

文章编号: 2095-4980(2020)03-0404-05

## WSNs 中基于通用回归神经网络的目标跟踪算法

张红军, 辛守庭

(安阳学院 计算机学院, 河南 安阳 455000)

**摘要:** 基于接收信号强度指示(RSSI)的移动目标定位和跟踪常采用三边或角度测量定位技术。尽管该技术简单, 易实施, 但由于 RSSI 值与距离间的非线性关系, 它们容易导致较大的定位误差。通用回归神经网络(GRNN)能够快速训练稀疏数据集。提出基于 GRNN 的移动目标跟踪(GMTT)算法, 该算法依据 GRNN 处理 RSSI 与目标位置间的非线性关系, 利用卡尔曼滤波(KF)修正目标位置。仿真实验结果表明, 相比于 RSSI+KF, GMTT 算法可以有效地降低目标定位的根均方误差。

**关键词:** 移动目标跟踪; 通用回归神经网络; 接收信号强度指示; 卡尔曼滤波; 根均方误差  
**中图分类号:** TN92                      **文献标识码:** A                      **doi:** 10.11805/TKYDA2019323

## General regression neural network-based mobile target tracking algorithm in Wireless Sensor Networks

ZHANG Hongjun, XIN Shouting

(School of Computer Science and Technology, Anyang University, Anyang Henan 455000, China)

**Abstract:** Traditional Received Signal Strength Indication(RSSI)-based moving target localization and tracking generally employs tri-lateration/angulation techniques. Although this method is simple and easy to be implemented, it creates significant errors in localization estimations due to nonlinear relationship between RSSI and distance. The Generalized Regression Neural Network(GRNN), a one-pass learning algorithm, is well known for its ability to train quickly on sparse data sets. Therefore, GRNN-based mobile Target Tracking(GMTT) is proposed in this paper. GMTT deals with high nonlinearity in RSSI's target location relationship by using GRNN, then further refines these location estimates with the help of KF framework. Simulation results show that GMTT can effectively decrease the Root Mean Square Error(RMSE) of target localization compared with RSSI+KF.

**Keywords:** mobile target tracking; General Regression Neural Network; Received Signal Strength Indication; Kalman Filtering; Root Mean Square Error

目标定位和跟踪是无线传感网络(WSNs)的重要应用之一<sup>[1]</sup>。最初, 目标定位和跟踪只应用于军事行业, 但随着技术的发展, 也广泛应用于民用行业, 如建筑物内的移动目标定位、行人跟踪<sup>[2]</sup>等。

目标的定位和跟踪是估计移动目标的位置(定位)和移动轨迹(跟踪)<sup>[3-4]</sup>。实质上, 跟踪是获取一系列时间点的目标位置。尽管通过全球定位系统(Global Positioning System, GPS)能够获取较准确的位置, 但是基于 GPS 定位并不适合室内定位<sup>[5]</sup>。此外, 基于 GPS 定位成本较高, 并不适合低成本的民用位置服务行业。而基于 WSNs 的定位算法成本较低, 更适合室内环境。目前, 基于 WSNs 的定位算法可分为基于测距和非测距 2 类。从技术角度, WSNs 内的目标定位和跟踪是借助于射频(Radio Frequency, RF)、红外(Infrared Radiation, IR)、声和超宽带(Ultra-Wideband, UWB)<sup>[4]</sup>信号估计移动目标位置。相比于其他技术, 由于 RF 信号能够穿越烟雾、非金属墙等物体, 基于 RF 定位技术得到广泛应用。实际上, RF 定位技术主要是指依据 RSSI 信号测距。在基于 RSSI 测距定位中, 常采用三边或角度测量算法。测量 RF 信号角度需要额外的硬件设备。

收稿日期: 2018-11-09; 修回日期: 2019-04-16

基金项目: 河南省科技攻关项目(182102210208,192102110057); 河南省高等学校重点科研项目(18A520013); 河南省高等学校青年骨干教师培养计划(2018GGJS196); 河南省教师教育课程改革研究重点项目(2019-JSJYZD-041)

作者简介: 张红军(1979-), 男, 副教授, 主要研究方向为计算机网络、大数据技术。email:zhang\_hongjj@tom.com

三边或角度测量存在距离或角度测量不准确问题。目标速度的变化和动态噪声均会引起测量不准确问题。在基于 RSSI 测距定位系统中，有效地处理非线性 RSSI 与距离关系非常重要，也非常困难。

神经网络(Artificial Neural Networks, ANN)能够处理噪声测量数据，并能够快速学习环境参数。ANN 广泛应用于存在不确定噪声<sup>[6-7]</sup>系统中的输入与输出间的匹配问题。与卡尔曼滤波(KF)框架不同，基于 ANN 的定位和目标跟踪无需噪声分布的先验知识。这正是 ANN 广泛应用于定位算法的原因。噪声距离测量数据可直接训练 ANN。

为此，提出基于 GRNN 的移动目标跟踪(GMTT)算法。GMTT 算法利用神经网络结构处理 RSSI 与目标距离间的非线性关系，再利用 KF 修正位置估计值。仿真结果表明，提出的 GMTT 算法有效地降低目标跟踪误差。

## 1 GMTT

### 1.1 GRNN 定位模型

先定义离散的目标移动模型和观察模型，如式(1)、式(2)：

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}, \mathbf{u}_{k-1}, \boldsymbol{\omega}_{k-1}) \tag{1}$$

$$z_k = h(\mathbf{X}_k) + \mathcal{G}_k \tag{2}$$

式中： $\mathbf{X}_k$  为目标状态矢量  $\mathbf{X}_k = (x_k, y_k, \dot{x}_k, \dot{y}_k)$ ，其中  $x_k, y_k$  表示目标在  $x$  轴、 $y$  轴的位置， $\dot{x}_k, \dot{y}_k$  表示在  $x$  轴、 $y$  轴的速度； $z_k$  为观察矢量，即在时刻  $k$  时来自锚节点的 RSSI 测量值； $\mathbf{u}_{k-1}$  为控制输入矢量； $\boldsymbol{\omega}_{k-1}$  和  $\mathcal{G}_k$  均为白噪声； $f, h$  为非线性函数。

令  $T_i$  表示第  $i$  个发射点。令  $R_j$  表示第  $j$  个接收点。引用正态对数衰落模型估计 RSSI 值，如图 1 所示。在时刻  $k$ ，发射点  $T_i$  发射信号，接收点  $T_j$  接收信号，坐标位置分别为  $(x_{ik}, y_{ik}), (x_{jk}, y_{jk})$ 。




Fig.1 Estimation model of RSSI  
图 1 RSSI 的估计模型

$$z_{ij,k} = P_r(d_0) - 10n \log(d_{ij,k} / d_0) + X_\sigma \tag{3}$$

式中： $P_r(d_0)$  表示接收端离发射端参考距离  $d_0$  时所接收的 RSSI 值，通常取  $d_0 = 1$  m； $X_\sigma$  为正态随机变量，其反映了随机噪声； $d_{ij,k}$  表示在时刻  $k$ ，发射点  $T_i$  与接收点  $T_j$  间的距离。

考虑如图 2 所示的 GRNN 结构。GRNN 结构共有 4 个层：输入层、模型层、整合层和输出层。输入层接收输入信号，而模型层将所输入进行非线性转换。对于 GRNN，隐藏层的神经元数通常等于训练集内模型层数。而整合层针对来自模型层的数据进行求和操作，并设置权重系数进行求和。最后，由输出层完成 GRNN 的输出。

将 RSSI 值作为 GRNN 结构的输入。而 GRNN 的输出作为移动目标的位置估计值。令  $M$  表示移动目标所估计的位置。 $N$  表示来自 4 个锚节点所接收的 RSSI 值。GRNN 算法就是通过所接收 RSSI 值估计目标的位置。

令  $M_i, N_i$  分别表示  $M$  和  $N$  的第  $i$  个抽样值。令  $M(N)$  表示所有抽样观察值  $M_i$  的权重平均，其定义如式(4)所示：

$$M(N) = \frac{\sum_{i=1}^n M_i \exp\left(\frac{-D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(\frac{-D_i^2}{2\sigma^2}\right)} \tag{4}$$

式中  $D_i^2$  表示每个观察的权重由  $N$  与  $N_i$  间平方欧式距离的指数关系，其定义如式(5)：

$$D_i^2 = (N - N_i)^T (N - N_i) \tag{5}$$

式(4)中  $n$  表示对观察值的抽样个数。图 2 中， $n=4$ 。此外，式(4)中  $\sigma$  表示平滑因子。作为神经网络算法的重要参数，其控制了算法的收敛速度。依据文献[8]分析可知，适当地选取  $\sigma$  值，可提高 GRNN 的精确度<sup>[8]</sup>。




Fig.2 Block diagram of GRNN architecture  
图 2 GRNN 结构的基本框架

## 1.2 基于 KF 的位置修正

若系统是线性的，且噪声服从零均值的高斯分布<sup>[8-11]</sup>，KF 能够提供最优的贝叶斯估计。基于标准 KF 所建立的目标移动和测量模型可表述为：

$$x_k = \mathbf{A}x_{k-1} + \mathbf{B}u_{k-1} + \omega_{k-1} \quad (6)$$

$$z_k = \mathbf{H}(x_k) + \mathcal{G}_k \quad (7)$$

式中： $\mathbf{A}, \mathbf{B}, \mathbf{H}$  分别为状态转换、控制输入和测量转换矩阵，定义如式(8)所示； $\mathcal{G}_k, \omega_{k-1}$  分别为观察噪声、过程噪声，假定服从正态分布的零均值的高斯噪声，且协方差为  $R_k(\mathcal{G}_k \sim N(0, R_k))$ ， $Q_k(\omega_k \sim N(0, Q_k))$ 。

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & dt & 0 \\ 0 & 1 & 0 & dt \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 0.5dt^2 & 0 \\ 0 & 0.5dt^2 \\ dt & 0 \\ 0 & dt \end{bmatrix}, \quad \mathbf{H} = \mathbf{I}_{4 \times 4} \quad (8)$$

式中  $dt$  表示 2 个连续时刻间的时长。

通过预测和更新实现 KF 的操作。在预测阶段，利用第  $k-1$  步的估计值估计当前  $k$  步的值。而在更新阶段，利用当前的测量值更新预测阶段的值，进而提高估计精确度。

预测：

$$\bar{x}_k = \mathbf{A}\hat{x}_{k-1} + \mathbf{B}u_{k-1} + \omega_{k-1} \quad (9)$$

$$P_k^- = \mathbf{A}P_{k-1}\mathbf{A}^T + Q_k \quad (10)$$

更新：

$$K_k = P_k^- \mathbf{H}_k^T (\mathbf{H}_k P_k^- \mathbf{H}_k^T + R_k)^{-1} \quad (11)$$

$$\hat{x}_k = \bar{x}_k + K_k (z_k - \mathbf{H}_k \bar{x}_k) \quad (12)$$

$$P_k = (\mathbf{I} - K_k \mathbf{H}_k) P_k^- \quad (13)$$

式中： $\mathbf{K}$  为卡尔曼增益矩阵； $\mathbf{I}$  为单位矩阵  $\mathbf{I}_{4 \times 4}$ ；符号“ $\hat{\cdot}$ ”为状态矢量的估计值。

## 1.3 移动目标定位及跟踪

### 1.3.1 目标移动模型

移动目标以常速移动。目标在  $x$  轴、 $y$  轴的速度变化如图 3~图 4 所示。移动目标在每个时刻接收来自所有锚节点的 RF 信号<sup>[12]</sup>，再将所收集的 RSSI 值传输至基站。换言之，目标作为接收节点，锚节点作为发射节点。基站通过与电脑相连，进而运行定位算法。




Fig.3 Speed variation in x direction  
图 3 目标在  $x$  轴的速度变化




Fig.4 Speed variation in y direction  
图 4 目标在  $y$  轴的速度变化

令  $T$  表示总的运行时间，并将其划分为多个时隙。令  $dt$  表示时隙。用  $X_k$  表示移动目标在第  $k$  个时刻的状态，且  $X_k = (x_k, y_k, \dot{x}_k, \dot{y}_k)$ ，其中  $x_k, y_k$  表示目标在  $x$  轴、 $y$  轴的位置； $\dot{x}_k, \dot{y}_k$  表示在在  $x$  轴、 $y$  轴的速度。因此，可建立式(14)和式(15)：

$$x_k = x_{k-1} + \dot{x}_k dt \quad (14)$$

$$y_k = y_{k-1} + \dot{y}_k dt \quad (15)$$

1.3.2 目标定位及跟踪步骤

首先，利用 70 对锚节点与移动目标间的 RSSI 值训练 GRNN 模型。然后，移动目标在每个时刻( $k$ )接收来自锚节点的 RSSI 值，再将这些 RSSI 值传输至基站。

基站再运行 GRNN 模型，估计在第  $k$  个时刻的移动目标位置。最后，利用 KF 框架修正所估计的位置。重复上述步骤，直到仿真完毕，如图 5 所示。

2 性能仿真

2.1 仿真参数

利用 NS 2.34 软件建立仿真平台。移动目标在  $100\text{ m} \times 100\text{ m}$  区域移动。在区域的 4 个角部署 4 个锚节点，它们的位置分别为(0,0), (100,0),(0,100)和(100,100)。此外，节点的通信范围为 100 m，发射天线和接收天线增益为 1 dB，发射功率为 1 mW。仿真时间  $T=35\text{ s}$ ，时隙  $dt=1\text{ s}$ 。

GMTT 算法主要由 RSSI,GRNN 和 KF 3 个算法组成。为了更好地分析 GMTT 算法性能，单独选用 RSSI,GRNN 和 KF 作为参照，并比较它们的平均定位误差(Average Localization Error, ALE)和根均方误差性能。

平均定位误差反映了估计的位置在  $x$  轴、 $y$  轴的平均误差，其定义如式(16)所示：

$$ALE = \frac{1}{T} \sum_{k=1}^T \frac{(\hat{x}_k - x_k) + (\hat{y}_k - y_k)}{2} \tag{16}$$

式中： $\hat{x}_k, \hat{y}_k$  表示对目标估计的位置； $x_k, y_k$  为目标的实际位置。

同时分析  $x$  轴、 $y$  轴上位置估计的根均方误差(RMSE)：

$$RMSE_x = \sqrt{\frac{1}{T} \sum_{k=1}^T (\hat{x}_k - x_k)^2} \tag{17}$$

$$RMSE_y = \sqrt{\frac{1}{T} \sum_{k=1}^T (\hat{y}_k - y_k)^2} \tag{18}$$

$$RMSE_{avg} = \frac{RMSE_x + RMSE_y}{2} \tag{19}$$

2.2 实验一

本次实验分析平滑因子  $\sigma$  对算法性能的影响。实验中， $\sigma$  值从 0.5 至 6 变化，分析平滑因子  $\sigma$  对 GMTT 算法的影响，如图 6 所示。从图 6 可知，平滑因子  $\sigma$  对算法的 RSSI 有较大影响。依据 RSSI、GRNN 和 GRNN+KF 随平滑因子  $\sigma$  的变化曲线可知， $\sigma$  取值在 [3,4] 区间，它们具有最低的 RSSI 值。这为后期实验设置  $\sigma$  的值提供依据。

2.3 实验二

本次实验对比分析 RSSI,GRNN,RSSI+KF 和 GRNN+KF(GMTT)跟踪目标的准确性。假定目标的开始位置为 (12,15)，终点位置为(97,10)。

分析 4 个算法的最低误差、最高定位误差和平均定位误差，如表 1 所示。从表 1 可知，GRNN+KF 算法的平均定位误差最低，远低于 RSSI 和 GRNN。相比 RSSI+KF，GRNN+KF 的平均定位误差仍得到有效控制。同时，

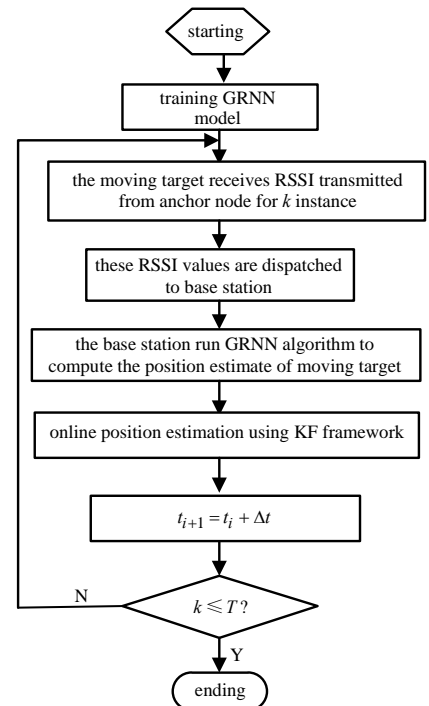


Fig.5 Flow of localization and tracking  
图 5 定位和跟踪流程

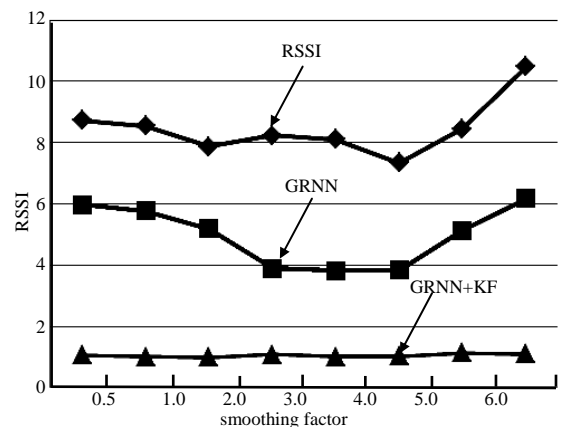


Fig.6 RSSI with smoothing parameter  $\sigma$   
图 6 RSSI 随平滑因子  $\sigma$  的影响

GRNN+KF 的最高定位误差较低,说明 GRNN+KF 的定位性能较稳定,波动小。

分析各算法的 RMSE。表 2 显示了 RSSI,GRNN,RSSI+KF 和 GRNN+KF 的 RMSE。从表 2 可知,只通过 RSSI 估计目标,误差很大,而通过 KF 滤波处理,能够降低 RMSE。例如,RSSI 的平均 RMSE 为 8.019 5 m,而 RSSI+KF 的平均 RMSE 为 1.335 2 m。而 GRNN+KF 的平均 RMSE 最低,低至 1.003 4 m。

表 1 定位误差  
Table1 Localization error

tracking algorithm	lowest localization error/m	highest localization error/m	average localization error/m
RSSI	1.783 4	9.781 2	7.062 1
GRNN	0.810 7	6.493 6	4.743 7
RSSI+KF	0.097 8	4.896 7	1.037 3
GRNN+KF	0.126 3	1.894 1	0.955 4

表 2 根均方误差  
Table2 Root Mean Square Error

tracking algorithm	RMS (x axis)/m	RMSE (y axis)/m	average RMSE/m
RSSI	8.140 5	7.898 5	8.019 5
GRNN	5.081 8	5.621 6	5.351 7
RSSI+KF	1.624 4	1.046 1	1.335 2
GRNN+KF	1.243 1	0.964 1	1.003 4

### 3 结论

针对移动目标的定位和跟踪问题,提出基于 GRNN 的移动目标跟踪算法 GMTT。GMTT 算法利用 GRNN 处理 RSSI 值与距离间的非线性关系,再通过 KF 修正移动目标位置。仿真结果表明,提出的 GMTT 算法降低定位误差,有效地提高跟踪精确度。

#### 参考文献:

- [1] 孙伟,赵心悦,张玉玺,等. 基于扩展集员滤波与信息几何的机动目标跟踪[J]. 太赫兹科学与电子信息学报, 2018, 16(5):786-790. (SUN Wei,ZHAO Xinyue,ZHANG Yuxi,et al. Maneuvering target tracking with the extended set-membership filter and information geometry[J]. Journal of Terahertz Science and Electronic Information Technology, 2018,16(5):786-790.)
- [2] 逯志宇,王建辉,巴斌. 修正容积卡尔曼滤波数据域直接定位方法[J]. 航空学报, 2018,38(25):34-45. (LU Zhiyu, WANG Jianhui,BA Bin. Direct position determination algorithm based on modified cubature Kalman filter[J]. Acta Aeronautica ET Astronautica Sinica, 2018,38(25):34-45.)
- [3] VIANI F,ROCCA P,OLIVERI G,et al. Localization,tracking and imaging of targets in wireless sensor networks:an invited review[J]. Radio Science, 2018,46(5):1-12.
- [4] PATWARI N,ASH J N,KYPEROUNTAS S,et al. Locating the nodes:cooperative localization in wireless sensor networks[J]. IEEE Signal Processing Magazine, 2015,22(4):54-69.
- [5] 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), 2016,39(5):140-148. (JIANG Yusheng,FENG Yanhao,GUAN Fang,et al. Range-free three-dimensional node location algorithm for the wireless sensor network[J]. Journal of Xidian University(Natural Science), 2016,39(5):140-148.
- [6] GHOLAMI M,CAI N,BRENNAN R W. An artificial neural network approach to the problem of wireless sensors network localization[J]. Robot Comput-Integr Manuf, 2016,29(1):96-109.
- [7] ZHUANG Y,LI Y,QI L,et al. A two filter integration of MEMS sensors and WiFi fingerprinting for indoor positioning[J]. IEEE Sensors Journal, 2016,16(13):5125-5126.
- [8] DAI H,YING W H,XU J. Multi-layer neural network for received signal strength-based indoor localization[J]. IET Communications, 2016,10(6):717-723.
- [9] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Fluids Engineering, 1960,82(1):35-45.
- [10] VAN DER MERWE R,WAN E A. The square-root unscented Kalman filter for state and parameter-estimation[J]. Proceeding IEEE International Conference Acoustics, Speech and Signal, 2016(6):3461-3464.
- [11] ANINDYA A S P,WAN E A. RSSI-based indoor localization and tracking using sigma-point Kalman smoothers[J]. IEEE Journal of Selected Topics in Signal Processing, 2018,3(5):860-873.
- [12] 毛科技,金洪波. 无线传感网络中的节点位置验证方法[J]. 传感技术学报, 2015,28(6):850-857. (MAO Keji,JIN Hongbo. Sensor location verification scheme in WSN[J]. Chinese Journal of Sensors and Actuators, 2015,28(6):850-857.)