

# 一种自适应于不同场景的智能无线传播模型

高士顺 赵海涛 张晓瀛 魏急波

国防科技大学电子科学学院 长沙 410073

(996672196@qq.com)

**摘要** 无线传播模型由于其对无线电波路径损耗的精准预测及对通信速率与覆盖范围等指标的估算起重要支撑作用,被广泛应用于民用和军用的通信系统设计。近年来,随着人工智能技术的发展,无线传播模型的发展方向也由传统的经验模型向基于数据驱动的智能无线传播模型发展,该类方法可有效地扩展无线传播模型的适用范围并减小预测误差。然而,由于在不同环境下智能无线传播模型的适用特征可能并不相同,如何针对不同场景最优地为智能无线传播模型设计以及选择输入特征是一个重要的研究问题。立足以上需求,提出了一种自适应智能无线传播模型。首先,该模型借鉴经验模型在不同场景下对频率、距离等特征的不同处理方式,对现有的输入特征集合进行了扩充;然后,基于在建模区域采集的训练数据,该模型利用模拟退火算法来自适应地针对当前建模区域为智能无线传播模型选择最优的输入特征子集,从而避免受到无关特征的影响;最后,基于优化过程所搜索到的最优输入特征子集,该模型利用采集到的全部数据对智能无线传播模型进行重新训练,并将该智能无线传播模型进行部署,以预测该区域的路径损耗。仿真结果表明,在复合地形下的 LTE 网络数据以及其他典型数据集下,与传统的经验模型以及现有的智能无线传播模型相比,所提模型对各种传播场景均具有适用性,且进一步减小了路径损耗的预测误差。

**关键词:** 深度学习;无线传播模型;模拟退火算法;经验模型

**中图法分类号** TN92

## Self-adaptive Intelligent Wireless Propagation Model to Different Scenarios

GAO Shi-shun, ZHAO Hai-tao, ZHANG Xiao-ying and WEI Ji-bo

College of Electronic Science, National University of Defense Technology, Changsha 410073, China

**Abstract** The wireless propagation model, which can accurately predict the path loss of radio waves, plays an important role in the estimation of communication rate, coverage and interference. It plays a fundamental role in the design of communication systems in civil and military fields. With the advance in artificial intelligence, there appears a significant trend to develop intelligent wireless propagation model that replaces the empirical formula with machine learning algorithms to fit the path loss. The intelligent wireless propagation model effectively extends the applicability of the propagation model and reduces the error in predicting path loss. However, because the optimal input features set of the intelligent wireless propagation model may be different in different propagation environments, it is important to optimally design and select the input features for different scenarios. Therefore, this paper proposes a self-adaptive intelligent wireless propagation model (SAIWP). Firstly, inspired by the processing methods of empirical model for features in different scenarios, the SAIWP model extends the input features set of the intelligent wireless propagation model. And then, the SAIWP model uses the simulated annealing algorithm to self-adaptively select the optimal input feature subset to reduce the error in the prediction of path loss. Finally, the SAIWP model exploits the optimal input feature subset in the optimization process and all data set to train the intelligent wireless propagation model. Simulation results show that, in the LTE networks and the smart campus, compared with traditional empirical models and intelligent wireless propagation models, the SAIWP model predict accurately in various terrains and distances, and effectively reduces the error in the prediction of path loss.

**Keywords** Deep learning, Wireless propagation model, Simulated annealing algorithm, Empirical model

## 1 引言

无线传播模型作为无线网络系统规划的关键技术,通过预测网络覆盖范围内无线电波的路径损耗,可以估算通信速

率、覆盖范围以及区间干扰等关键指标<sup>[1]</sup>。因此该技术已被广泛应用于军事、商业及民用生活,如中继节点的部署以及移动蜂窝网络的基站选址等。然而,由于传播环境的复杂性,无线电波在传输过程中往往会受到各种因素的影响,如建筑物、

到稿日期:2020-10-29 返修日期:2021-02-09

基金项目:国家自然科学基金重点项目(61931020)

This work was supported by the Key Program of the National Natural Science Foundation of China(61931020).

通信作者:赵海涛(haitaozhao@nudt.edu.cn)

森林、湖泊、大气以及地球曲率等,使得电磁波不再以单一的方式和路径进行传播而产生复杂的反射、折射、散射、绕射以及透射等。因此,构建一个准确的无线传播模型是一项具有挑战性的任务。

传统的无线传播模型分为以下3种,分别是确定性模型、经验模型以及改进型经验模型。确定性模型根据电磁波的传输理论,在考虑电磁波在空间中的折射、反射、绕射等的基础上通过麦克斯韦方程组来对路径损耗进行求解,其中射线追踪法<sup>[2-4]</sup>为典型的方法。该类方法具有较高的预测准确性,但需要对物理环境进行精准建模并且复杂度较高,因此往往只能应用于简单的物理环境。经验模型通过统计方法从经验数据中拟合固定的经验公式来完成模型构建,典型方法有 Okumura-Hata<sup>[5]</sup>和 Cost-231 模型等。改进型经验模型则是在经验模型的基础上引入更多的可调参数,从而能够对更细致的场景进行建模,典型的方法有 Standard Propagation Model 等。经验模型与改进型经验模型所需计算量低,能广泛应用于各种场景且易于实现,但其预测值与实际路径损耗往往存在一定的误差。

为了使无线传播模型能够在各种复杂的物理环境下均表现良好,机器学习技术与无线传播模型相结合的智能无线传播模型成为了当前的热点研究问题。通过将无线传播模型建模成机器学习中的有监督回归问题,研究者们利用机器学习算法来拟合输入特征(如天线高度、频率、距离等)与其对应的路径损耗之间的关系。文献<sup>[6-16]</sup>分别从智能无线传播模型中不同的机器学习方法(支持向量机、神经网络等)、物理环境(城市、郊区和农村等)以及工作频带等方面展开了研究。基于机器学习算法强大的拟合能力,以上工作<sup>[6-16]</sup>在扩展了无线传播模型适用范围的同时也有效地降低了预测误差。然而当下无线传播模型的应用场景变得更加复杂,在建模区域内往往存在多种地形,并且不同建模区域内的各种地形所占比例可能各不相同。现有建模方法<sup>[6-16]</sup>在面对这些不同的复杂建模区域时,未考虑不同场景的适用特征并不相同,而仅仅是将天线高度、频率以及距离等同一套特征简单地输入模型。当不相关的特征被输入机器学习算法时,机器学习算法往往会拟合于该特征并导致预测误差增加。因此如何针对不同场景最优地为智能无线传播模型设计以及选择输入特征是一个重要的研究问题。

基于以上问题,本文提出了一种自适应智能无线传播模型(Self-Adaptive Intelligent Wireless Propagation Model, SAIWP)。该模型在建模过程中能够自适应地针对当前建模区域为智能无线传播模型筛选最适合的输入特征,从而使得路径损耗预测误差被有效降低。本文的主要贡献以及创新点总结如下。

(1)根据典型经验模型(如 Okumura-Hata 以及 COST-231 等)在不同场景下对频率、距离等特征的不同处理方式,本文提出了一种特征扩展方式。该方式按照原始特征(现有智能无线传播模型的输入特征集合)、处理特征(按照经验模型中特征处理方式处理后的特征)以及经验模型特征(典型经验模型的预测结果)3方面对输入特征集合进行扩充,而不是像现有方法那样仅将原始的采集数据输入网络。

(2)为自适应地针对当前建模区域为智能无线传播模型筛选出最适合的输入特征子集,本文将模拟退火算法与特征筛选过程相结合。通过将输入特征进行01编码,并将训练后的智能无线传播模型的预测性能当作评价标准,本文所提的SAIWP模型能够利用模拟退火算法在众多特征子集中搜索到性能较优的输入特征子集,从而避免智能无线传播模型受到无关特征的影响。

(3)根据不同的典型路径损耗预测数据集,本文在均方误差(Mean Squared Error, MSE)、平均绝对误差(Mean Absolute Error, MAE)、平均误差(Mean Error, ME)以及标准差(Standard Deviation, STD)等方面将本文所提SAIWP模型与一些典型的无线传播模型进行对比。实验结果表明,本文的特征扩展方法以及特征筛选方法均能够明显地降低路径损耗的预测误差。同时,本文所提SAIWP模型对多种传播场景均具有适用性。

本文第2节综述了智能无线传播模型的研究现状;第3节介绍了数据集以及常见传播模型;第4节描述了本文提出的一种自适应智能无线传播模型;第5节通过实验来验证了所提模型的性能;最后总结全文。

## 2 相关工作

智能无线传播模型,即为利用机器学习技术来拟合收发节点之间天线高度、频率、距离等特征与其对应路径损耗之间关系的模型。由于机器学习技术具备强大的拟合能力,以及运营商等无线传播模型的实施者具备充足的资源来采集数据并训练模型,因此该技术已经展现出十分优越的性能并且在工业界及学术界都已被广泛地研究并应用。机器学习中的各种典型技术在智能无线传播模型的建模中都有所应用。例如, Aldossari 等利用线性回归方法对5G毫米波通信中的路径损耗进行预测<sup>[6]</sup>, Goudos 等<sup>[7]</sup>与 Wen 等<sup>[8]</sup>分别验证了支持向量机在路径损耗预测中的效果。与传统的经验模型方法相比,以上基于机器学习的方法在计算复杂度以及准确度上均展现出更优秀的性能。

近年来,随着神经网络技术的迅速发展,考虑到建立无线传播模型时采集数据的常见形式(非矩阵类数据、无时序性),研究者们逐渐将无线传播模型与学习性能更强的神经网络技术相结合,并提出一些基于人工神经网络(Artificial Neural Network, ANN)的方法<sup>[9-16]</sup>。文献<sup>[9-16]</sup>分别从智能无线传播模型中的神经网络结构、应用环境以及工作频带等方面展开了研究。在神经网络结构方面,文献<sup>[9-10]</sup>针对智能无线传播模型中神经网络的不同层数以及训练方式等方面展开了研究。这些工作指出人工神经网络是对无线传播模型进行良好建模的工具,反向传播则是其常用的训练方式。同时文献<sup>[10]</sup>指出,3层神经网络(输入层、单隐含层、输出层)是智能无线传播模型中合适的网络结构,过多的网络层数将会导致神经网络过度拟合于训练数据,从而产生过拟合。

在应用环境方面,现有工作分别从城市<sup>[11-14]</sup>、郊区<sup>[15]</sup>、乡村<sup>[15]</sup>以及森林<sup>[16]</sup>等方面展开了研究。在工作频段方面,现有的工作主要集中在UHF(Ultra High Frequency)频段,例如2.4GHz<sup>[16]</sup>等。文献<sup>[9-16]</sup>的验证结果表明,与基于典型

机器学习方法的无线传播模型相比,基于人工神经网络的无线传播模型表现出更准确的预测性能,并且极大地扩展了传统经验模型的应用场景以及工作频带。但是,这些智能无线传播模型在设计模型的输入特征时,仅将采集到的收发节点间频率、距离、天线高度等数值直接当作模型的输入特征,并未对其进行扩展及筛选,从而使得有些有效特征并未产生预期效果且导致一些无用特征对预测结果产生了负面影响。因此,以上智能无线传播模型的预测性能仍有进一步提升的空间。

智能无线传播模型的输入特征筛选问题具体指:当前有  $N$  个特征,其共有  $2^N - 1$  个可选特征子集,则如何在  $2^N - 1$  个特征子集中选择出预测性能最优的特征子集。此问题在数据挖掘领域已经得到充分研究,并且 Chen 等已经证明了搜索最优特征子集为 NP 问题<sup>[17]</sup>。现有的特征筛选方法一般可以分为过滤式(filter)、嵌入式(embedded)以及封装式(wrapper)三大类<sup>[18]</sup>。过滤式方法的使用独立于预测模型的训练过程,此类方法需要在预测模型建立前按照某些准则对单个特征的重要程度进行评判,并对重要程度较低的特征进行剔除。在过滤式方法中,常用的衡量准则有信息增益、相关系数、距离度量等<sup>[18]</sup>。此类特征筛选方法计算效率较高,但对特征之间的组合效应未加考虑,因此特征子集的预测效果并不理想。

嵌入式方法的特征筛选过程是在预测模型的训练过程中完成的。通过引入 L1 系数或 L2 系数,预测模型能够在训练过程中自主地决定降低哪些特征的权重。该类方法筛选出的特征子集性能较好,并且拥有较高的计算效率。封装式方法

将预测模型视作黑盒,并且将训练后预测模型的性能当作特征子集的评价标准,然后通过随机搜索方法在  $2^N - 1$  个特征子集中进行搜索。此类方法中,常用的搜索方法为遗传算法<sup>[19]</sup>、模拟退火算法<sup>[20]</sup>以及禁忌算法<sup>[21]</sup>等。由于封装式方法需要多次执行训练过程以评估特征子集的性能,因此该方法的计算量较大,但是该类方法也能获得近似最优解的特征子集<sup>[22]</sup>。因此,考虑到特征筛选方法的性能以及运营商等无线传播模型的实施者所具备的充足的计算能力,本文将利用封装式方法来对智能无线传播模型的输入特征进行筛选。

### 3 数据与常见传播模型

为便于读者理解本文所提的 SAIWP 模型,本节将依次对无线传播模型建模所用数据集的常见形式以及 SAIWP 模型特征扩展时所借鉴的经验模型进行介绍。

#### 3.1 数据

本节以华为提供的 LTE 网络数据为例,使读者能够对无线传播模型的常见应用场景以及建模所用数据有直观的了解。

如图 1(a)所示,该数据集是在 LTE 蜂窝通信场景中采集到的。在该场景中,用户终端与对应基站以 2.6 GHz 的频率交互,并且不同基站之间互不干扰。整个数据集共包括 4000 个基站和 12011833 个接收测量点,其中测试点的覆盖面积为  $45\text{ km} \times 50\text{ km}$ ,并且测量点所在地形涵盖了如表 1 所列的内陆湖泊、植被区、中心城区、郊区以及农村等 20 种常见的地物类型。




图 1 测试场景

Fig. 1 Communication scenarios

表 1 地物类型

Table 1 Types of scenario

序号	地形	序号	地形
1	海洋	11	城区小于 20m 高密度建筑群
2	内陆湖泊	12	城区小于 20m 多层建筑
3	湿地	13	低密度工业建筑区域
4	植被区	14	高密度工业建筑区域
5	灌木植被	15	城郊开阔区域
6	森林植被	16	市区开阔区域
7	农村	17	道路开阔区域
8	城区超高层建筑(>60m)	18	城郊
9	城区高层建筑(40~60m)	19	发达城郊区域
10	城区中高层建筑(20~40m)	20	CBD 商务区

数据集的测试场景如图 1(b)以及图 1(c)所示。在该场景下,如表 2 所列,针对每个测试点共需要测量以及计算的数值有 14 个,其中路径损耗为测量的实际损耗值(标

签),其表达式为:

$$L = 10 \log \left( \frac{P_r}{P_t} \right) \text{ (dB)} \quad (1)$$

其中,  $P_r$  与  $P_t$  分别为接收信号与发射信号的能量, dB 为无线传播模型中表示倍数的常见单位。

表 2 测量特征

Table 2 Measuring features

参数名称	单位	参数名称	单位
基站与测量点的距离 $d$	km	测量点地物类型 $c_i$	—
基站附近建筑物高度 $h_{cb}$	m	天线垂直角度 $\theta_d$	Deg
测量点附近建筑物高度 $h_b$	m	天线水平角度 $\theta_a$	Deg
测量点与信号线垂直距离 $d_d$	m	中心频率 $f$	MHz
测量点与信号线水平距离 $d_a$	km	基站海拔 $h_{ca}$	m
基站高度 $h$	m	测量点海拔 $h_a$	m
基站地物类型 $c_i$	—	路径损耗 $L$	dB

整个数据集的电子地图如图 2 所示,其中黑点代表基站,红色点代表不同高度的测试点。




图 2 电子地图(电子版为彩色)

Fig. 2 Electronic map

由于该数据集包含较多数据,为方便建模及检验,本文在地图中提取了一块明显包含多种地形的区域进行研究,其提取方案如图 2 所示。该区域不仅包括建筑物地形,同时含有内陆湖泊以及植被区等类型的地形。

### 3.2 经验模型

经验模型指通过统计方法从经验数据(如 3.1 节介绍的数据形式)中拟合固定的经验公式来完成路径损耗预测的方法,其在实际工程中被广泛应用且在不同场景下均有不同形式的变形。本节将对常见的经验模型进行介绍。

自由空间(free space)传播模型是无线传播模型中最简单的一种模型。该模型是指电磁波在自由空间(无阻挡、无衰减)中传输,并且不伴随反射、折射以及绕射等现象,其能量的损失仅仅是能量的辐射导致的。自由空间传播模型的经验公式表达如下:

$$L = 32.45 + 20 \log_{10}(f) + 20 \log_{10}(d) \quad (2)$$

Okumura-Hata<sup>[5]</sup>传播模型是在预测城市以及其周边区域时最常用的经验模型,该模型是利用测量数据拟合计算得到的公式,适用频段很广,其表达式如下:

$$L = 69.55 + 26.16 \log_{10}(f) - 13.82 \log_{10}(h) + (44.9 - 6.55 \log_{10}(h)) \log_{10}(d) + \alpha(h_r) \quad (3)$$

其中, $h_r$ 是接收端天线高度, $\alpha(h_r)$ 是在不同地形下的修正因子。对于大城市、郊区以及农村, $\alpha(h_r)$ 可以分别表示为:

$$\alpha(h_r) = 3.2 (\log_{10} 11.75 h_r)^2 - 1.1 \quad (4)$$

$$\alpha(h_r) = 2 (\log_{10}(f/28))^2 - 5.4 \quad (5)$$

$$\alpha(h_r) = 4.78 (\log_{10} f)^2 + 18.33 \log_{10} f + 40.98 \quad (6)$$

本文将分别通过 OKH-Urban、OKH-Suburban 以及 OKH-Rural 来表示 Okumura-Hata 模型在城市、郊区以及农村的相应形式。

COST-231 模型同样是蜂窝网络中常见的无线传播模型,其表达式如下:

$$L = 46.3 + 33.9 \log_{10}(f) - 13.82 \log_{10}(h) + (44.9 - 6.55 \log_{10}(h)) \log_{10}(d) \quad (7)$$

观察式(7)可知,经验模型从采集数据中拟合的经验公式较为简单。在实际使用时,仅需要将频率、距离以及天线高度等特征进行 $\log_{10}(\cdot)$ 或 $\log_{10}^2(\cdot)$ 等处理,随后通过采集数据对公式中的系数稍作调整即可使用,并且式(7)能在路径损耗预测上取得良好效果。因此可以得出猜想,经验模型在不同场景下对不同特征的处理方式能够有效地提升

无线传播模型的预测性能。

## 4 自适应智能无线传播模型

本节将对所提的 SAIWP 模型进行介绍。由于神经网络在智能无线传播模型中表现出色<sup>[9-16]</sup>,考虑到采集数据的常见形式(非矩阵类数据、无时序性),SAIWP 模型将采用人工神经网络来对路径损耗进行拟合。SAIWP 模型由 4 部分组成,分别为特征构建、新解产生、特征选择及整体训练,其中新解产生和特征选择组成模拟退火算法。模型的示意图如图 3 所示。

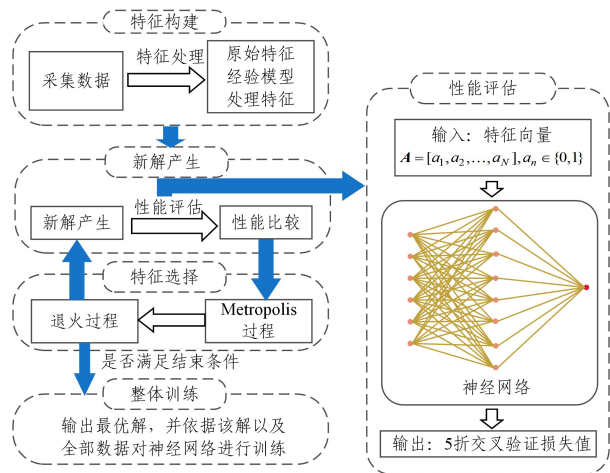


图 3 SAIWP 模型示意图

Fig. 3 Diagram of SAIWP

### 4.1 特征构建

为了加强输入特征集合与路径损耗的关联性以及为了便于后续步骤中针对建模区域进行特征筛选,SAIWP 模型首先对表 2 所列的原始特征(直接从物理环境中采集的数据)进行了扩展。

扩展特征的第一部分为处理特征。该部分特征是由原始特征经过典型经验模型在不同场景下对原始特征的处理方式变换而来的,例如对距离  $d$  做 $\log_{10}(\cdot)$ 处理(参考式(2)),以及对频率  $f$  做 $\log^2(\cdot)$ 处理(参考式(6))等。总结式(2)一式(7),本文共转化得到了 13 个处理特征,这些处理特征及其借鉴模型展示如表 3 所列。

表 3 处理特征

Table 3 Feature processing

借鉴模型	处理后特征
Free Space	$\log_{10}(f) \log_{10}(d)$
COST-231	$\log_{10}(d_a) \log_{10}(d_b)$
	$\log_{10}(h) \log_{10}^2(f) \log_{10}(h) \log_{10}(d)$
Okumura-Hata	$\log_{10}(h_{cb}) \log_{10}(h_{ca}) \log_{10}(h) \log_{10}(d_a)$
	$\log_{10}(h_a) \log_{10}(h_b) \log_{10}(h) \log_{10}(d_a)$

扩展特征的第二部分为经验模型特征。该部分特征是典型经验模型的路径损耗预测结果,即将表 2 中的原始特征直接输入式(2)一式(7)所得的预测结果(共 5 个经验模型特征)。采用该类特征的原因:如果经验模型能够对所应用区域精准建模并且表现良好,那么神经网络在训练时仅输出该特征即可完成训练,因此能够有效减少训练损耗。

综上,经过以上两部分的扩展处理,原始特征(表2中除路径损耗以外的所有特征值)、处理特征(如表3所列)以及经验模型特征(Okumura-Hata在城市、农村和郊区3种地形下相应传播模型、COST-231模型以及自由空间传播模型的预测结果)将被当作SAIWP模型中神经网络的输入特征集合(共31个特征)。

因此,当实施者在建模区域按照表2所列的原始特征形式采集了数据集 $\mathbf{D}$ 后(长度为 $I$ 的13维数据),SAIWP模型将按照处理特征以及经验模型特征将 $\mathbf{D}$ 扩展为31维。

在完成特征构建后,为加速后续神经网络的收敛并且提升神经网络模型的预测精度,本文按照式(8)对每个特征进行归一化处理:

$$x_n = \frac{x_n - \min(x_n)}{\max(x_n) - \min(x_n)}, n = 1, 2, \dots, N \quad (8)$$

其中, $x_n$ 为所有样本的第 $n$ 个特征, $N$ 为特征长度。

#### 4.2 新解产生

采集数据经过4.1节所述的处理后,SAIWP模型将得到一个维度(特征长度)为 $N=31$ 的数据集 $\mathbf{D}$ 。在本节以及下一节中,SAIWP模型将利用模拟退火算法来对输入特征进行筛选,从而在当前数据集 $\mathbf{D}$ 下为基于神经网络的无线传播模型搜索到最优的输入特征子集。本文采用模拟退火算法的原因:1)模拟退火算法在具备优秀的局部优化能力的同时,也具有一定的随机性(能以一定概率接受较差解),因此能够跳出局部最优解,在全局进行搜索;2)在众多随机搜索算法中,模拟退火算法的局部优化能力以及全局搜索能力都较为适中,并且根据文献[20]等工作的结果,模拟退火算法在特征子集搜索问题上能够获得良好的性能。

在SAIWP模型中,本文通过特征向量 $\mathbf{A}=[a_1, a_2, \dots, a_N]$ , $a_n \in \{0, 1\}$ 来控制神经网络的输入特征,其中 $a_n=1$ 表示第 $n$ 个特征(数据集 $\mathbf{D}$ 的第 $n$ 维)被输入神经网络,反之则不输入。假设当前模型接受的解为 $\mathbf{A}$ ,在模拟退火算法的每一次迭代过程中,算法需要按照一定准则来产生新解 $\mathbf{A}'$ 以供后续筛选过程进行挑选。具体来讲,本文通过随机抽取的方式来生成新解 $\mathbf{A}'$ ,即在每一次迭代过程中模型都在当前接受解 $\mathbf{A}$ 中随机抽取一个元素 $a_n$ 并且改变其值,以得到新解 $\mathbf{A}'$ 。

在产生新解 $\mathbf{A}'$ 后,新解 $\mathbf{A}'$ 与当前接受解 $\mathbf{A}$ 将被输入神经网络,并依次针对训练集 $\mathbf{D}_{\text{train}}$ 和测试集 $\mathbf{D}_{\text{test}}$ 进行训练和检测,以检验这些输入特征子集在该建模区域下的适应性。本文用 $f_w(\cdot)$ 来表示基于神经网络的无线传播模型,其中 $\mathbf{w}$ 代表神经网络中的所有参数。该模型的示意图如图4所示。




图4 基于神经网络的无线传播模型

Fig. 4 Neural network based wireless propagation model

在神经网络的训练阶段,本文通过梯度迭代法来对参数 $\mathbf{w}$ 进行优化,其优化目标为:

$$\min_{\mathbf{w}} \sum_{X_i, L_i \in \mathbf{D}_{\text{train}}} E(f_w(X_i), L_i) \quad (9)$$

其中, $X_i$ 为输入样本, $f_w(X_i)$ 是神经网络输出路径损耗预测值, $L_i$ 为实际的路径损耗, $E(\cdot)$ 为损失函数。对于智能无线传播模型,MSE与MAE为常见的损失函数<sup>[9]</sup>,其表达式分别为:

$$\text{MSE}: E(f_w(X_i), L_i) = (f_w(X_i) - L_i)^2 / I \quad (10)$$

$$\text{MAE}: E(f_w(X_i), L_i) = |f_w(X_i) - L_i| / I \quad (11)$$

其中, $I$ 为数据集的长度。这两个损失函数对模型的影响将在第5节进行讨论。

当给定损失函数时,神经网络的训练过程如下:

$$\mathbf{w} \leftarrow \mathbf{w} - \beta \sum_{X_i, L_i \in \mathbf{D}_{\text{train}}} \nabla_{\mathbf{w}} E(f_w(X_i), L_i) \quad (12)$$

其中, $\beta$ 为学习速率。在式(12)被执行 $E_{\text{epoch}}$ 次后,神经网络即完成训练。

在测试阶段,通过计算以上两个训练过的神经网络在测试集 $\mathbf{D}_{\text{test}}$ 上的损失值,即可得到新解 $\mathbf{A}'$ 与当前接受解 $\mathbf{A}$ 的评估性能 $E'$ 与 $E$ 。

为了避免验证过程中由于性能评估误差所造成的优化方向错误问题,本文在验证输入特征子集的适应性时将采用5折交叉验证法来减小误差。该方法通过将数据集随机划分成5份 $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_5$ ,然后轮询地取其中1份为测试集 $\mathbf{D}_{\text{test}}$ 来评估模型,将其余4份作为训练集 $\mathbf{D}_{\text{train}}$ 来训练模型,最后取这5次的泛化损失的平均值以减少随机误差。

#### 4.3 特征选择

在产生新解 $\mathbf{A}'$ 以及评估性能后,SAIWP模型将进入特征选择阶段,即对新解 $\mathbf{A}'$ 以及当前接受解 $\mathbf{A}$ 进行选择,该阶段由Metropolis过程以及退火过程两部分组成。

首先进入Metropolis过程,该过程是指对当前接受解 $\mathbf{A}$ 以及新解 $\mathbf{A}'$ 进行性能比较时,若新解 $\mathbf{A}'$ 性能较优,则说明新解 $\mathbf{A}'$ 更适合于当前建模区域,模型立即接受该解并使得 $\mathbf{A}=\mathbf{A}'$ ;若新解 $\mathbf{A}'$ 性能较差,则模型以一定概率接受该解,从而使使得模型能以一定概率跳出局部最优解,而该接收概率<sup>[20]</sup>是由退火过程所控制的温度参数决定并且可表达为:

$$p = e^{-\frac{E - E'}{T(k)}} \quad (13)$$

其中, $T(k)$ 为当前时刻的温度。

在接受解后,SAIWP模型将进入退火阶段对温度参数进行更新,温度参数的变化规律为:

$$T(k) = \lambda \cdot T(k-1) \quad (14)$$

其中, $k$ 为当前迭代时刻, $\lambda$ 为衰减系数。随着温度的逐渐降低,其解也逐渐趋于收敛。

在完成退火过程后,模型将进入下一次循环迭代。直到完成 $k_{\text{max}}$ 次优化,模型将结束求解过程并且输出此过程中的最优输入特征子集。

#### 4.4 整体训练

依据求解过程所找到的最优输入特征子集以及在建模区域的全部数据集 $\mathbf{D}$ ,神经网络将重新进行训练,从而使得数据集被充分利用。在完成训练后,该神经网络便可在该区域进行部署并对路径损耗进行预测。

总结以上过程,本文所提出的SAIWP模型如算法1所示。

##### 算法1 一种自适应于不同场景的智能无线传播模型

1. 初始化:随机初始化特征向量 $\mathbf{A}$ , $k=0$ ,数据集随机划分成5份 $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_5$ ,初始化参数 $T(0), k_{\text{max}}$ ;
2. 特征构建:对采集数据按照原始特征、经验模型特征、处理特征进行

数据转换,并进行归一化处理;

性能评估(A):

3.  $E_{ave} = 0$

4. for  $i \in \text{range}(5)$ :

5. 基于特征向量  $\mathbf{A}$  随机初始化神经网络参数  $\mathbf{w}$ ;

6. 基于  $\mathbf{D}_{-i}$  (除  $\mathbf{D}_i$  以外的所有数据集) 以及式 (12) 对神经网络  $f_w(\cdot)$  训练 Epoch 次;

7. 基于  $\mathbf{D}_i$  计算此时神经网络  $f_w(\cdot)$  的泛化误差  $E_i, E_{ave} \leftarrow E_{ave} + E_i/5$ ;

8. return  $E_{ave}$

9. 基于  $\mathbf{A}$  以及性能评估步骤 (3)–(8) 得到  $E$ ;

10. while  $k < k_{max}$ :

11. 在  $\mathbf{A}$  中随机选择  $a_n$  并且改变其值得到  $\mathbf{A}'$ ;

12. 基于  $\mathbf{A}'$  以及性能评估步骤 (3)–(8) 得到  $E'$ ;

13. if  $E' < E$ ;

14.  $\mathbf{A} = \mathbf{A}', E = E'$ ;

15. else if  $e^{\frac{E-E'}{T(k)}} > \text{rand}[0,1)$ ;

16.  $\mathbf{A} = \mathbf{A}', E = E'$ ;

17.  $k = k + 1, T(k) = \lambda \cdot T(k - 1)$ ;

18. 基于步骤 (9)–(17) 所得到的最优特征向量  $\mathbf{A}$ , 随机初始化神经网络参数  $\mathbf{w}$ , 然后基于全部数据集  $\mathbf{D}$  以及式 (12) 对神经网络  $f_w(\cdot)$  训练 Epoch 次。

## 5 实验仿真

本文通过 Tensorflow 来对所提模型进行仿真分析。本文所采用神经网络的超参数如表 4 所列, 其中神经网络层数依据文献 [10] 设置为 3 层, 其余部分超参数的影响将在 5.2 节进行分析。

表 4 超参数

Table 4 Hyperparameter

超参数名称	参数取值
<i>Epoch</i>	5 000
损失函数	MSE
激活函数	Relu
学习速率	0.01
数据集规模	150 000
降温系数 $\lambda$	0.9
初始温度 $T(0)$	10
优化次数 $k_{max}$	150
神经网络层数	3
隐含层神经元个数	256

表 6 模型输入特征

Table 6 Features of model

特征	$h_{ca}$	$h_b$	$d_a$	<i>OKH-Urban</i>	$\log_{10}(h)$	$\log_{10}(h_{cb})$	$\log_{10}(d_a)$	$\log_{10}(h)\log_{10}(d_d)$
是否输入	×	√	×	×	√	√	√	×
特征	$h_{cb}$	$d$	<i>Free Space</i>	<i>OKH-Suburban</i>	$\log_{10}(f)$	$\log_{10}(h_b)$	$\log_{10}(d_d)$	$\log_{10}(h)\log_{10}(d_a)$
是否输入	×	√	×	√	√	×	×	×
特征	$h_a$	$d_d$	<i>COST-231</i>	<i>OKH-Rural</i>	$\log_{10}(h_{ca})$	$\log_{10}(h_a)$	$\log_{10}(d)$	$\log_{10}(h)\log_{10}(d)$
是否输入	×	√	√	×	√	√	×	×
特征	$c_i$	$h$	$\theta_a$	$\theta_d$	$f$	$c_{ci}$	$\log_{10}(f)^2$	
是否输入	×	×	√	√	×	√	×	—

为进一步说明 SAIWP 模型预测性能的优越性, 本文给出了数据集中每个测试点的路径损耗泛化误差的分布情况, 如图 6 所示。

从图 6 可以看出, 模型的大部分预测误差值较小, 其中有

在仿真中, 3.1 节所介绍的 LTE 网络数据将在本节中用于智能无线传播模型的训练及检测, *MAE*, *MSE*, *ME* 及 *STD* 将作为传播模型的性能指标。为减少随机误差, 本文对不同方法都采用 5 折交叉验证法进行验证。

为综合检测本文所提方法的预测性能, 本文在模型完成训练后将神经网络分别从建模区域内的不同地形、距离以及频率等方面进行验证。同时为证明本文所提方法的有效性, 本文将其分别与已有的经验模型、智能无线传播模型以及不同优化方法的自适应智能无线传播模型进行对比。

### 5.1 SAIWP 模型仿真

表 5 列出了 SAIWP 模型在图 2 中提取区域建模所得的测试误差以及训练误差。可以看到, SAIWP 模型具有较低的泛化误差 (5.436 dB), 并且其平均误差 (0.259 dB) 在 0 dB 左右, 标准差 (4.703 dB) 小于 9, 满足国际电信联盟 (International Telecommunication Union, ITU) 的要求。

表 5 SAIWP 模型的性能

Table 5 Performance of SAIWP model

误差	<i>MAE</i>	<i>MSE</i>	<i>ME</i>	<i>STD</i>
测试误差	5.436	52.493	0.259	4.703
训练误差	4.308	33.312	0.150	3.772

SAIWP 模型在该建模区域中所得的最优输入特征子集如表 6 所列, 该特征子集的训练过程如图 5 所示。从表 6 可以看出, SAIWP 模型能够有效地依据该区域的特点选择相应特征, 例如提取区域在图 2 中明显处于郊区地带, 而 SAIWP 模型能够有效地找到与郊区有关的特征 *OKH-Suburban*。同时 SAIWP 模型均匀地从 3 类特征中选取智能无线传播模型的输入特征, 而不是全输入或仅选取原始特征, 这表明综合考虑 3 类特征能更有效地提升模型的性能。




图 5 神经网络训练过程

Fig. 5 Training process of neural network

55.3% 的预测值误差在  $-5$  dB 到  $5$  dB 之间, 并且仅有 1.6% 的预测值误差大于 25 dB 或小于  $-25$  dB。这说明 SAIWP 模型在预测时仅以极低的概率做出极端预测, 并且在大多数情况下其预测性能均表现良好。




图6 模型误差分布

Fig. 6 Error distribution

考虑到建模区域内测量点地形的复杂性以及收发两端距离和发射频率的多样性(见图 1(a)),本文在上述训练后的神经网络的基础上,分别针对区域内不同的地形、距离以及频率的泛化误差做了测试,结果如表 7、表 8 以及表 9 所列。表 7 列出了该模型在不同地形下的性能,可以看出,该模型在城市开阔区域(16)、植被区(5)以及高密度城区(11)具备较好的性能,其 MAE(5.516 dB, 4.974 dB 以及 5.482 dB)较小,并且 ME 趋近于 0 dB,具备较低的 STD,满足 ITU 的要求。尽管该模型在内陆湖泊(2)地形上的预测值误差满足需求,但与其他地形相比误差有所增加,并且其 ME(3.064 dB)有了一定的偏差,主要原因是该区域的内陆湖泊数据较少(仅占 0.396%),使得该模型主要拟合于区域内其他地形数据(城市开阔区域占 50.145%,植被区占 7.057%,高密度城区占 9.172%)。

表 7 模型在不同地形的性能

Table 7 Performance on different scenarios

地形(表 1)	MAE	MSE	ME	STD
2	6.143	96.753	3.064	7.646
16	5.516	54.841	0.244	4.855
5	4.974	42.027	0.337	4.069
11	5.482	53.132	0.339	4.714

表 8 模型在不同距离的性能

Table 8 Performance on different distances

距离/m	MAE	MSE	ME	STD
0~500	5.468	53.102	0.245	4.814
500~1000	4.614	32.950	0.335	3.590
1000~3000	5.213	46.998	0.215	4.487
3000~5000	5.527	65.532	0.340	4.888

表 9 模型在不同频率的性能

Table 9 Performance on different frequencies

频率/MHz	MAE	MSE	ME	STD
2585	5.486	55.950	0.253	4.708
2624.6	5.279	48.220	0.245	4.421

表 8 和表 9 分别列出了该模型在不同距离以及不同频率下的性能。可以得知,该模型在不同情况下均具备较好的性能,并且与表 5 中的整体性能偏差不大,满足应用的实际需求。综合表 7—表 9,可以得出结论:SAIWP 模型能够适用于复合场景(多种地形、频带以及距离),而不像传统经验模型以及确定性模型那样只适用于单一固定场景。

## 5.2 超参数影响

正如前文所提,智能无线传播模型的超参数将会影响 SAIWP 模型的预测准确度。本节将对超参数的影响进行分析。

针对智能无线传播模型中损失函数对 SAIWP 模型的影响,本文分别对 MSE 以及 MAE 这两个常用的损失函数进行了研究,其结果如表 10 所列。从表中可以看出,两种损失函数具备相近的性能,其误差以及 STD 均较低,并且 ME 接近于 0 dB,满足应用的要求。但通过实验发现,损失函数 MSE 更适用于无线传播模型的建模。

表 10 模型在不同损失函数下的性能

Table 10 Performance of model on different loss functions

损失函数	MAE	MSE	ME	STD
MSE	5.436	52.493	0.259	4.703
MAE	5.486	54.712	0.291	4.916

表 11 对神经网络隐含层中不同神经元个数的影响进行了描述。从表中可以看出,随着神经元个数从 64 增加至 256,模型的复杂度逐渐增加,神经网络将获得更强的拟合能力,具体表现为误差逐渐减小。但随着神经元由 256 增加至 512,虽然神经网络的拟合能力有所提升,但模型的性能却在下降,主要原因是网络过强的拟合能力使网络过度拟合于训练数据,而丧失了对未曾训练过的测试数据的泛化能力。因此当神经元个数为 256 时,网络具备合适的拟合能力,此时是较为合适的神经网络结构。

表 11 模型在不同神经元个数下的性能

Table 11 Performance of model on different number of neuron

神经元个数	MAE	MSE	ME	STD
64	5.592	54.935	0.319	4.772
128	5.504	53.908	0.254	4.771
256	5.436	52.493	0.259	4.703
512	5.464	53.128	0.263	4.737

表 12 列出了学习速率对 SAIWP 模型的影响。观察表 12 可知,不同学习速率下的 SAIWP 模型性能具有较大差异。当  $\beta=0.1$  或  $\beta=1$  时,SAIWP 模型性能较差(MAE 分别为 5.830 dB 和 7.164 dB),原因是:较大的学习速率导致神经网络无法收敛,从而导致 SAIWP 模型表现不佳。当  $\beta=0.001$  时,SAIWP 模型性能同样较差(MAE 为 5.762 dB),此时的原因为:较小的学习速率导致神经网络的训练过程收敛较慢,神经网络无法在  $E_{epoch}$  次梯度迭代内找到最优参数  $w$ ,或者收敛到次优解无法跳出。因此  $\beta=0.01$  是在本文场景下的一个合适的学习速率。

表 12 模型在不同学习速率下的性能

Table 12 Performance of model on different learning rates

学习速率	MAE	MSE	ME	STD
0.001	5.762	55.509	0.581	4.737
0.01	5.436	52.493	0.259	4.703
0.1	5.830	56.023	0.342	4.750
1	7.164	85.030	0.616	5.805

## 5.3 方法对比

本节将所提 SAIWP 模型与现有的不同模型进行对比。为更公平以及更全面地展示不同算法的性能,除了华为提供的 LTE 网络数据,我们还将不同方法在文献[23]中公开的校园场景数据上进行验证。

图 7 给出了本文 SAIWP 模型与现有的不同无线传播模型在不同数据集上的比较结果,其中神经网络、支持向量机分

别指文献[9]以及文献[7]所提方法,线性回归指将表2中的原始特征按照线性回归进行拟合的方法,经验模型指将表3中的处理特征按照线性回归进行拟合的一种改进型经验模型方法。从图7可以看出,相比其他无线传播模型,本文的SAIWP模型能够在不同数据集上更准确地预测路径损耗,具有更低的MAE。同时,通过经验模型与线性回归的对比,我们观察到,尽管两种方法都通过线性回归进行拟合,但输入处理特征的经验模型获得了更好的性能,此现象能够很好地证明处理特征的有效性以及本文SAIWP模型在扩展特征时采用处理特征的合理性。与此同时,不同模型在校园数据<sup>[23]</sup>上的MAE, MSE, ME以及STD如表13所列。从表中可以看出,所提SAIWP模型在其他性能指标上也表现良好,且优于传统智能无线传播模型以及经验模型等方法。




图7 不同模型在不同数据集上的性能

Fig. 7 Performance of different models on different data sets

表13 不同模型的性能

Table 13 Performance of different models

模型	MAE	MSE	ME	STD
SAIWP	3.812	28.194	0.213	3.253
神经网络	4.353	34.223	0.249	3.767
支持向量机	4.891	40.836	0.307	4.173
经验模型	5.616	50.551	0.532	4.672
线性回归	5.965	55.657	0.613	5.436

图8给出了智能无线传播模型在不同输入特征下不同数据集的预测性能,其中原始特征表示仅输入表2特征的神经网络模型,全部输入是指输入4.1节所提出的全部特征的模式。




图8 不同输入特征的性能

Fig. 8 Performance of different input features

从原始特征以及全部特征的对比可以看出,在智能无线传播模型的输入特征中引入的经验模型和处理特征能够有效地增强输入特征集合与路径损耗的关联性,在预测误差上则表现为全部特征在不同数据集上的MAE分别减小了0.44 dB(LTE数据)与0.23 dB(校园场景数据)。但随着输入特征数量的增多,由于神经网络强大的拟合能力,网络过度拟合于输入的无关特征,从而造成泛化误差的增加。而本文所提的

SAIWP模型能够有效地针对当前建模区域为神经网络选择最优的输入特征子集,从而去掉无关以及冗余的输入特征并且降低了预测值误差。在图8中,与全部输入相比,SAIWP模型在不同数据集上的MAE减少了0.31 dB(LTE数据)与0.27 dB(校园场景数据)。

为说明本文所用模拟退火算法的有效性,本文将SAIWP模型与其他特征筛选方法进行对比,结果如图9所示,其中嵌入式方法是指通过L2系数来降低输入特征权重的方法,贪心算法、遗传算法指通过此类启发式随机搜索方法来筛选特征的封装式方法(与SAIWP模型具有相同的计算量)。观察SAIWP模型与嵌入式方法的对比结果可知,尽管SAIWP模型的计算量更大(封装式方法在特征搜索过程中需要对神经网络进行多次训练,而嵌入式方法仅需要训练一次),但SAIWP模型在不同数据上的预测性能明显优于嵌入式方法。在校园场景数据<sup>[23]</sup>上,以上两种方法的MAE差值为0.13 dB。




图9 不同优化方法的性能

Fig. 9 Performance of different optimization methods

在不同封装式方法的对比中,从SAIWP模型与贪心算法的预测性能中可以看出,SAIWP模型在预测路径损耗时能达到更好的性能。这是因为贪心算法缺少随机性,只能接受性能更优的解,容易陷入局部最优;而模拟退火算法在遇到较差解时,有一定概率去接受,因此能够跳出局部最优解,达到更好的性能。而遗传算法与模拟退火算法相比,遗传算法虽然更侧重于全局搜索能力,但在局部优化能力方面有所欠缺。在本文所用数据集以及神经网络构架下,遗传算法在特征子集的搜索过程中因为没有对局部进行深入搜索,从而导致其所得解的预测误差高于模拟退火算法。


**结束语** 本文提出了SAIWP模型。该模型首先借鉴经验模型在不同场景下对输入特征的处理方式,对输入特征集合进行了扩充。然后针对当前建模区域所采集的训练数据,该模型通过模拟退火算法来自适应地为神经网络在当前建模区域选择最优的输入特征子集。最后,该模型利用优化过程中的最优输入特征子集以及采集的全部数据对神经网络进行训练。仿真结果表明,在多种典型路径损耗预测数据集上,与传统的经验模型以及现有的智能无线传播模型相比,本文提出的SAIWP模型对多种传播场景均具有适用性并且进一步减小了路径损耗预测误差。

本文在智能无线传播模型的研究中对输入特征的扩展方式以及筛选方式做出了创新。在下一步工作中,可针对路径损耗预测问题的独有特性,设计出更高效准确的机器学习模型,从而进一步提升预测性能。

## 参考文献

[1] WANG Y. Impact of Path Loss Exponent on Interference and

- Carrier Sensing Performance Metrics of 802. 11 WLANs[J]. *Computer Science*, 2017, 44(7): 84-88.
- [2] SARKAR T K, JI Z, KIM K, et al. A survey of various propagation models for mobile communication[J]. *IEEE Antennas and Propagation Magazine*, 2003, 45(3): 51-82.
- [3] BRIEN W M, KENNY E M, CULLEN P J, et al. An efficient implementation of a three-dimensional microcell propagation tool for indoor and outdoor urban environments [J]. *IEEE Transactions on Vehicular Technology*, 2000, 49(2): 622-630.
- [4] GORCE J M, JAFFRES-RUNSER K, DE LA ROCHE G, et al. Deterministic approach for fast simulations of indoor radio wave propagation[J]. *IEEE Transactions on Antennas and Propagation*, 2007, 55(3): 938-948.
- [5] HATA M. Empirical formula for propagation loss in land mobile radio services[J]. *IEEE transactions on Vehicular Technology*, 1980, 29(3): 317-325.
- [6] ALDOSSARI S, CHEN K. Predicting the Path Loss of Wireless Channel Models Using Machine Learning Techniques in Mm-Wave Urban Communications [C] // 2019 22nd International Symposium on Wireless Personal Multimedia Communications (WPMC). 2019: 1-6.
- [7] GOUDOS S K, ATHANASIADOU G, TSOULOS G V, et al. Modelling Ray Tracing Propagation Data Using Different Machine Learning Algorithms [C] // 2020 14th European Conference on Antennas and Propagation (EuCAP). 2020: 1-4.
- [8] WEN J, ZHANG Y, YANG G, et al. Path Loss Prediction Based on Machine Learning Methods for Aircraft Cabin Environments [J]. *IEEE Access*, 2019, 7: 159251-159261.
- [9] POPOOLA S I. Determination of neural network parameters for path loss prediction in very high frequency wireless channel[J]. *IEEE Access*, 2019, 7: 150462-150483.
- [10] SOTIROUDIS S P, GOUDOS S K, GOTSIS K A, et al. Application of a composite differential evolution algorithm in optimal neural network design for propagation path-loss prediction in mobile communication systems[J]. *IEEE Antennas and Wireless Propagation Letters*, 2013, 12: 364-367.
- [11] HU W L. Wireless propagation model calibration and coverage area prediction for LTE networks[D]. Wuhan: Huazhong University of Science and Technology, 2018.
- [12] POPOOLA S, FARUK N, OLOYEDE A, et al. Characterization of Path Loss in the VHF Band using Neural Network Modeling Technique[C]//2019 19th International Conference on Computational Science and Its Applications (ICCSA). 2019: 166-171.
- [13] WANG Y, HUANG C L Z, LIANG M Y, et al. A New Method for Radio Wave Propagation Prediction Based on BP-Neural Network and Path Loss Model [C]//2020 12th International Conference on Knowledge and Smart Technology (KST). 2020: 41-46.
- [14] FARUK N. Path Loss Predictions in the VHF and UHF Bands Within Urban Environments: Experimental Investigation of Empirical, Heuristics and Geospatial Models [J]. *IEEE Access*, 2019, 7: 77293-77307.
- [15] AYADI M, ZINEB A B, TABBANE S, et al. A UHF path loss model using learning machine for heterogeneous networks[J]. *IEEE Transactions on Antennas and Propagation*, 2017, 65(7): 3675-3683.
- [16] OROZA C A, ZHANG Z, WATTEYNE T, et al. A machine-learning-based connectivity model for complex terrain large-scale low-power wireless deployments[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2017, 3(4): 576-584.
- [17] CHEN B, HONG J R, WANG Y D, et al. Optimal feature subset selection problem[J]. *Journal of Computer Science*, 1997(2): 133-138.
- [18] GUYON I, ELISSEEF F, ANDR É, et al. An Introduction to Variable and Feature Selection[J]. *Journal of Machine Learning Research*, 2003, 3(6): 1157-1182.
- [19] ZHAO Y, LIU W Y. Feature selection method based on genetic algorithm[J]. *Computer Engineering and Applications*, 2004, 40(15): 52-54.
- [20] ZHANG Y B, YOU L J, CHEN J X. Feature selection of multi-mark data based on simulated annealing[J]. *Computer Engineering and Design*, 2011(7): 286-292.
- [21] ZHANG W H, LIU S H, HOU H F. A tabu search algorithm for feature selection[J]. *Computer Applications and Software*, 2010(5): 131-133.
- [22] LI Z Q, DU J Q, NIE B, et al. A review of feature selection methods [J]. *Computer Engineering and Applications*, 2019, 55(24): 10-19.
- [23] POPOOLA S I, ATAYERO A A, ARAUSI O D, et al. Path loss dataset for modeling radio wave propagation in smart campus environment[J]. *Data in Brief*, 2018, 17: 1062.



**GAO Shi-shun**, born in 1996, postgraduate. His main research interests include cognitive radio networks and machine learning.



**ZHAO Hai-tao**, born in 1981, Ph.D, professor, is a senior member of IEEE. His main research interests include cognitive radio networks and self-organized networks.