

基于特征降维的在线序列学习机 算法在室内动态定位中的应用

Application of Online Sequence Learning Machine Algorithm
Based on Feature Dimension Reduction in Indoor Dynamic Localization

李园, 苏胜君, 施伟斌 (上海理工大学, 上海 200093)

Li Yuan, Su Shengjun, Shi Weibin (University of Shanghai for Science and Technology, Shanghai 200093, China)

摘要:

随着室内定位需求的不断增加,基于指纹的定位方法由于低成本、易于实现、精度较高等优势被广泛使用。但指纹定位算法在离线阶段训练成本高,接收信号强度值易受环境和噪声的影响,对环境的动态变化缺乏灵活性。提出了一种基于特征降维的在线序列学习机算法(PCA-OS-ELM),PCA算法可以对原始的RSSI数据进行降维,去除干扰信息,构造新的特征。OSELM的快速学习能力可以降低离线阶段的训练成本,适应环境的动态变化。在2种不同的环境下进行了对比实验,结果表明所提出的算法能适应环境的动态变化,提高定位精度。

Abstract:

With the increasing demand for indoor positioning, fingerprint-based positioning methods are widely used due to their advantages of low cost, easy implementation and high accuracy. However, the training cost of the fingerprint localization algorithm is high in the offline stage, and the received signal strength value is easily affected by noise, and the fingerprint localization algorithm lacks flexibility to the dynamic changes of the environment. It proposes an online sequence learning machine algorithm based on feature dimension reduction (PCA-OS-ELM). The PCA algorithm can reduce the dimension of the original RSSI data, remove the interference information, and construct new features. The fast learning ability of OSELM can reduce the training cost in offline phase and adapt to the dynamic changes of the environment. Comparative experiments are carried out in two different environments, and the results show that the proposed algorithm can adapt to the dynamic changes of the environment and improve the positioning accuracy.

Keywords:

PCA; OS-ELM; Indoor environment; Dynamic environment; Fingerprint database

引用格式: 李园, 苏胜君, 施伟斌. 基于特征降维的在线序列学习机算法在室内动态定位中的应用[J]. 邮电设计技术, 2023(10): 54-58.

0 引言

随着无线技术的不断发展,基于位置服务的需求越来越广泛。由于全球定位系统技术(Global Positioning System, GPS)很成熟,对高精度定位技术的研究已逐渐从室外转移到室内^[1]。室内定位可采用位置指纹^[2]、测距定位^[3-5]等不同技术。位置指纹定位因定位精度高、扩展性强、易于实施等优点被广泛关注,但基

关键词:

特征降维; 在线序列学习机; 室内定位; 动态环境; 指纹数据库

doi: 10.12045/j.issn.1007-3043.2023.10.011

文章编号: 1007-3043(2023)10-0054-05

中图分类号: TN929.5

文献标识码: A

开放科学(资源服务)标识码(OSID):



于位置指纹的传统方案大多存在2个主要问题:一是在离线阶段消耗较高的时间成本;二是在在线阶段,当环境存在干扰时,指纹库难以实时反映接收信号强度值(Receive Signal Strength, RSS)的变化,从而明显影响定位精度^[6]。

在线顺序极限学习机(Online Sequential Extreme Learning Machine, OS-ELM)算法^[7]适合在动态环境下进行室内定位,在变换的新环境中,只需在少量的参考点上采集新的指纹库数据信息,用来更新补充上一次训练模型的参数,就可以在新环境中对位置信息进

收稿日期: 2023-08-18

行在线估计。在室内动态环境中,该算法相比于静态室内定位算法,在定位时间和性能上有较高的提升。然而,RSS值容易受到路径衰减、多径效应^[8]、噪声干扰^[9]等影响,获得的RSS值是复杂的非线性分布^[10]。为了解决这个问题,本文提出了PCA-OS-ELM算法,利用主成分分析^[11](Principal Component Analysis, PCA)对训练数据集进行预处理,通过投影的方式,将收集到的高维数据以最小程度的数据损失投影到低维空间,降低训练数据集维数,达到简化数据结构的的目的。同时,提取数据的主要特征成分,剔除受环境和噪声干扰的数据信息。PCA将原始RSS值转换为新函数,OS-ELM通过新函数进行训练。该算法解决了环境和噪声对定位结果的干扰,并提高了算法的计算速度。

1 算法原理

1.1 定位算法流程图

本文所提出的算法流程分为离线阶段和在线阶段(见图1),在离线阶段,对采集到的RSS信号进行均值处理,形成初始阶段指纹库。利用PCA算法提取指纹主要特征信息,去除噪声和不必要的特征信息,预处理后的RSS指纹作为离线特征指纹库。将特征指纹作为OS-ELM的训练输入,建立初始化OS-ELM模型。一旦收集到新的指纹数据,对其进行PCA特征提取后,将其集成到初始化的OS-ELM模型中,进行在线序列训练,以更新OS-ELM模型。在在线阶段,测试采集RSS信号,通过PCA进行特征降维,再利用更新的OS-ELM模型预测位置。

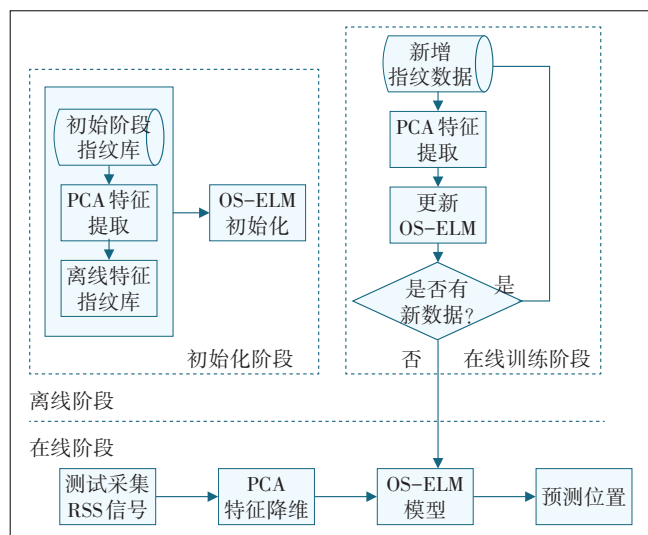


图1 定位算法流程图

1.2 PCA变换

PCA是一种数据降维的方法,通过降维去除掉冗余数据,将噪声、多径干扰等影响因素减小^[12]。其核心思想是对原始数据进行线性变换,投影到一个新的数据空间,在原始数据方差中选取贡献最大的若干维特征值,提取数据中的主要特征信息,将受到环境影响和噪声干扰的RSS信息进行剔除,降维处理^[13]后的数据既可以保留重要的特征信息,又可以去除噪声,达到提高数据处理速度和准确性的目的。

在离线阶段构建一个数据指纹库, m 个参考节点,放置 n 个锚节点。 $L_i = (x_i, y_i), i \in (1, m)$ 表示第 i 个参考节点的位置坐标, $F_{i \cdot} = (f_{i,1}, f_{i,2}, \dots, f_{i,n})$ 表示在位置坐标 L_i 接收到来自所有锚节点的RSS信号值, $F_{\cdot j} = (f_{1,j}, f_{2,j}, \dots, f_{m,j}), j \in (1, n)$ 表示所有位置点接收到来自第 j 个锚节点发出的RSS信号值,则 $F_{ij} = (F_1, F_2, \dots, F_j), j \in (1, n)$ 表示原始RSSI指纹信息库。PCA的变换过程如下。

- a) 去均值化: $\bar{F}_{\cdot j} = F_{\cdot j} - \frac{1}{m} \sum_{i=1}^m f_{ij}$
- b) 求协方差矩阵: $C = \frac{1}{n-1} \sum_{j=1}^n \bar{F}_{\cdot j} \bar{F}_{\cdot j}^T$
- c) 求出协方差矩阵的特征值 λ_j 及对应的特征向量 V_j 。
- d) 将特征向量按对应特征值从大到小按行排列成矩阵,取前 k 行组成矩阵 $T_{jk} (k < j)$ 。
- e) 降维后的特征矩阵: $X = X_{ik} = F_{ij} \times T_{jk}$ 。

其中, k 表示主元的个数,可以采用交叉验证的方式取值,也可以从主元成分贡献率方面选取阈值。

1.3 基于特征提取的OS-ELM算法

极限学习机ELM是一种单隐层前馈神经网络(Singlehidden Layer Feedforward Neural Network, SLFN)的机器学习算法^[14]。ELM用于单隐层前馈神经网络训练,可自适应设置隐层节点数,并对输入权值和隐层偏差进行随机分配,输出层权值由最小二乘法获得,整个学习过程无需迭代,以实现快速学习和高性能。OS-ELM是极限学习机的在线版本,可以对固定或可变块大小的数据进行逐个或逐块的学习^[15]。经过PCA预处理后的离线特征指纹信号 $X = (x_1, x_2, \dots, x_i), i \in (1, m)$ 作为极限学习机的训练输入,其中 $x_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ 表示第 i 个位置点采集到 k 个锚节点的信号强度。 $Y = (y_1, y_2, \dots, y_i), i \in (1, m)$ 是训练输出的位置坐标,其中 $y_i = (y_{i1}, y_{i2})$ 表示第 i 个位置点对应的

横坐标和纵坐标。若具有 L 个隐含层节点的SLFN能够以零误差近似于这 m 个样本,则存在 ω_j, b_j, β_j ,使得:

$$f_L(x_i) = \sum_{j=1}^L \beta_j H(\omega_j, b_j, x_i) = y_i, i = 1, 2, \dots, m \quad (1)$$

其中 ω_j, b_j 表示第 j 个隐含层节点的输入权重和偏置, β_j 表示第 j 个隐含层节点的输出权重, $H(\omega_j, b_j, x_i)$ 为激励函数。ELM的网络结构如图2所示。

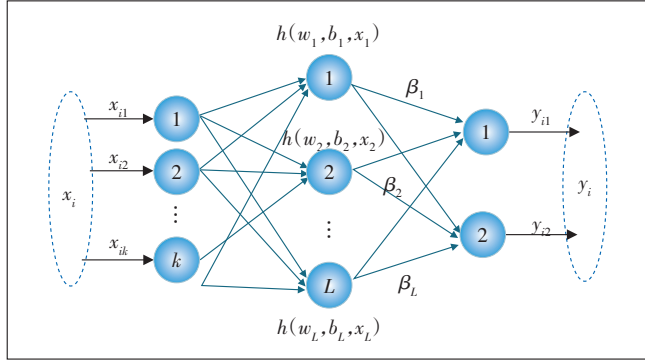


图2 极限学习机网络结构图

OS-ELM^[16]算法包含2个阶段,分别是初始化阶段和顺序学习阶段。在初始化阶段采集数据 $N_0 = \{x_i, y_i\}_{i=1}^m, m > L$ 用于训练网络模型,其中 m 表示初始化阶段采集样本点数量, L 表示隐含层神经元个数。

式(1)可以采用矩阵的形式表示如下:

$$H_0 \beta = Y_0 \quad (2)$$

给 ω_j, b_j 随机赋值,计算隐含层输出矩阵 H_0 :

$$H_0 = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_m + b_1) & \cdots & g(w_L \cdot x_m + b_L) \end{bmatrix}_{m \times L} \quad (3)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}_{L \times 2}, Y_0 = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}_{m \times 2} \quad (4)$$

单隐层神经网络学习的目标是使得输出的误差最小,可以表示为:

$$\|H_0 \hat{\beta} - Y_0\| = \min_{\hat{\beta}} \|H_0 \beta - Y_0\| \quad (5)$$

输出权重计算如下:

$$\hat{\beta} = H^\dagger Y_0 \quad (6)$$

式(6)中, H^\dagger 是矩阵的Moore-Penrose广义逆矩阵^[17], H^\dagger 可通过奇异值分解(SAD)方法^[18]进行求解,计算结果如下:

$$H^\dagger = (H_0^T H_0)^{-1} H_0^T \quad (7)$$

$$\hat{\beta} = (H_0^T H_0)^{-1} H_0^T Y_0 = P_0 H_0^T Y_0 \quad (8)$$

式(8)中, $P_0 = (H_0^T H_0)^{-1}$ 。

设置初始阶段的 $t=0, t$ 表示数据采集的次数。当环境发生变化时,在新环境中再采集部分数据进行训练,用 $t+1$ 次数据计算隐含层输出矩阵 H_{t+1} ,进而计算新的输出权重,计算如下:

$$P_{t+1} = P_t - P_t H_{t+1}^T (I + H_{t+1} P_t H_{t+1}^T)^{-1} H_{t+1} P_t \quad (9)$$

$$\beta_{t+1} = \beta_t + P_{t+1} H_{t+1}^T (Y_{t+1} - H_{t+1} \beta) \quad (10)$$

2 实验结果与分析

2.1 实验场景

为了评估该算法的性能,本文选择某学院9楼作为实验场地,该楼层有办公室、会议室、休息区,存在着一定的遮挡物与干扰,实验环境具有代表性。实验区域(58 m×14 m)集中在两边的走廊和中间的大厅,两边的走廊一共分布着26个锚节点,每边各13个,节点之间的间隔为4.8 m。中间区域用于训练数据和测试数据的采集,如图3所示。

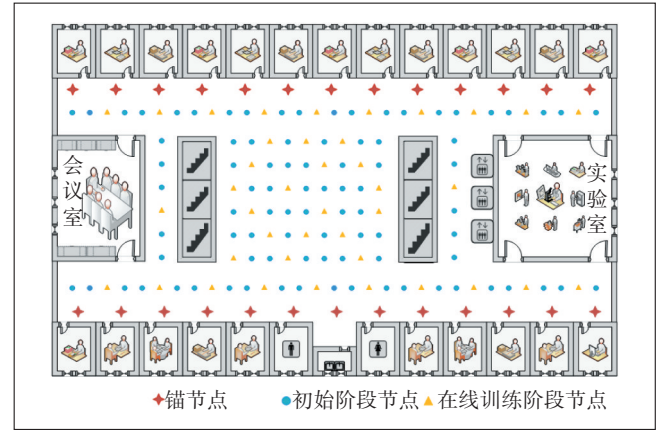


图3 实验环境平面图

在初始阶段,随机选择了88个离线参考点,每个点采集数据100次并进行均值化处理。在数据采集过程中,由于干扰或墙壁的遮挡,使得某些位置点接收不到信号,统一标记为-90 dBm。根据训练输入与训练目标,构建OS-ELM初始阶段模型。在线阶段,实验环境考虑了无人干扰和有人干扰2种场景,每种环境选择20个在线参考点,每个点采集数据200次并进行均值化处理,然后进行在线化训练,构建新的指纹数据库。同时在这2种环境下进行测试数据的采集,通过数据处理以及算法对比,评估本文所提出的算法性能。

2.2 参数设置

如图4所示,由于特征值贡献率的不同,主元数量

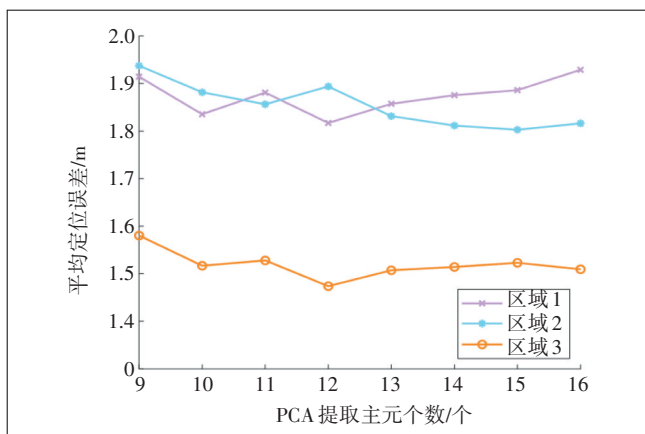


图4 主元个数对定位精度的影响

的选择对定位性能有很大的影响^[19]。主元数量过多使计算量增大,而过小则可能会损失较多的原始信息。通过实验环境仿真发现,随着主元个数增多,定位误差并没有减小,而是处于一个波动的状态,说明主元个数与定位精度之间并不是正相关的。在区域1和区域3中,主元个数为12的时候定位误差最小,区域2在主元个数为15时定位精度最高,由于本文实验环境中锚节点个数并不多,因此选择PCA的主元个数为12,在减小计算量的同时提高定位精度。

OS-ELM的隐含层节点的输入权重 ω_i 和偏置 b_i 在 $[-1, 1]$ 范围内随机赋值,隐含层节点数和激活函数^[20]通过仿真实验进行选择,计算高斯RBF激活函数 $H(\omega, b, x) = e^{-b|x-\omega|^2}$ 和Sigmoid激活函数 $H(\omega, b, x) = \frac{1}{1 + e^{-(ax+b)}}$ 在不同的隐含层节点下的累计误差分布(见图5)。通过实验发现Sigmoid激活函数的OS-ELM的性能优于RBF激活函数的OS-ELM性能,当隐含层节点数超过15时,2种激活函数的OS-ELM性能变得稳定。因此,实验时选择Sigmoid函数作为OS-ELM的激活函数,隐含层节点数选择16。

2.3 实验结果分析

图6和图7分别给出了有人环境和无人环境下的定位误差。从图6和图7可知,在2种不同的环境下,有人环境的定位误差明显大于无人环境,这表明环境干扰会导致数据信号产生偏差,影响定位结果。在有人环境中,PCA-OS-ELM算法的定位误差比其他2种算法小,说明该算法可以对环境中的干扰进行剔除,提高定位精度。在无人环境中,PCA-OS-ELM算法90%的累计误差在1.8 m以内,说明PCA-OS-ELM算法的定位误差更小。对比2种实验环境下的数据发




图5 不同激活函数和不同隐藏节点数的定位精度

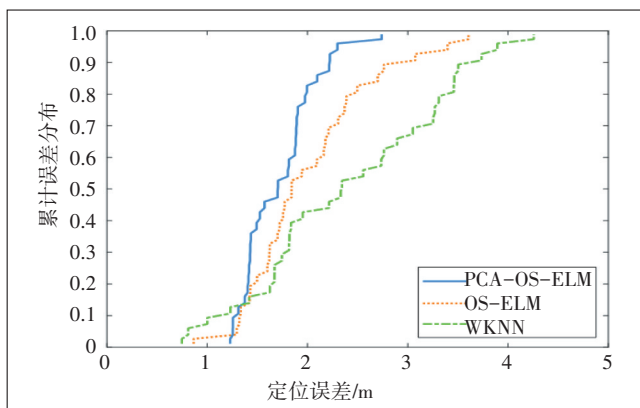


图6 有人环境下的定位误差

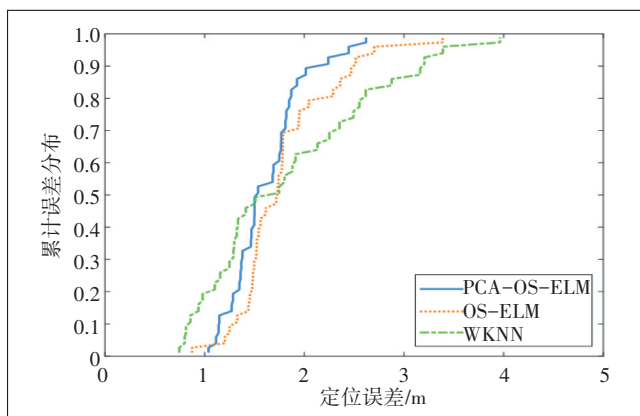


图7 无人环境下的定位误差

现,本文提出的算法能在不同环境中保持定位精度的稳定性,且可以在新环境中快速更新新数据库,减少训练时间。

表1所示为定位算法的性能比较。由表1可知,在有人干扰的环境下,PCA-OS-ELM算法的平均定位误差相比于OS-ELM减小了14.4%,相比于WKNN减小了28.6%;在无人干扰的环境下,PCA-OS-ELM算法

表1 定位算法的性能比较

环境	算法	平均定位误差/m	算法耗时/s
有人环境	PCA-OS-ELM	1.72	1.36
	OS-ELM	2.01	1.27
	WKNN	2.41	1.31
无人环境	PCA-OS-ELM	1.62	0.74
	OS-ELM	1.79	0.66
	WKNN	1.83	1.43

的平均定位误差相比于OS-ELM减小了10.1%，相比于WKNN减小了11.5%。对比这3种算法可知，WKNN的性能随着人为干扰而变差，而本文提出的算法可以自适应感知环境变化，剔除干扰因素，平均定位误差随环境波动很小。从算法耗时来看，本文提出的算法在OS-ELM的基础上引入PCA对原始数据进行处理，但耗时并没有明显增加。当环境变化时，指纹库无需重构，所以与WKNN相比，耗时减少了48.3%。

3 结束语

本文提出了一种基于PCA-OS-ELM的室内定位算法，旨在解决指纹定位算法在离线阶段训练成本高、接收信号强度值易受噪声的影响，对环境的动态变化缺乏灵活性的问题。在无人环境和有人环境进行对比实验，结果表明，PCA算法可以有效去除数据中的冗余信息，减小环境变化带来的干扰。OS-ELM的快速学习速度明显减少了离线校准阶段现场测量的时间消耗和人力成本。此外，OS-ELM的在线顺序学习能力使其能够及时反映和适应环境变化。未来可以在其他室内场景中进行实验使PCA-OS-ELM的性能评估更具决定性。

参考文献：

[1] ZAFARI F, GKELIAS A, LEUNG K K. A survey of indoor localization systems and technologies[J]. IEEE Communications Surveys & Tutorials, 2019, 21(3): 2568-2599.

[2] XUE W, HUA X, LI Q, et al. A new weighted algorithm based on the uneven spatial resolution of RSSI for indoor localization[J]. IEEE Access, 2018, 6: 26588-26595.

[3] OUYANG X, YAO S, WAN Q. A Coherent Integrated TDOA Estimation Method for Target and Reference Signals[J]. Electronics, 2022, 11(16): 2632.

[4] ZHENG Y, SHENG M, LIU J, et al. Exploiting AoA estimation accuracy for indoor localization: A weighted AoA-based approach[J]. IEEE Wireless Communications Letters, 2018, 8(1): 65-68.

[5] YUAN P, ZHANG T, YANG N, et al. Energy efficient network localization using hybrid TOA/AOA measurements[J]. IET Communications, 2019, 13(8): 963-971.

[6] ZOU H, LU X, JIANG H, et al. A fast and precise indoor localization algorithm based on an online sequential extreme learning machine[J]. Sensors (Basel, Switzerland), 2015, 15(1): 1804-1824.

[7] ZHANG M, WEN Y, CHEN J, et al. Pedestrian dead-reckoning indoor localization based on OS-ELM[J]. IEEE Access, 2018 (6): 6116-6129.

[8] XIE T, JIANG H, ZHAO X, et al. A Wi-Fi-Based wireless indoor position sensing system with multipath interference mitigation[J]. Sensors, 2019, 19(18): 3983.

[9] CHEN Z, WANG J. ES-DPR: A DOA-based method for passive localization in indoor environments[J]. Sensors, 2019, 19(11): 2482.

[10] DAIYA V, EBENEZER J, MURTY S A V S, et al. Experimental analysis of RSSI for distance and position estimation[C]//2011 International Conference on Recent trends in information technology (ICRTIT). IEEE, 2011: 1093-1098.

[11] LI N, GUO S, WANG Y. Weighted preliminary-summation-based principal component analysis for non-Gaussian processes[J]. Control Engineering Practice, 2019(87): 122-132.

[12] ZHANG D, LI N, YE Q. Positional context aggregation network for remote sensing scene classification[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 17(6): 943-947.

[13] 张贺娜, 乐燕芬, 施伟斌. 基于特征降维的核岭回归室内定位算法[J]. 仪器仪表学报, 2020, 41(10): 83-91.

[14] YAN J, CAO Y, KANG B, et al. An ELM-based semi-supervised indoor localization technique with clustering analysis and feature extraction[J]. IEEE Sensors Journal, 2020, 21(3): 3635-3644.

[15] DENG C H, WANG X J, GU J, et al. A review of online sequential extreme learning machines[C]//Journal of Physics: Conference Series. IOP Publishing, 2019, 1302(3): 032054.

[16] 乔延松, 贺泽华, 赵绪营. 面向动态数据流的改进OSELM算法研究[J]. 北京电子科技学院学报, 2020, 28(3): 1-12.

[17] HUANG G B. An insight into extreme learning machines: random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3): 376-390.

[18] MATEEN M, WEN J, SONG S, et al. Fundus image classification using VGG-19 architecture with PCA and SVD[J]. Symmetry, 2018, 11(1): 1.

[19] 乐燕芬, 汤卓, 盛存宝, 等. 基于多分布密度位置指纹的高效室内定位算法研究[J]. 通信学报, 2019, 40(1): 172-179.

[20] 陈明玲. 基于不同激活函数ELM的无人机实测数据高程拟合算法[J]. 北京测绘, 2020, 34(8): 1057-1060.

作者简介：

李园, 上海理工大学在读硕士, 主要从事无线传感器网络定位研究工作; 苏胜君, 上海理工大学讲师, 博士, 主要从事无线传感器网络应用研究工作; 施伟斌, 上海理工大学副教授, 博士, 主要从事无线传感器网络协议与应用技术研究工作。