



改进的核极限学习机定位算法

杨晋生, 郭雪亮, 陈为刚

(天津大学 微电子学院, 天津 300072)

摘要:针对神经网络无线定位方法,存在训练耗时长,定位结果易受噪声干扰的问题,提出了一种改进的核极限学习机无线定位算法。采取在同一位置进行多次测量的方法得到训练数据;把同一位置测得的数据划分为一个样本子空间并提取样本子空间的特征,以样本子空间的特征代替原来的训练数据;利用矩阵近似及矩阵扩展的相关理论改进核极限学习机算法;将处理过的训练数据利用改进的核极限学习机进行训练,得到定位预测模型。仿真结果表明,在相同数据集下,改进的核极限学习机训练用时短、定位速度快;在相同噪声干扰情况下,此算法定位预测误差小。经验证,该算法不但能提高网络的训练速度、定位速度,还能有效地降低噪声的干扰,提高定位精度。

关键词:无线定位;核极限学习机;样本子空间;降维

中图分类号:TP39;TN929.5

文献标志码:A

文章编号:1673-825X(2018)02-0249-08

Improved kernel extreme learning machine localization algorithm

YANG Jinsheng, GUO Xueliang, CHEN Weigang

(School of Microelectronics, Tianjin University, Tianjin 300072, P.R. China)

Abstract: Aiming at the problems of neural networks wireless location, such as large training time consumption and positioning results easily interfered by noise, this paper presents an improved kernel extreme learning machine wireless positioning algorithm. Firstly, the training data is obtained by the method of multiple measurements at the same location. Then, the data obtained at the same position is divided into a sample subspace and the characteristics of the sample subspace are extracted to replace the original training data. At the same time, the kernel extreme learning machine algorithm is improved by using the matrix approximation and matrix extension theory. Finally, the processed training data is trained by the improved kernel extreme learning machine, and the positioning prediction model is obtained. The simulation results show that the improved kernel extreme learning machine has shorter training time and the positioning speed is faster under the same data set. In the case of the same noise interference, the algorithm makes less prediction errors. It has been proved that the algorithm can not only improve the training speed and positioning speed of the network, but also reduce the interference of noise and improve the positioning accuracy.

Keywords: wireless location; kernel extreme learning machine; sample subspace; dimension reduction

0 引言

近年来,随着神经网络的发展越来越成熟,神经网络被广泛应用于人工控制、图像分析、智能预测等

各个领域。由于神经网络具有抗干扰能力强、非线性映射能力强、自学习能力强等优点,许多学者将神经网络应用在无线定位领域。例如:径向基(radial basis function, RBF)、反向传播(back propagation,

收稿日期:2017-05-31 修订日期:2017-07-26 通讯作者:郭雪亮 xueliang@tju.edu.cn

基金项目:天津市科技兴海项目(KJXH2011-2)

Foundation Item: The Science and Technology Xinghai Project of Tianjin City of China(KJXH2011-2)

BP)、支持向量机^[3](support vector machine, SVM)、极限学习机^[4](extreme learning machine, ELM)等神经网络都被应用到了无线定位中。神经网络定位主要分为 2 部分:训练和预测。训练阶段,主要是将样本数据输入到神经网络中进行训练,得到预测模型;预测阶段,主要是将预测数据输入预测模型中得到预测结果。其中,样本数据主要由测量点到各个接收点的信号强度(received signal strength, RSS)^[5]和测量点的位置坐标组成。

ELM 是由 Huang 等提出的一种新的神经网络算法,相较于其他神经网络算法,ELM 神经网络具有泛化能力强和学习速度快的优点。因此,被广泛应用在室内无线定位领域。基于 ELM 神经网络的定位方法主要分为 2 类:①利用 ELM 的分类特性,针对预测区域建立指纹数据库,通过指纹匹配的方式得到定位结果。文献[4-7]中的做法就是先建立指纹数据库,然后用 ELM 神经网络对指纹进行匹配。然而,这种建立指纹库的方法存在一个严重的缺点,就是没有充分考虑到信号强度受噪声的干扰导致指纹与位置坐标不是唯一对应的问题。为此,文献[8]采用序贯极限学习机对指纹数据库进行不定时的更新,这一做法在一定程度上避免了噪声的干扰,但是仍然对指纹的不唯一性考虑不足,定位精度不高;②利用 ELM 的强大的泛化能力,进行非线性拟合,进而估计出位置。文献[9-12]先利用训练样本建立预测模型,然后通过这一预测模型进行定位,虽然在获取 RSS 信息时进行了降低噪声干扰的处理,但是效果不明显,定位结果受噪声干扰大,定位精度不高。文献[12]采取对同一位置进行多次测量的方法,有效降低了噪声对定位结果的干扰,但是这一方法导致了训练样本增多,使网络训练时间变长。

针对在同一位置测得的数据受噪声干扰可能有多组,不是唯一不变的,导致定位误差较大,以及目前神经网络无线定位算法参数设置复杂、训练耗时较长的问题。本文提出一种改进的核极限学习机(kernel extreme learning machine, KELM)定位算法。算法具有以下优点。

1)算法定位精度高。对同一位置进行多次测量得到受噪声干扰的样本数据,充分考虑了噪声对定位结果的干扰。

2)定位速度快。一方面是由于以样本子空间中心为训练集,达到了降维的效果;另一方面由于本

文改进了 KELM 算法,提高了算法的计算速度。

1 核极限学习机

由于 RELM 算法需要设置的参数较少,训练速度快,泛化能力强,因此,选用 KELM。

KELM 是由黄广斌^[13-14]等提出的一种新的单层前馈神经网络算法。RELM 具有训练速度快,预测精度高的优点^[15]。

对于 N 个任意不同的样本 $(\mathbf{x}_i, \mathbf{t}_i)$, 其中, $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n, \mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m, R$ 为实数集;对于具有 L 个隐层神经元数的单层前馈神经网络,网络的输出表示为

$$\sum_{i=1}^L \beta_i h(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{t}_j, j = 1, \dots, N \quad (1)$$

(1)式中, $\mathbf{x}_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \in R^n$ 为输入样本; $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T \in R^n$ 为输入层到隐藏层的权重; $\mathbf{w}_i \cdot \mathbf{x}_j$ 为 \mathbf{w}_i 和 \mathbf{x}_j 的内积, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为隐层到输出层的权重; b_i 为第 i 个隐层神经元的偏置; $h(\cdot)$ 为隐层神经元的激励函数; \mathbf{t}_j 为第 j 个样本的输出。(1)式可以写成矩阵相乘的形式,即

$$\mathbf{H}\beta = \mathbf{T} \quad (2)$$

(2)式中, $\mathbf{H} = \begin{bmatrix} h(w_1 \cdot x_1 + b_1) \cdots h(w_L \cdot x_1 + b_L) \\ \vdots \\ h(w_1 \cdot x_N + b_1) \cdots h(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L}$ 为

隐层输出矩阵, $\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}$ 为隐层到输出层的输出

权重矩阵, $\mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$ 为输出层输出矩阵。

对(2)式求最小二乘法得到

$$\hat{\beta} = \mathbf{H}^\dagger \mathbf{T} \quad (3)$$

(3)式中, \mathbf{H}^\dagger 为 \mathbf{H} 的广义逆矩阵。

上述过程可等效于求解 $\min \|\mathbf{H}\hat{\beta} - \mathbf{T}\|$ 的最优化问题,根据 Karush-Kuhn-Tucker (KKT) 理论可得

$$L_{\text{ELM}} = \frac{1}{2} \|\beta\|^2 + \frac{C}{2} \sum_{j=1}^N \xi_j^2 - \sum_{j=1}^N \alpha_j (\mathbf{h}(x_j) \beta - \mathbf{t}_j^T + \xi_j)^T \quad (4)$$

(4)式中: C 为惩罚系数; ξ_j 为实际输出与理论输出的差, $\xi_j = [\xi_{j1}, \dots, \xi_{jm}]$; α_j 为 Lagrange 乘子, $\alpha_j = [\alpha_{j1}, \dots, \alpha_{jm}]$, $\mathbf{h}(x_j) = [h(w_1 \cdot x_j + b_1), \dots, h(w_L \cdot x_j +$

$b_1)$] 为矩阵 H 的行向量。

(4) 式由 KKT 条件得

$$\begin{cases} \frac{\partial L_{ELM}}{\partial \beta} = 0 \rightarrow \beta = \sum_{j=1}^N h(x_j)^T \alpha_j \rightarrow \beta = H^T \alpha \\ \frac{\partial L_{ELM}}{\partial \xi_j} = 0 \rightarrow \alpha = C \xi, j = 1, \dots, N \\ \frac{\partial L_{ELM}}{\partial \alpha_j} = 0 \rightarrow h(x_j) \beta - t_j^T + \xi_j = 0 \rightarrow T - \xi = H \beta \end{cases} \quad (5)$$

(5) 式中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$; $\xi = [\xi_1, \xi_2, \dots, \xi_N]^T$ 。

由(5)式得

$$\begin{cases} \alpha = (H^T)^{-1} \beta \\ T = \left(HH^T + \frac{I}{C} \right) \alpha \end{cases} \quad (6)$$

求解(6)式得

$$\beta = H^T \left(\frac{I}{C} + HH^T \right)^{-1} T \quad (7)$$

定义核矩阵表达式如下: $\Omega = HH^T$, $K(x_i, x_j) = h(x_i) \times h(x_j)$, 代入(5)式得

$$\beta = H^T \left(\frac{I}{C} + \Omega \right)^{-1} T \quad (8)$$

将(8)式代入(2)式得

$$T = H \cdot \beta = H \cdot H^T \left(\frac{I}{C} + \Omega \right)^{-1} T \quad (9)$$

由此得到核极限学习机的输出权值为

$$\lambda = \left(\frac{I}{C} + \Omega \right)^{-1} T \quad (10)$$

2 本文算法

2.1 样本子空间降维

为了充分考虑噪声对样本的干扰, 本文采取对同一个位置进行多次测量的方法得到样本数据, 然后将这些对应同一位置的数据划分为一个样本子空间, 之后用该样本子空间的特征代替原来的样本数据, 这样不仅充分考虑了噪声对样本数据的干扰, 同时也起到了降低样本维度的效果。本文已考虑不同的干扰源可能引起样本数据聚集出不同的簇, 如图 1 所示, 圆 A_i 表示在任意一个位置测得样本数据, 圆 B_1, B_2, B_3 代表受不同干扰影响形成的簇。本文提出了一种样本子空间降维算法 (sample subspace dimension reduction, SDDR), 算法以样本子空间的中心和该子空间的簇的中心与该子空间的中心的余弦相似度来代替原来的训练数据。




图 1 样本子空间

Fig.1 Sample subspace

假设在一个周围有 M 个固定信号接收点的场景中, 对 $N (M \ll N)$ 个位置进行训练样本采集, 且针对同一个位置测量 k 次, 那么得到的样本集可以用 $N \times k$ 行 M 列的矩阵表示。

根据位置将这些样本划分为 N 个不同的样本子空间, 在求各个子空间的中心时, 考虑到这些子空间属于高维子空间, 一般的低维空间求聚类中心的方法不再适用。因此, 本文利用子空间投影的方法来求高维子空间的聚类中心, 先将子空间中的点投影到各个平面上, 再用 k-means 聚类得到平面上的聚类中心, 再由各个平面中心坐标得到子空间中心坐标为 O_i 。

同理, 求得任意一个样本子空间中划分出的 $m (m < k)$ 个簇 (通过网格搜索法得 $m = 4$) 的中心坐标 B_j 。利用余弦相似度公式 $\cos \theta = (O_i \cdot B_j) / (|O_i| \cdot |B_j|)$ 度量簇与子空间中心的相似度, 并利用子空间中心与余弦相似度的度量值代替原来的样本特征, 得到新的样本, 以此达到降维目的。算法具体实现过程如下。

算法 1 SDDR 降维算法。

输入: 样本矩阵 $S = [x_1, x_2, \dots, x_N]^T$ 。其中, $x_i = [x_{i1}, x_{i2}, \dots, x_{iM}]$, N 为样本总数, M 为固定信号接收点数, 即样本特征数。

输出: 降维之后的样本矩阵 S' 。

1) 将样本按测量位置分为 N 子矩阵, 即 N 个 M 维子空间。

2) For $i = 1, 2, \dots, N$

从 S 中划分出子矩阵 $A_i, i = 1, 2, \dots, N$ 。

3) For $j = 2, 3, \dots, M$

① 取特征 1 与特征 j 构成矩阵将样本投影到平面上得 $P_j \leftarrow [A_i(:, 1), A_i(:, j)]$;

② 利用 k-means 求平面上聚类中心 $o_{ij} \leftarrow$

$kmeans(P_j, 1)$;

③同理得到 A_i 子空间的 $m(m < k)$ 个簇, 其中 m 的值根据网格搜索法搜索 $\{1, 2, \dots, k/10\}$ 得到坐标 $B_r \leftarrow [b_{r1}, b_{r2}, \dots, b_{rM}], r = 1, 2, \dots, m$;

4) End For

5) 得到 A_i 聚类中心 $O_i \leftarrow [o_{i1}, o_{i2}(:, 2), \dots, o_{iM}(:, 2)]$;

6) 求余弦相似度 $\theta_i \leftarrow \left[\frac{O_i \cdot B_1}{|O_i| \cdot |B_1|}, \dots, \frac{O_i \cdot B_m}{|O_i| \cdot |B_m|} \right]$;

7) 得到 $S'_i \leftarrow [O_i, \theta_i]$;

8) End For

9) 得到降维之后样本 $S' \leftarrow [S'_1, \dots, S'_N]^T$ 。

2.2 改进核极限学习机算法

提出一种改进的核极限学习机(improved kernel extreme learning machine, IMP-KELM)。由于核极限学习机算法的核矩阵 Ω 的大小与输入样本数 N 正相关。在 N 较大的情况下, 计算核 Ω 会花费较长的时间, 为了降低计算复杂度, 本文采用计算 Ω 的近似矩阵 h 的方法来降低计算复杂度。

考虑到矩阵 $\Omega_{N \times N}$ 是根据输入样本计算得来的, 所以可以通过减少参与计算的样本数量来达到降低计算复杂度的目的。又因为输入的样本对算法的贡献度不同, 本文根据主向量分析法(principal component analysis, PCA), 以样本为特征, 得到样本的贡献度。取贡献度较大的 n 个样本组成样本矩阵 $X_{n \times M}$ 。

为了减少参与计算的样本数, 本文用 $X_{N \times M} \times X_{n \times M}^T$ 代替求解核矩阵 Ω 公式中的 $X_{N \times M} \times X_{N \times M}^T$, 得到 Ω 的子矩阵 $\Omega_{N \times n}$ 。

依据 Nystrom 扩展技术, 核矩阵 $\Omega_{N \times N}$ 可由其部分数据逼近原始数据的特征空间, 因此, 近似矩阵可表示为 $h_{N \times N} = \begin{bmatrix} \Omega_{n \times n} \\ \Omega_{(N-n) \times n} \end{bmatrix} \Omega_{n \times n}^{-1} \begin{bmatrix} \Omega_{n \times n} \\ \Omega_{(N-n) \times n} \end{bmatrix}^T = \Omega_{N \times n} \Omega_{n \times n}^{-1}$ $\Omega_{N \times n}^T = G G^T$, 由此得到分解矩阵 $G = \Omega_{N \times n} \Omega_{n \times n}^{-1/2}$, 其中, $\Omega_{n \times n}$ 为 $\Omega_{N \times n}$ 的子矩阵。

最后, 将 $h_{N \times N} = G G^T$, 代入(8)式再根据 Woodbury 公式得到网络输出权重矩阵为

$$\beta = C \left[I - G \left(\frac{I}{C} + G^T G \right)^{-1} \right] T^T \quad (11)$$

算法具体实现过程如下。

算法 2 改进的 KELM 算法。

输入: 训练样本 (x_i, y_i) , 其中, $x_i = [x_{i1}, x_{i2}, \dots, x_{iM}]^T \in R^M, t_i = [t_{i1}, t_{i2}]^T \in R^2, N$ 为样本总数, M 为固定信号接收点数, 即样本特征数。

输出: 最终定位预测模型。

1) 利用主向量分析法, 以样本个数为特征, 得到样本的贡献度。取前 n 个贡献度大的样本构成矩阵 $X_{n \times M}$;

2) 加载 KELM 训练模型;

3) IF 选择 RBF 核函数, 则

$$\begin{cases} number1 \leftarrow size(X_{N \times M}, 1) \\ number2 \leftarrow size(X_{n \times M}, 1) \\ xx1 \leftarrow sum(X_{N \times M} \cdot ^2, 2) * ones(1, number2) \\ xx2 \leftarrow sum(X_{n \times M} \cdot ^2, 2) * ones(1, number1) \\ omega \leftarrow xx1 + xx2^T - 2 * (X_{N \times M} X_{n \times M}^T) \\ \Omega_{N \times n} \leftarrow exp(-omega./C) \end{cases}$$

求得 $\Omega_{N \times n}$;

4) End IF

5) $G \leftarrow \Omega_{N \times n} \cdot \Omega_{n \times n}^{-1/2}$;

6) $\beta \leftarrow C \left[I - G \left(\frac{I}{C} + G^T G \right)^{-1} \right] T^T$;

7) 得到最终预测模型。

2.3 改进的核极限学习机定位算法

本文以 SSDR-IMP-KELM 表示该定位算法。首先, 根据样本子空间降维算法对样本进行降维, 得到以子空间特征组成的新的样本; 然后, 将这些新的样本数据输入到核极限学习机中训练神经网络, 得到预测模型; 最后, 用得到的预测模型进行位置估计, 达到定位目的。算法具体实现过程如下。

算法 3 改进核极限学习机定位算法。

输入: 样本 (x_i, y_i) , 其中, $x_i = [x_{i1}, x_{i2}, \dots, x_{iM}]^T \in R^M, t_i = [t_{i1}, t_{i2}]^T \in R^2, N$ 为样本总数, M 为固定信号接收点数, 即样本特征数。

输出: 定位预测结果, 即预测位置的坐标。

1) 取样本的特征信息组成矩阵 $S \leftarrow [x_1, x_2, \dots, x_N]^T$;

2) 调用 SSDR 降维算法, 得 $S' \leftarrow [S'_1, \dots, S'_N]^T$;

3) $\frac{1}{2} S'$ 为训练样本, $\frac{1}{2} S'$ 为测试样本;

4) 加载改进的核极限学习机模型, 训练得到预测模型。其中, 输出权重求解公式为 $\beta \leftarrow C \left[I - G \left(\frac{I}{C} + G^T G \right)^{-1} \right] T^T$;

- 5) 测试样本输入到预测模型;
- 6) $T' \leftarrow H \cdot \beta$ 得到预测位置坐标。

算法流程图如图 2 所示。

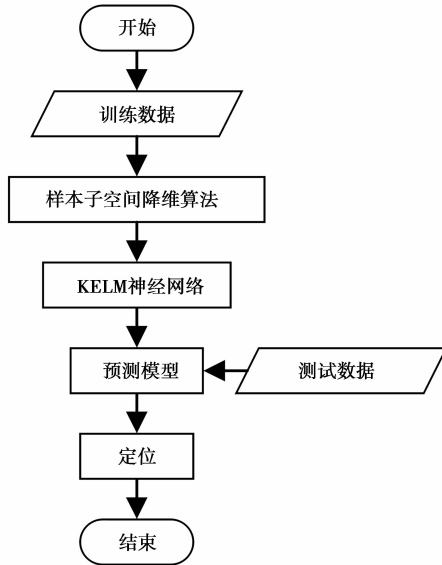


图 2 定位算法流程图

Fig.2 Flow chart of positioning algorithm

2.4 计算复杂度分析

本文算法的计算复杂度主要由 2 部分组成:SSDR 降维算法的计算复杂度、改进的 KELM 算法的计算复杂度。参照文献[15]计算复杂度的方法,统计加、减、乘、除的运算总次数来度量算法的计算复杂度。遵循以下 2 个原则。

- 1) 矩阵的加、减、乘和求逆计算的统计。

若矩阵 $A \in R^{m \times n}$, $B \in R^{m \times n}$, $C \in R^{n \times l}$, $D \in R^{n \times n}$ 则 $A \pm B$ 的计算复杂度为 mn , AC 为 $2mnl - ml$; D^{-1} 为 n^3 。

- 2) 消减原则。

只保留最高次幂项且忽略每一项前的系数。

依据以上原则统计实现 SSDR 降维算法的运算总次数,得到计算复杂度为 $o((Nk)^2NM(M-1)/2)$ 。

同理,改进的 KEM 的计算复杂度为 $o(Nn^2 + n^3)$ 。

改进的核极限学习机定位算法的复杂度主要由 SSDR 降维算法与改进的 KELM 算法的复杂度组成则计算复杂度为 $o((Nk)^2NM(M-1)/2 + Nn^2 + n^3)$ 。

同理,未改进的 KELM 算法计算复杂度为 $o((Nk)^3)$ 。其中, M, N, k 代表含义与 2.1 节相同, n 为 2.2 节样本经过 PCA 分析,得到的 n 个贡献度较大的样本。

3 实验与仿真

3.1 实测数据分析

为了使仿真实验与实际联系起来,本文首先对实际环境下得到的数据进行分析,并以此为依据进行仿真实验。实测数据来源于 2016 年 8 月 29 日,在天津市无线电管理委员会频谱资源监控中心,利用位于天津市南开区天津大学西侧的白堤路上的编号为 UMS300-101487 的监测站,对南开大学校园广播的信号强度进行连续 3 天的检测得到的数据。本文取每一天的上午一分钟和下午一分钟得到的测量统计图如图 3 所示。

图 3 中,在实际环境中,针对同一个点进行多次测量,得到的 RSS 值不是固定不变的, RSS 值是变化的。同时,由于测得的数据是在一分钟内完成的,所以在实际应用中,可以利用较短的时间得到大量的 RSS 值。为了使仿真更符合实际,本文采用了以下仿真方法。

3.2 场景仿真

应用 MATLAB R2013b 在 CPU 型号为 intel(R) Core(TM) i5-2450M,主频 2.50 GHz,内存为 4 GByte, Windows7 64 位系统的环境下进行仿真实验。仿真一个 2 000 m×2 000 m 的室外环境,且周围有 4 个接收点,具体仿真场景如图 4 所示,利用信号路径损耗模型,根据参考点距离计算 RSS 值。

$$PL(d) = PL_0 + 10\alpha \log\left(\frac{d}{d_0}\right) + X \quad (12)$$

(12) 式中: PL_0 为路径损耗系数,在本文中被设为 -40 dBm; d_0 是与 PL_0 对应的测量距离; d 为到参考点的距离; α 为路径损耗指数取 2, X 为由服从高斯分布、伽马分布和均匀分布的噪声组成。

图 5 为对某一点仿真得到的 RSS 统计图。在仿真场景范围内随机取 200 个点,对每个点进行 100 次的测量,得到仿真数据,从中随机选取 100 个点作为训练集,剩余 100 个点为测试集。

3.3 实验涉及参数设置

1) 算法 1 涉及的参数。在同一位置重复测量次数 k ,由 3.2 节知 $k=100$;任意一个样本子空间中划分出 $m(m < k)$ 个簇,设定 $m \in \{1, 2, \dots, k/10\}$,通过网格搜索,得到 $m=4$ 。




图 3 室外实际测量某一信号 RSS 变化统计图

Fig.3 Outdoor actual measurement of a signal RSS change statistics

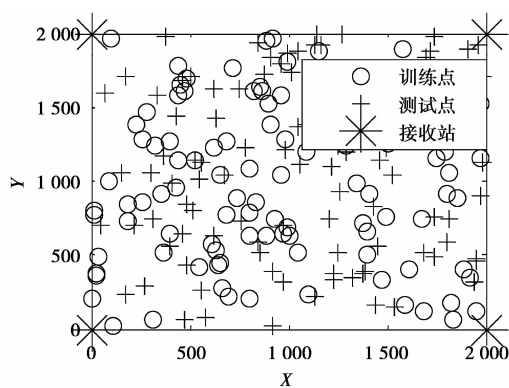


图 4 仿真场景图

Fig.4 Simulation scenario




图 5 某一点仿真得到的 RSS 统计图

Fig.5 RSS statistics obtained from a point simulation

2) 算法 2 涉及的参数。选择贡献度大的前 n 个样本, n 的选取通过多次实验得到, $n = 82$; 核极限学习机的核参数设为 RBF 核, 如(13)式; 惩罚参数 C , 设 $C \in \{2^{-10}, 2^{-9}, \dots, 2^{40}, 2^{50}\}$, 进行网格搜索得到 $C = 2^{20}$; RBF 核的参数 μ , 设 $\mu \in \{2^{-10}, 2^{-9}, \dots, 2^{40}, 2^{50}\}$, 网格搜索得到 $\mu = 2^{10}$ 。

$$K(u, v) = \exp[-(\|u - v\|^2 / \mu)] \quad (13)$$

(13) 式中, μ 为核参数。

3) 遗传算法优化的 BP 神经网络算法(GA-BP)。GA-BP 用于与本文算法对比, 网络参数设置为: 隐层数 3, 隐层节点数取 20(经过多次实验得到), 迭代次数设为 1 000 次。

4) RBF 神经网络参数设置。RBF 用于与本文算法对比, RBF 神经网络网络参数设置为: 隐层节点数 70, 迭代次数 1 000 次。

3.4 定位仿真实验

衡量性能的指标一般选取均方根误差 (root mean square error, RMSE) 作为衡量测试性能的标准, 如(14)式。

$$RMSE = \sqrt{\frac{1}{N-1} \sum_{i=1}^N ((\hat{t}_{xi} - t_x)^2 + (\hat{t}_{yi} - t_y)^2)} \quad (14)$$

(14) 式中: N 为样本数; t_{xi} 与 t_{yi} 分别为实际输出的坐标; \hat{t}_{xi} 与 \hat{t}_{yi} 分别为预测输出的坐标。

仿真结果如表 1 所示。表 1 中, Training-

RMSE, Train-Time, Test-RMSE 分别表示训练耗时 以及测试所得结果的均方根误差。
(原始数据输入 KELM 到得出模型参数)、训练误差

表 1 仿真结果对比

Tab.1 Comparison of simulation results

	Training-Time/s	Train-RMSE/m	Test-RMSE/m
GA-BP	160.004 7	153.243 2	195.025 9
RBF	158.020 6	123.402 2	190.823 3
KELM	15.932 2	170.626 7	195.188 2
IMP-KELM	5.848 9	171.320 0	195.770 1
SSDR-IMP-KELM	1.705 9	17.642 4	47.631 1

表 1 中, KELM 与改进后 IMP-KELM 相比, 在训练时间方面, 改进的 KELM 算法明显耗时较短, 其他方面相差不大。因此, IMP-KELM 算法是有效的。KELM 与本文算法 SSDR-IMP-KELM 相比, 在时间方面, 训练耗时和测试耗时都要比本文算法用时长, 训练耗时是本文算法 SSDR-IMP-KELM 的 10 倍左右; 在误差方面, 本文算法误差明显小于 KELM 算法, 约为 KELM 误差的 1/4。GA-BP 算法和 RBF 算法与本文算法相比, 训练耗时长, 误差较大, 误差是本文算法的 4 倍左右。

由 2.4 节知, KELM 算法的时间复杂度为 $o((N \times k)^3)$, 改进的 KEM 的计算复杂度为 $o(Nkp^2 + p^3)$, SSDR-IMP-KELM 算法复杂度为 $o((Nk)^2NM \cdot (M-1)/2 + Nn^2 + n^3)$ 。仿真实验中 $k = 100, N = 100, n = 82, M = 4, p = 3000$ 则 $o((N \times k)^3) = o(10^{12})$, $o(Nkp^2 + p^3) = o(9.27 \times 10^{10})$, $o((Nk)^2NM \cdot (M-1)/2 + Nn^2 + n^3) \approx o(6.0 \times 10^{10})$ 。

为了更直观地比较 SSRD-IMP-KELM 算法与其他算法的误差, 本文给出了误差累计分布图, 如图 6 所示。

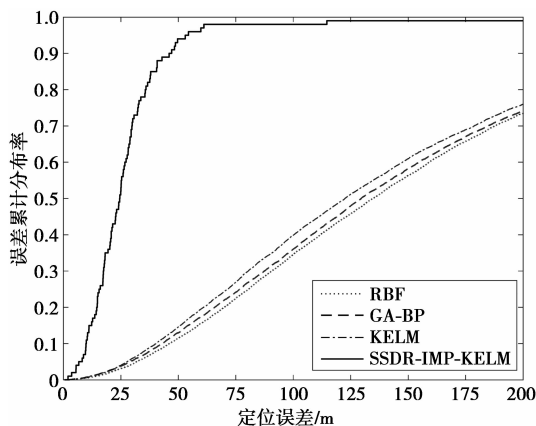


图 6 误差累计分布图

Fig.6 Cumulative error distribution

从图 6 中可以看出, 本文算法在误差为 75 m 时累计误差分布率接近 100%, 而 KELM 算法在误差为 200 m 时误差累计分布率刚刚达到 76%。GA-BP 与 RBF 算法在误差为 200 m 时误差累积分布率刚刚达到 74%。由此可以看出, 本文算法误差更小, 且分布较为集中。

4 结 论

本文针对目前神经网络无线定位耗时较长, 且定位结果易受噪声干扰的问题提出了一种改进的核极限学习机的定位算法。因为测量 RSS 数据时易受各种噪声的干扰导致定位精度不高, 本文采用以样本子空间特征代替原来样本的方法处理数据, 这样既提高了定位精度又降低了样本数据维度, 提高了定位速度。为了进一步提高定位速度本文提出了一种改进的核极限学习机, 利用改进的核极限学习机学习降维之后的样本, 得到定位预测模型。仿真实验验证了本文算法具有定位速度快, 定位精度高的优点。

参考文献:

[1] 毛永毅, 李明远, 张宝军. 基于 RBF 神经网络的蜂窝无线定位算法 [J]. 系统工程与电子技术, 2008 (09): 1798-1800.
MAO Yongyi, LI Mingyuan, ZHANG Baojun. Cellular location algorithm based on the RBF neural network [J]. Journal of Systems Engineering and Electronics, 2008 (09): 1798-1800.

[2] 张会清, 石晓伟, 邓贵华, 等. 基于 BP 神经网络和泰勒级数的室内定位算法研究 [J]. 电子学报, 2012, 40 (9): 1876-1879.
ZHANG Huiqing, SHI Xiaowei, DENG Guihua, et al. Research on Indoor Location Technology Based on Back Propagation Neural Network and Taylor Series [J]. Chi-

- nese Journal of Electronics, 2012, 40(9): 1876-1879.
- [3] CHOU K C, CAI Y D. Using functional domain composition and support vector machines for prediction of protein subcellular location[J]. Journal of Biological Chemistry, 2002, 277(48): 45765-45769.
- [4] ZOU H, HUANG B, LU X, et al. A robust indoor positioning system based on the procrustes analysis and weighted extreme learning machine[J]. IEEE Transactions on Wireless Communications, 2016, 15(2): 1252-1266.
- [5] 夏英, 王磊, 刘兆宏. 基于无线局域网接收信号强度分析的混合室内定位方法[J]. 重庆邮电大学学报: 自然科学版, 2012, 24(2): 217-221.
- XIA Ying, WANG Lei, LIU Zhaohong. Hybrid indoor positioning method based on WLAN RSS analysis[J]. Journal of Chongqing University of Posts and Telecommunications: Natural Science Edition, 2012, 24(2): 217-221.
- [6] DWIYASA F, LIM M H, ONG Y S, et al. Extreme learning machine for indoor location fingerprinting[J]. Multidimensional Systems and Signal Processing, 2017, 28(3): 867-883.
- [7] XIAO W, LIU P, SOH W S, et al. Extreme learning machine for wireless indoor localization[C]//Proceedings of the 11th international conference on Information Processing in Sensor Networks. 2012 ACM/IEEE 11th International Conference on. Beijing, China: IEEE Press, 2012: 101-102.
- [8] ZOU H, JIANG H, LU X, et al. An online sequential extreme learning machine approach to WiFi based indoor positioning [C]//Internet of Things (WF-IoT). 2014 IEEE Press, World Forum on. Seoul, South Korea: IEEE Press, 2014: 111-116.
- [9] LIU J, CHEN Y, LIU M, et al. SELM: semi-supervised ELM with application in sparse calibrated location estimation[J]. Neurocomputing, 2011, 74(16): 2566-2572.
- [10] LU X, LONG Y, ZOU H, et al. Robust extreme learning machine for regression problems with its application to wifi based indoor positioning system [C]//Machine Learning for Signal Processing (MLSP). 2014 IEEE International Workshop on. Reims, France: IEEE Press, 2014: 1-6.
- [11] XIAO W, LIU P, SOH W S, et al. Large scale wireless indoor localization by clustering and Extreme Learning Machine[C]//Information Fusion (FUSION). 2012 15th International Conference on. Singapore, Singapore: IEEE Press, 2012: 1609-1614.
- [12] LU X, ZOU H, ZHOU H, et al. Robust extreme learning machine with its application to indoor positioning [J]. IEEE Transactions on Cybernetics, 2016, 46(1): 194-205.
- [13] HUANG G B, ZHU Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]//Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on. Budapest, Hungary: IEEE Press, 2005: 985-990.
- [14] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(2): 513-529.
- [15] HUANG G B, CHEN L, SIEW C K. Universal approximation using incremental constructive feed-forward networks with random hidden nodes [J]. IEEE Transactions on Neural Networks, 2006, 17(4): 879-892.
- [16] 文成林, 吕冰, 葛泉波. 一种基于分布式滤波的数据融合算法[J]. 电子学报, 2004, 32(8): 1264-1267.
- WEN Chenglin, LU Bing, GE Quanbo. A Data Fusion Algorithm Based on Filtering Step by Step [J]. Chinese Journal of Electronics, 2004, 32(8): 1264-1267.

作者简介:



杨晋生 (1965—), 男, 河北邢台人, 副教授, 硕士生导师, 主要研究方向为无线传播理论与技术。E-mail: jsyang@tju.edu.cn。



郭雪亮 (1990—), 男, 天津大学微电子学院硕士研究生, 主要研究领域机器学习无线定位和数据挖掘等。E-mail: xueliang@tju.edu.cn。



陈为刚 (1980—), 男, 山东临沂人, 副教授, 硕士生导师, 主要研究方向为无线通信、信息理论与编码技术。E-mail: chenwg@tju.edu.cn。

(编辑: 刘 勇)