmei

(Department of Information Engineering, Zhumadian Career Technical College, Zhumadian Henan 463000, China)

**Abstract:** Aiming at the problem of node location in Wireless Sensor Network(WSNs), Unmanned Aerial Vehicle-assisted localization algorithm based on Feedforward Neural Network(UAV-NN) is proposed. The localization is performed by using mobile Unmanned Aerial Vehicles(UAVs) as the anchor nodes to send the beacon signals every period of time, thus every unknown node can estimate its current position based on the Received Signal Strength Indicator(RSSI) values of the received beacon signals by training the Single hidden-Layer Feedforward Neural Network(SLFN) using Extreme Learning Machine(ELM) technique. The proposed method requires fewer anchor nodes and no ground anchor node compared to traditional RSSI based localization technique to yield better accuracy. Simulation results show that this technique is capable of performing real-time localization for unknown nodes with less localization error by using ELM compared to other traditional machine learning algorithms.

**Keywords:** Unmanned Aerial Vehicle; localization; Single hidden-Layer Feedforward Neural Network; Received Signal Strength Indicator; Extreme Learning Machine

无线传感网络(WSNs)由微型、低功耗的传感节点组成。传感节点首先感知环境数据<sup>[1-2]</sup>, 再将数据传输至控制中心, 进而实现对环境的监测。为了支持 WSN 内的位置服务, 需先估计节点位置。全球定位系统(GPS)提供位置服务, 但不适合 WSN 内节点: 首先, 给每个节点安装 GPS 成本过高; 其次, GPS 在室内环境的定位性能差。多数 WSNs 定位算法均需部署锚节点(已知位置的传感节点), 通过获取与锚节点的距离信息估计自己的位置。基于测距定位算法, 利用测量信号特性估计节点位置, 如到达时间(Time of Arrival, ToA)<sup>[3]</sup>、到达角度(Angle of Arrival, AoA)<sup>[4]</sup>、到达时间差(Time Difference of Arrival, TDoA)、接收信号强度(RSSI)<sup>[5-6]</sup>。相比 ToA、TDoA 和 AoA, 测量 RSSI 简单, 成本低, 更适合 WSNs。

研究人员试图利用无人机(UAV)提高 WSN 内节点的定位精确度和效率, 如, 文献[7]提出基于 UAV 的协作传输策略, 提高节点的能量效率; 文献[8-9]利用 UAV 的移动轨迹估计节点位置。此外, 为了减少定位算法的复杂度, 研究人员在定位系统中引用单隐藏前向反馈的神经网络(SLFN)实现节点定位<sup>[10-11]</sup>, 如使用支持向量机(Support Vector Machine, SVM)、反向传播(Back Propagation, BPN)。相比于深度学习, SLFN 更简单。文献[12]

收稿日期: 2019-08-05; 修回日期: 2019-11-06

作者简介: 王冬梅(1981-), 女, 双学士, 讲师, 主要研究方向为计算机应用及物联网技术。email:shi\_yibin89@yeah.net

提出基于极端学习机(ELM)的 SLFN 定位算法, 利用 ELM 提高训练阶段的效率。文献[13-14]分别提出了基于神经网络的两跳定位(DV-hop Localization based on Neural Network, DLNN)算法和基于软计算定位(Soft Computing-based Localization, SCL)算法, 并且证实运用 ELM 能够有效缩短定位算法的时间。

无人机辅助的基于前馈神经网络的节点定位(UAV-NN)算法用 UAV 替代传统的在地面上部署锚节点, 并由 UAV 发射 beacon 信号, 地面节点获取 RSSI 值, 同时利用 ELM 训练神经网络, 并由神经网络估计节点位置。仿真数据表明, 提出的 UAV-NN 算法降低了定位误差, 缩短了运行时间, 减少了锚节点数。

## 1 系统模型

### 1.1 定位系统

$n$  个节点( $s_1, s_2, \dots, s_N$ )分布于兴趣区域  $\Theta = \ell_1 \times \ell_2$ 。考虑 2 个 UAV, 由它们作为锚节点, 令  $a_i = (x_i, y_i)$  为传感节点二维位置, 将区域划分为同尺寸的多个网格, 如图 1 所示。2 个 UAV 穿越网格, 并广播 beacon 数据包。beacon 包携带了 UAV 的身份信息。

2 个 UAV 的初始位置为  $(W/2, 0)$ 、 $(0, L/2)$ , 其中  $W$  为网格的宽度,  $L$  为网格的长度。第 1 个 UAV(UAV-1)从初始位置沿着直线移动至  $(W/2, L)$ ; 类似地, 第 2 个 UAV(UAV-2)从初始位置沿着直线移动至  $(W, L/2)$ , 如图 2 所示。令  $r$  表示 UAV 的传输范围。

### 1.2 传输模型

每个 UAV 匹配 2 架天线。节点记录接收的最强 RSSI 值, 再利用最强的 RSSI 值估计位置。引用对数正态阴影衰落模型:

$$L(d) = L_0 + 10\eta \lg\left(\frac{d}{d_0}\right) + X_\sigma \quad (1)$$

式中:  $L(d)$  为传输距离  $d$  时的接收功率, 单位为 dBm;  $d$  为节点离 UAV 的距离;  $\eta$  为路径损耗指数;  $L_0$  为在参考距离  $d_0=1$  m 下的参考功率;  $X_\sigma$  为噪声变量, 服从零均值高斯分布, 即  $X_\sigma \sim N(0, \sigma^2)$ , 其中  $\sigma$  为标准方差。

### 1.3 SLFN 模型

对于  $N_s$  个样本值  $(x_j, o_j)$ , 其中  $x_j$  为输入矢量、 $o_j$  为输出矢量, 激励函数  $g(x)$  的 SLFN 模型可表示为:

$$\sum_{i=1}^{N_h} \beta_i g(\mathbf{w}_i \mathbf{x}_j + b_i) = o_j, j=1, 2, \dots, N_s \quad (2)$$

式中:  $\mathbf{w}_i$  为连接第  $i$  个隐藏层节点的输入矢量;  $b_i$  为第  $i$  个隐藏层节点的偏差;  $\beta_i$  为连接第  $i$  个隐藏层节点的输出权重矢量;  $\mathbf{w}_i \mathbf{x}_j$  为  $\mathbf{w}_i$  与  $\mathbf{x}_j$  的矢量积;  $N_h$  为隐藏层节点数目<sup>[15]</sup>。

式(2)可简化表述为:

$$\sum_{i=1}^{N_h} \beta_i \mathbf{H}_i^j = o_j \quad (3)$$

式中  $\mathbf{H}_i^j = g(\mathbf{w}_i \mathbf{x}_j + b_i)$ , 为第  $i$  个隐藏节点上第  $j$  个抽样样本值的激励函数的输出矢量。

## 2 UAV-NN 算法

### 2.1 训练数据的收集

先在网络内部署一些已知位置的节点, 利用这些节点收集来自 2 个 UAV 的 beacon 信号, 再利用这些信号的 RSSI 值训练神经网络。

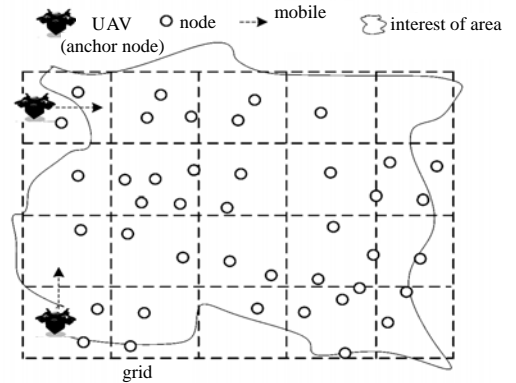


Fig.1 Localization system  
图 1 定位系统

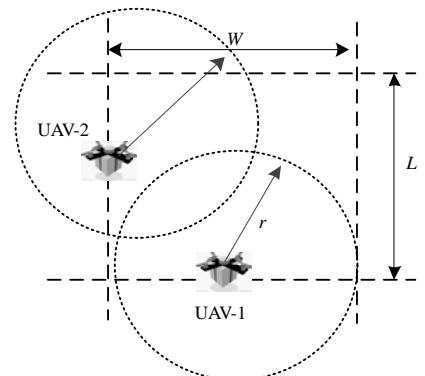


Fig.2 Diagram of grid  
图 2 网格示意图

一个节点可能收到来自同一个 UAV 的多个 beacon 包。令  $m$  表示收到 beacon 包数。引入变量  $R_{lm}^k$  和  $R_{rm}^k$ ，其中  $R_{lm}^k$  表示第  $k$  个节点收到 UAV 来自左边天线传输的第  $m$  个 beacon 信号； $R_{rm}^k$  表示第  $k$  个节点收到 UAV 来自右边天线传输的第  $m$  个 beacon 信号。如图 3 所示，每个节点都保存  $R_{lm}^k$  和  $R_{rm}^k$  两项数据。

每个节点获取了来自同一个 UAV 的 RSSI 数据后，再计算这些 RSSI 值的统计特性，即均值、最大值和标准方差。令  $\mu_i^l, M_i^l, \sigma_i^l$  分别表示节点  $s_i$  从 UAV 左边天线获取的 RSSI 值的均值、最大值和标准方差； $\mu_i^r, M_i^r, \sigma_i^r$  分别表示节点  $s_i$  从 UAV 右边天线获取的 RSSI 值的均值、最大值和标准方差。

节点  $s_i$  利用  $\mu_i^l, M_i^l, \sigma_i^l, \mu_i^r, M_i^r, \sigma_i^r$  这些观察数据训练神经网络。假定在训练阶段部署了  $n$  个已知位置的节点，则能够获取  $n$  组观察数据，如图 4 所示，其中  $T_i$  表示  $s_i$  所接收的 beacon 数。

2.2 神经网络的训练

为了训练神经网络，令  $t_j$  表示目标训练矢量。从 2.1 节可知， $n$  组观察数据是来自  $n$  个已知位置节点获取的 RSSI 统计数据。因此， $t_j$  表示了  $n$  个节点位置信息。据此，可建立式(4)：

$$\sum_{i=1}^{N_h} \beta_i H_i^j = t_j \tag{4}$$

即通过  $n$  组观察数据，获取  $\beta_i$  值。

2.3 节点位置估计

神经网络训练后，节点将所收集的 RSSI 统计特性作为已训练神经网络的输入，输出为节点位置，如图 5 所示。

3 性能分析

利用 Matlab R2017a 软件建立仿真平台，并建立 2 个实验分析 UAV-NN 算法性能。

3.1 实验 1

实验选择 SVM 和 BPN 作为参照，分析 UAV-NN 算法选择 ELM 的定位误差和运算时间。运行算法的电脑参数：Intel Core i5-7400, 1.5 GHz CPU。

考虑 20 m×20 m 兴趣区域。在训练阶段，选择 50 个节点作为已知位置节点，每个节点收集 10 个 RSSI 数据，用于神经网络训练；在定位阶段，选择 100 个未知节点，并用已训练的神经网络估计这 100 个节点位置。神经网络的隐藏层数为 20。

表 1 为 SVM、BPN 和 ELM 这 3 个算法的训练时间、估计节点位置所消耗的时间(定位时间)。从表 1 可知，相比于 BPN 和 SVM，ELM 在训练时间和定位时间方面均具有优势。ELM 的训练时间明显短于 BPN 和 SVM。

图 6 为 SVM、BPN 和 ELM 的定位误差。相比于 SVM 和 BPN，ELM 可以有效控制定位误差。当 UAV 的传输距离在 5~25 m 的变化期间，ELM 的最低定位误差达到 1.737 m。此外，从图 6 可知，定位误差随 UAV 传输距离增加而上升，原因在于 UAV 覆盖范围越大，则 UAV 的高度越高，导致 UAV 与节点距离越远。

3.2 实验 2

本次实验选择 DLNN 和 SCL 定位算法与本文所提出的 UAV-NN 算法进行比较。实验场景：在 100 m×100 m 区域内部署 100 个未知节点。表 2 为 3 个算法的性能，包括所需的锚节点数、最小定位误差。

从表 2 可知，UAV-NN 算法约需 40 个锚节点，而 DLNN 需 100 个锚节点。尽管 SCL 只需 10 个锚节点，但是其定位精确度远低于 UAV-NN 算法，它的最小定位误差达到 6.45 m。同时，DLNN 和 SCL 需给锚节点安装 GPS，这增加了部署成本。




Fig.3 RSSI values of the beacon signals from a single UAV  
图 3 来自单一 UAV 的 beacon 包信息




Fig.4 Structure of data  
图 4 观察数据格式




Fig.5 Location estimation  
图 5 位置估计

表 1 训练时间和定位时间  
Table1 Training and testing time

	BPN	SVM	UAV-NN(ELM)
training time/s	0.151 6	0.190 6	0.003 2
testing time/s	0.151 6	9.912 8×10 <sup>-4</sup>	3.897 7×10 <sup>-4</sup>

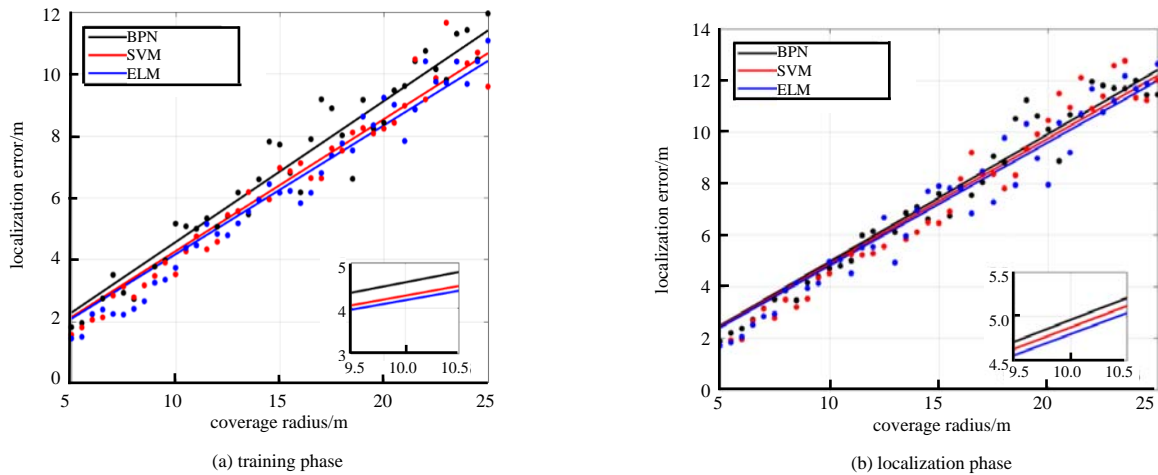


Fig.6 Localization error  
图 6 定位误差

表 2 三种算法的定位性能比较

Table 2 Comparison of localization performance of three algorithms

	DLNN	SCL	UAV-NN
type of anchor node	static ground nodes	static ground nodes	mobile UAV
number of anchor nodes	100	10	40
anchor nodes deployment	random	random	fixed
minimum localization/m	3.6	6.45	1.753 7
GPS on the anchor nodes	needed	needed	no need

#### 4 结论

本文针对 WSNs 的节点定位问题, 提出新的实时定位算法 UAV-NN。UAV-NN 算法不使用任何地面锚节点, 而是利用移动 UAV 发射 beacon 信号, 这能够增加节点部署密度, 提高了算法的扩展性。UAV-NN 算法利用 ELM 训练 SLFN, 再由已训练的 SLFN 估计节点位置。仿真结果表明, 相比于传统的反向传播的神经网络和 SVM, 利用 ELM 估计节点位置能够减少定位误差, 缩短定位时间。

#### 参考文献:

[ 1 ] 江禹生,冯砚毫,管芳,等. 无线传感网非测距三维节点定位算法[J]. 西安电子科技大学学报(自然科学版), 2012,39(5): 140-148. (JIANG Yusheng,FENG Yanhao,GUAN Fang,et al. Rang-free three-dimensional node location algorithm for the wireless sensor network[J]. Journal of XIDIAN University(Natural Science Edition), 2012,39(5):140-148.)

[ 2 ] 顾剑,李文钧. 轻量级 WSN 分层协议栈的设计与实现[J]. 太赫兹科学与电子信息学报, 2018,16(2):312-316. (GU Jian, LI Wenjun. Design and implementation of lightweight layered protocol stack for WSN[J]. Journal of Terahertz Science and Electronic Information Technology, 2018,16(2):312-316.)

[ 3 ] SHABAN A Z,ZHOU X,ABHAYAPALA T D. A novel TOA-based mobile localization technique under mixed LOS/NLOS conditions for cellular networks[J]. IEEE Transactions on Vehicular Technology, 2016,65(11):8841-8853.

[ 4 ] YAN Q,CHEN J,OTTOY G. An accurate AOA localization method based on unreliable sensor detection[J]. IEEE Transactions on Vehicular Technology, 2018,35(10):841-853.

[ 5 ] HUANG C H,LEE L H. Real-time RFID indoor positioning system based on Kalman-filter drift removal and heron-bilateration location estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2015,64(3):728-739.

[ 6 ] TOMIC S,BEKO M,DINIS R. RSS-based localization in wireless sensor networks using convex relaxation:non-cooperative and cooperative schemes[J]. IEEE Transactions on Vehicular Technology, 2015,64(5):2037-2050.

[ 7 ] GIORGETTI A,LUCCHI M,CHIANI M,et al. Throughput per pass for data aggregation from a wireless sensor network via a UAV[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011,47(4):2610-2626.

[ 8 ] KULKARNI R V,VENAYAGAMOORTHY G K. Bio-inspired algorithms for autonomous deployment and localization of sensor nodes[J]. IEEE Transactions on Systems,Man,and Cybernetics(Applications and Reviews), 2010,40(6):663-675.

(下转第 638 页)