

# 改进 GA-BP 神经网络的无线信道预测方法

王智宁<sup>1</sup>, 江虹<sup>1</sup>, 彭潇祺<sup>2</sup>

(1. 西南科技大学信息工程学院, 绵阳 621000; 2. 南洋理工大学电气与电子工程学院, 新加坡 639798)

**摘要:** 无线信道建模与仿真中, 实现一种高效率、高准确性的无线信道预测方法是具有非常重要意义的。针对该需求, 提出一种基于多种群遗传算法 (Multi-population genetic algorithm, MPGA)-反向传播 (Back propagation, BP) 神经网络的无线信道预测方法。该方法通过改进遗传算法, 优化 BP 神经网络中神经元的权值和阈值, 以此改善 BP 神经网络预测精度差的问题, 从而极大提高了 BP 神经网络的预测性能。将射线跟踪算法的理论值和 BP 神经网络结合, 实现更高效的无线信道预测方法。通过对比遗传算法 (Genetic algorithm, GA)-BP 神经网络模型和 MPGA-BP 神经网络模型的预测误差, 发现 MPGA-BP 神经网络模型的预测结果优于 GA-BP 神经网络模型, 证明了所提出无线信道预测方法具有良好的精确度, 可以更高效地进行无线信道预测。

**关键词:** 射线跟踪; 遗传算法; 反向传播神经网络; 无线信道预测

**中图分类号:** TN911      **文献标志码:** A

## Wireless Channel Prediction Method Based on Improved GA-BP Neural Network

WANG Zhining<sup>1</sup>, JIANG Hong<sup>1</sup>, PENG Xiaoqi<sup>2</sup>

(1. College of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China; 2. School of Electronics and Information Engineering, Nanyang Technological University, Singapore 639798, Singapore)

**Abstract:** In wireless channel modeling and simulation, it is of great significance to realize a high-efficiency and high-accuracy wireless channel prediction method. Aiming at this request, a wireless channel prediction method based on multi-population genetic algorithm-back propagation (MPGA-BP) neural network is proposed. This method optimizes the structure parameters of BP neural network by improving the genetic algorithm, thereby improving the problem of poor prediction accuracy of the BP neural network and greatly improving the prediction performance of the BP neural network. In this paper, the theoretical value of ray tracing algorithm is combined with BP neural network to realize a more efficient wireless channel prediction method. By comparing the prediction errors of the genetic algorithm (GA)-BP neural network model and the MPGA-BP neural network model, it is found that the prediction results of the MPGA-BP neural network model are better than the GA-BP neural network model, which proves that the proposed wireless channel prediction method has good accuracy. Therefore, the wireless channel prediction can be performed more efficiently.

**Key words:** ray tracing (RT); genetic algorithm (GA); back propagation neural network (BPNN); wireless channel prediction

## 引言

无线信道预测对无线通信的规划、运行与优化具有重要作用。在电磁波和几何光学等理论的支撑下,射线跟踪(Ray tracing, RT)算法是一种充分考虑电磁波和周围环境相互作用的确定性预测模型,是电磁波传播预测的重要方法。但为了保证RT算法的精确性,需要保证必要的射线发射数量、最大反射次数与最大绕射次数,这带来了巨大的计算量,虽然射线跟踪算法的加速方法层出不穷<sup>[1-2]</sup>,但对算法效率的提升仍为有限。

神经网络已成为无线通信领域的研究热点<sup>[3]</sup>。文献[4]提出一种基于反向传播神经网络(Back propagation neural network, BPNN)的三维无线信道特征预测模型。通过对比传统融合信道模型与BP神经网络模型,表明反向传播(Back propagation, BP)能快速预测无线信道特性。但其没有涉及BP结构,该网络在训练优化时易陷入局部最优解的情况。文献[5]基于神经网络,利用基站特征和用户特征的相关性,对基站特征进行训练,以预测用户侧的特征参数。文献[6]提出一种基于机器学习算法和卷积神经网络的信道特性预测方法,当获取收发节点的三维位置信息时,可对室内场景中的子信道进行统计特性的预测,但未考虑预测比室内空间更小的空间环境。文献[7]提出一种模块化神经网络的场强预测模型,基于射线跟踪软件计算的理论值训练神经网络,通过神经网络模块化以及预测数据模块化的方式进行无线信道参数的预测。文献[8]改进了射线跟踪算法,对比了仿真所得路径损耗和BPNN拟合所得路径损耗,验证了BP神经网络算法能够很好地对无线信道参数进行预测。文献[9]基于少量实测数据,构建了基于人工神经网络的路径损耗预测模型,与传统Log-distance模型进行对比,证明了其模型的优越性。文献[10]通过多层感知器神经网络估计信道中的莱斯 $K$ 因子,实验结果表明该方法对于莱斯 $K$ 因子具有很高的精度。文献[11]采用线性回归,支持向量机和深度神经网络来预测眼图指标,数值结果表明向量机和深度神经网络回归都能够捕获收发射机模型在高速信道中所产生的非线性特性。

由上述可知,相较于其他神经网络,BP神经网络具有更好的非线性映射能力、更为强大的自适应和自学习能力,作为目前较为流行的一种算法数学模型,已在多种领域被证实上述能力,非常适用于求解内部机制复杂的问题。传统射线跟踪算法进行场景精确建模具有较大计算复杂度,而将BP神经网络模型与射线跟踪算法相结合进行无线信道预测,既能够将两者的优点相综合,又能够有效地克服现存射线跟踪算法的一些缺点。

BP神经网络本质上仍然是基于梯度下降思想的搜索算法,其本身存在不足之处,诸如易陷入局部极值点、全局搜索能力差等缺点。许多学者做了大量研究以克服这些缺点,有代表性的是蚁群算法<sup>[12]</sup>、粒子群算法<sup>[13]</sup>和传统遗传算法<sup>[14]</sup>等。但上述算法均存在不同缺点,其中蚁群算法寻优盲目,收敛较慢,易陷入局部最优解;粒子群算法后期较难保持种群多样性,同样较易陷入局部最优解;传统遗传算法易早熟收敛,在后期收敛较慢。

鉴于此,基于RT进行信道仿真生成数据集,将信道参数预测模型建模成一个基于BP网络的信道参数预测模型,通过改进遗传算法(Genetic algorithm, GA)优化BP中的权值和阈值来提升BP的全局搜索能力和收敛效率。该模型的优点在于:(1)基于电磁波理论的RT算法进行信道建模仿真所产生的数据精确性高;(2)结合神经网络进行无线信道参数预测,能极大提高信道预测的效率;(3)改进GA对BP网络进行优化,能有效改进局部最优以及种群早熟等缺陷。

## 1 射线跟踪算法

无论4G还是5G,甚至于未来的6G,通过将通信理论与计算机相结合的方法已是解决无线通信问题的一种有用且高效的方法<sup>[15-16]</sup>。RT算法通过模拟射线的传播方式,预测电磁波在传播中的有效路

径,结合不同的传播机制,计算每条有效路径的特征参数,对接收节点处所有有效传播路径进行矢量和处理,能够有效进行无线信道建模与仿真。

首先,进行高精度的RT仿真实验,得到某场景无线信道特征参数。论文使用文献[17]中的真实场景,通过对比文献数据,验证了RT算法的精确性和正确性。

其次,通过建模仿真数据进行数据预处理。通过RT算法获取收发节点间的有效射线,包括传播路径长度、传播时间等参数。根据电磁波理论计算出各有效射线到达接收点的场强,并通过对接收点处的信号值进行矢量叠加的计算。得出接收点总场强 $E_{\text{total}}$ 为

$$E_{\text{total}} = \sum_{i=1}^l E_i \quad (1)$$

式中: $l$ 为有效射线的总数, $E_i$ 为第 $i$ 条射线末场的矢量场强,由式(2)计算<sup>[18]</sup>。

$$E_i = E^{\text{inc}} \prod_{h=1}^{R_n} R_h \prod_{f=1}^{D_n} D_f \prod_{t=1}^{T_n} T_t \times \prod_{s=1}^{R_n+D_n+T_n} A_s \prod_{q=1}^{R_n+D_n+T_n} \exp(-jkrq) \quad (2)$$

式中: $E^{\text{inc}}$ 为射线发生下一次传播机制前的矢量辐射场; $R_n$ 、 $D_n$ 、 $T_n$ 分别为反射、绕射和透射的总次数; $R_h$ 、 $D_f$ 、 $T_t$ 分别为并矢反射、绕射、透射系数; $A_s$ 为产生各种传播机制后的扩散因子; $r_q$ 为所跟踪射线发生一次传播机制的距离, $q$ 为传播机制节点数。

接收点处的接收功率 $P_r$ 由接收点的总场强计算,可由式(3)计算<sup>[19]</sup>。

$$P_r = 10 \lg \left( P_t G_t G_r \left( \frac{\lambda}{4\pi} \right)^2 \left| \frac{E_{\text{total}}}{E_0} \right|^2 \right) + 30 \quad (3)$$

式中: $P_t$ 和 $E_0$ 分别为发射功率和电场强度, $G_r$ 和 $G_t$ 分别为收发天线增益, $\lambda$ 为波长。

最后,为了评估所提出的基于多种群遗传算法的BP神经网络性能。论文在目标场景中固定发射点,随机布置接收点,进行该目标场景下的无线信道仿真实验,存储大量标签样本用于BP训练。

## 2 改进GA-BP神经网络的无线信道预测方法

在某场景中,对于一个固定的收发点位置,功率随着收发点间的距离和收发点间障碍物的数量增大而减小,可以看作收发点三维坐标点间的非线性函数。基于此,提出一种基于BP的多输入单输出非线性函数建模方法。BP网络包含非线性激活函数,它将输入信号映射到不同的非线性域。这些非线性域输出与适当的权值相乘,并以一个常数值偏置,使这些输出的总和最终等于所需的输出。

### 2.1 神经网络算法

BP网络由输入层、隐藏层和输出层3部分构成,每层由相应神经元构成,总体采用单向连接方式,层与层之间实行全连接,并通过梯度下降算法,寻求误差小、预测精准的神经网络<sup>[20]</sup>。BP网络通过适应度值的调整不断更新网络中的权值和阈值,逼近期望输出值,生成输入和输出的非线性关系函数。然而,BP网络中隐藏层到输出层的连接权值和阈值采用随机取值方法,存在收敛慢、易陷入局部极小值的问题。

### 2.2 遗传操作

GA可以在不需要误差函数梯度信息的情形下学习近似最优解,从而具备优秀的全局搜索能力,尤其适用于求解复杂的非线性问题求解<sup>[21]</sup>。GA通过对种群进行遗传、变异、选择以及交叉等操作,筛选出最优个体。

本文将GA中对种群的操作整合成遗传操作。即首先将待优化值转化成二进制编码,以二进制编码为个体构建初始种群,接着依次进行各遗传操作,然后将二进制个体解码成实数个体,转换成可用于

BP训练的实数串,最后将完成操作的个体代入BP中迭代计算适应度,寻找适应度最小的个体。本文中的适应度值 $L$ 由复数场强模的预测值和期望值计算,计算方式如下

$$L = \frac{\left( \sum_{i=1}^m (y_i - p_i)^2 \right)}{m} \quad (4)$$

式中: $m$ 为BP输出节点总数, $y_i$ 和 $p_i$ 分别为BP网络节点的期望值和预测值。

## 2.3 基于改进GA的BP神经网络

### 2.3.1 优化GA-BP算法构建思想

传统GA能在一定程度上提升神经网络算法的全局搜索能力和收敛速度。然而,传统遗传算法初始种群的产生和遗传操作的执行都具有随机性,导致该算法仍存在收敛慢和易陷入局部最优解的缺点。针对该问题,本文构建了多种群遗传算法。

多种群遗传算法(Multi-population genetic algorithm, MPGA)的基本思想是:采用多种群并行计算方式,进行多种群同步遗传操作,择取各种群中的最优个体,组成最优种群,再次进行遗传操作,进化出最优个体。由于多个种群间保持相互独立,利用各子种群进行多代遗传操作后的最优个体,重组为最优种群,进行最优基因之间的信息交换,即增加了基因模式数的同时,又保持了最优个体进化的稳定性,还可以通过最优种群进化出更优个体。该方法能增强GA的全局搜索能力,加快算法的收敛效率。

MPGA具体步骤如下:首先,初始化 $N_{pop}$ 个权值和阈值种群,每个种群中所具有的个体数都相等,并且将个体中的所有权值和阈值组成二进制数串。然后,对各子种群进行遗传操作,进化出子种群中的最优个体。接着,选择各个子种群中的最优个体,组合成最优种群。最后,对最优种群进行遗传操作,进化出最优个体。

### 2.3.2 数据预处理

射线跟踪算法基于几何理论和一致性绕射理论,能够识别收发节点间的所有有效射线,并计算出无线信道特征参数,如接收场强、接收功率和路径损耗等。

本文通过将收发节点三维坐标值进行归一化处理,组成六元组,作为输入

$$X = (t_x, t_y, t_z, r_x, r_y, r_z) \quad (5)$$

根据射线跟踪算法计算的无线信道特征参数构成神经网络输出

$$P = p_o \quad (6)$$

式中输出参数可分别为接收场强、接收功率和路径损耗等多种无线信道特征参数。

基于射线跟踪算法在目标场景中进行多次仿真,搜集到能够用于训练的数据集。对数据集进行随机选取,按照7:3的比例分为训练集和测试集,用于神经网络的训练和测试。

### 2.3.3 构建MPGA-BP神经网络

基于改进GA优化BPNN算法的流程如图1所示。图1中共有9个步骤,从确定网络拓扑结构到使用BP进行预测,将MPGA与BP进行结合形成新的BP网络模型。整个模型确定所需神经网络结构后,采用MPGA优化BP神经网络,确定初始权值和阈值,输入训练数据集,训练网络,直至当前BP满足精度要求为止。步骤如下:

(1)确定网络拓扑结构。本文神经网络中的输入层采用6个神经元,隐藏层由两层全连接层构成,各11个神经元,用 $h$ 表示;输出层由1个神经元组成,用 $m$ 表示。

(2)初始化权值和阈值。将BP中的权值和阈值赋值为随机产生的8位二进制数串。

(3)获取最优权值和阈值。通过MPGA优化初始权值和阈值,获取最优值。




图1 基于改进GA优化BPNN程序流程图

Fig.1 Program flow chart of BPNN optimization based on improved GA

(4)计算隐藏层输出。阈值为  $b_h$ ,激励函数为  $f$ ,输入两层之间的权值为  $\omega_{ij}$ ,且采用 ReLu 函数,输出值为

$$H_{aj} = f\left(\sum_{i=1}^n \omega_{ij}x_i - b_{hj}\right) \quad 1 \leq j \leq h, 1 \leq i \leq n \quad (7)$$

(5)计算输出层输出。阈值为  $b_o$ ,两层之间的权值为  $\omega_{jk}$ ,输出值为

$$P_k = \sum_{j=1}^m H_{aj}\omega_{jk} - b_{ok} \quad 1 \leq k \leq m \quad (8)$$

(6)计算误差。误差  $e$  为预测值和期望值之差,计算方式如下

$$e_k = |Y_k - P_k| \quad (9)$$

(7)更新权值和阈值。根据上述步骤计算出误差  $e$ ,更新  $\omega_{ij}$  和  $\omega_{jk}$ ,计算方式如下

$$\omega_{ij} = \omega_{ij} + \eta H_{aj}(1 - H_{aj})x_i \sum_{k=1}^m \omega_{jk}e_k \quad (10)$$

$$\omega_{jk} = \omega_{jk} + \eta H_{aj}e_k \quad (11)$$

式中  $\eta$  为学习速率,本文中设置为 0.1,阈值修正计算如下

$$b_h = b_h + \eta H_{aj}(1 - H_{aj}) \sum_{k=1}^m \omega_{jk}e_k \quad (12)$$

$$b_o = b_o + e_k \quad (13)$$

(8)对网络误差进行判断。若误差满足要求,则达到结束条件。否则,回到步骤6继续学习。

(9)测试数据,进行预测。神经网络达到预期设定后,对当前神经网络模型进行保存,然后进行预测。

### 2.3.4 多种群遗传算法收敛性分析

为便于 MPGA 算法收敛性分析,本节使用符号定义如下。

符号 1:种群大小和空间分别为  $P_{size}$  和  $S^N$ ,个体染色体长度为  $l$ ,种群迭代次数为  $n$ 。

符号 2:使用大写表示当前种群,如  $X$ 。

符号 3:使用小写和下标表示当前种群个体,如  $x_i$ 。

符号 4:使用  $f(\cdot)$  表示个体的适应度值,如  $f(x_i)$  表示种群  $X$  中个体  $i$  的适应度值。

各算子符号的定义如下。

(1)选择算子  $T_s$

$$P\{T_s(X) = x_i\} = \frac{f(x_i)}{\sum_{i=1}^{P_{size}} f(x_i)} \quad (14)$$

(2)交叉算子  $T_c$

$$P\{T_c(X(n))=Y(n)\}=\frac{P_c}{l}\times P\{T_c(X(n-1))=Y(n-1)\} \quad (15)$$

式中: $P_c$ 为交叉概率, $l$ 为杂交点可选择的数量。

(3)变异算子  $T_m$

定义式与  $T_c$  相似。

(4)满意值算子  $T_g$

$$P\{T_g(X_0=Y_0)\}=\begin{cases} 1 & f(Y_0)\geq f(X_0) \\ 0 & f(Y_0)<f(X_0) \end{cases} \quad (16)$$

MPGA算法的个体更新过程可表示为

$$P\{T(X(n))k=x_k(n+1)\}=\sum_{z_k\in S}\sum_{Z\in S^N}\{P[T_c(X(n))k=x(n)]\times P[T_s(Z(n))=z_k(n)]\}\times P[T_m(z_k(n))=x'k(n)] \quad (17)$$

MPGA算法迭代过程可表示为

$$P(n)=\prod_{k=1}^{P_{sim}}P\{T(X(n))k=x'k(n+1)\}\times P\{T_g(X_0(n))\} \quad (18)$$

由定义可知, $P(T_c)$ 、 $P(T_s)$ 和 $P(T_m)$ 均大于0,所以有

$$P\{T(X(n))=X(n+1)\} \begin{cases} >0 & P\{T_g\}>0 \\ =0 & \text{其他} \end{cases} \quad (19)$$

由算子  $T_g$  定义可知,  $\lim_{n\rightarrow\infty} P(n)=0$ , 证得该算法依概率收敛。

## 2.4 算法时间复杂度分析

### 2.4.1 传统GA与改进GA的时间复杂度分析

传统GA的时间复杂度主要来源于对适应度函数的多次调用<sup>[22]</sup>。通常可以基于遗传算法中间点的染色体编码长度、种群规模和迭代次数来对适应度函数的调用次数进行计算<sup>[23]</sup>。

结合文献[22-24],通过分析本文中适应度函数的设计,假设交叉概率为1,可以得出在优化BP神经网络结构问题中,传统GA的时间复杂度为

$$T_{GA}=T_{GA1}+T_{GA2} \quad (20)$$

$$T_{GA2}=O(N_{fit}\cdot T_{fit}) \quad (21)$$

$$N=i_p\cdot p_s\cdot g_n \quad (22)$$

式中: $T_{GA1}$ 为初始化种群个体染色体编码的耗时; $T_{GA2}$ 为针对种群进行遗传操作的耗时; $T_{fit}$ 为适应度函数的耗时; $N_{fit}$ 为适应度函数的调用次数; $i_p$ 为染色体编码长度中间点数目; $p_s$ 为种群规模; $g_n$ 为迭代次数。相比于对种群进行遗传操作的耗时,初始化种群个体染色体编码的耗时可以忽略不计。因此,传统GA的时间复杂度为

$$T_{GA}=O(N_{fit}\cdot T_{fit}) \quad (23)$$

通过分析改进GA,得到采用改进GA进行BP神经网络优化的计算时长  $T_{NGA}$  由以下几个部分组成:(1)时间  $T_{NGA1}$  为初始化多种群个体染色体编码;(2)时间  $T_{NGA2}$  为对多种群个体并行进行遗传操作的耗时;(3)时间  $T_{NGA3}$  为组合最优种群的耗时;(4)时间  $T_{NGA4}$  为对最优种群进行遗传操作的耗时。则可知

$$T_{\text{NGA}} = T_{\text{NGA1}} + T_{\text{NGA2}} + T_{\text{NGA3}} + T_{\text{NGA4}} \quad (24)$$

相较于对多种群和最优种群进行遗传操作的耗时,初始化多种群染色体编码和组合最优种群的耗时可以忽略不计。

由于对多种群进行遗传操作是并行进行,所以时间  $T_{\text{NGA2}}$  和时间  $T_{\text{NGA4}}$  均可与传统 GA 的时间复杂度相等。所以,改进 GA 的时间复杂度为

$$T_{\text{NGA}} = O(2N_{\text{fit}} \cdot T_{\text{fit}}) \quad (25)$$

据式(23,25)可得,改进 GA 的时间复杂度与传统 GA 的时间复杂度相等。因此,改进 GA 算法并未增加算法的时间复杂度。

#### 2.4.2 传统 RT 与改进 BPNN 的时间复杂度分析

通过分析传统射线跟踪算法,单根射线完成传播的耗时  $T_{\text{RT}}$  由以下几个部分构成:(1)时间  $T_1$  为射线跟踪过程中发生一次传播机制的耗时;(2)时间  $T_2$  为判断当前射线是否被接收点所接收;(3)时间  $T_3$  为计算所有有效射线特征参数的耗时。则可知

$$T_{\text{RT}} = T_1 + T_2 + T_3 \quad (26)$$

相较于射线数量,仅需单次计算的  $T_3$  可以忽略不计。

假设场景中障碍物表面总数为  $F_{\text{all}}$ ;单次线面求交计算耗时为  $k_1$ ;单条射线从开始到结束发生传播次数平均为  $T_{\text{avr}}$ ,则时间  $T_1$  为

$$T_1 = F_{\text{all}} \times T_{\text{avr}} \times k_1 \quad (27)$$

$T_2$  为判断所跟踪射线是否被接收。假设相关耗时为  $k_2$ ,则时间  $T_2$  为

$$T_2 = (T_{\text{avr}} + 1) \times k_2 \quad (28)$$

相对于  $T_2$ ,  $T_1$  的耗时更为巨大,因为求交运算、传播机制判断等相关计算的计算过程复杂,而判断是否被接收点所接收的计算过程相对简单,因此  $k_1$  远大于  $k_2$ 。其次,因为  $T_1$  同时与整体环境中的物体表面总数为  $F_{\text{all}}$  和传播机制的次数  $T_{\text{avr}}$  都有关,且物体表面总数  $F_{\text{all}}$  与  $T_2$  无关,并且其值远大于  $T_{\text{avr}}$ 。因此可以忽略  $T_2$ ,则算法最终时间复杂度  $T_{\text{RT}}$  可表示为

$$T_{\text{RT}} = O(T_{\text{avr}} \times F_{\text{all}}) \quad (29)$$

由于 BP 神经网络通过适应度值逆向调整各神经元的权值和阈值,且所构建神经网络为两层神经网络,其时间复杂度为

$$T_{\text{BP}} = O(S^2) \quad (30)$$

式中  $S$  为单层网络中的网络节点数。

由于此两层神经网络隐含层节点数  $S$  通过误差和节点数的测试后经人为设定,与传播机制次数  $T_{\text{avr}}$  通过衰减计算后的最大值近似,物体表面总数  $F_{\text{all}}$  远远大于节点数  $S$  和传播机制次数  $T_{\text{avr}}$ ,且随着场景复杂度的提升,呈现几何级增长。因此  $T_{\text{RT}} \gg T_{\text{BP}}$ 。由此可得,BP 神经网络的预测效率是远优于传统射线跟踪算法的预测效率。

#### 2.4.3 传统 RT 与改进 GA 优化 BPNN 的时间复杂度分析

通过分析改进 GA 优化 BPNN 算法,得到整个神经网络训练的时间复杂度  $T_{\text{GABPNN}}$  为

$$T_{\text{GABPNN}} = T_{\text{NGA}} + T_{\text{TBPNN}} \quad (31)$$

式中  $T_{\text{TBPNN}}$  为训练神经网络的时间复杂度。

根据 2.4.1 和 2.4.2 节,可得改进 GA 优化 BPNN 的时间复杂度为

$$T_{\text{NGA}} = O(i_p \cdot p_s \cdot g_n \cdot S^2) \quad (32)$$

根据 2.4.2 节,可得训练神经网络的时间复杂度为

$$T_{\text{TBPNN}} = O(\partial \cdot S^2) \quad (33)$$

式中 $\partial$ 为训练集的数据数量。

相对于训练集的大小 $\partial$ ,适应度函数的调动次数 $N_{\text{fit}}$ 可以忽略不计,因此改进GA优化BPNN进而进行BPNN训练的时间复杂度为

$$T_{\text{GABPNN}} = O(\partial \cdot S^2) \quad (34)$$

由于神经网络训练集的大小 $\partial$ 通常在万级数量以上,因此神经网络训练消耗的时间常是大于单次传统RT算法的。然而,在固定场景中,采用传统RT进行多次无线信道预测的耗时将远大于训练神经网络的耗时。即使训练神经网络有较大的耗时,但换来了在应用该网络进行无线信道预测时更高的效率。

### 3 仿真结果对比分析

#### 3.1 目标场景

为了验证本文所提出方法的有效性,论文构建场景的三维图形进行建模。该场景为立方体的密闭小空间,上下底半径均为2 m,高为6.5 m,内部分为3层:上层空间中有3个立方体形障碍物模型;中层空间共有6个立方体形障碍物模型;下层空间中有1个圆柱形障碍物模型,整个场景如图2所示。在无线信道仿真中,场景中障碍物材料介电常数为4.5,导电率为0.8 S/m。导出场景STEP文件,将目标场景的形状、尺寸和材质等信息导入仿真平台进行数据解析以及三维建模仿真。

#### 3.2 验证BP神经网络算法精确性

首先与RT算法结果进行对比,验证两种BP神经网络模型的精准性。神经网络结构如2.3.2节所述,MPGA设置的种群数为20,单个种群个体数为20,模型训练结束条件为迭代次数达到10 000次。

本次验证的环境模型如3.1节所描述,设定发射频率为1 GHz,收发节点均为全向天线,射线发射数量为4万条。发射点坐标固定为(234,144,352),单位均为cm。仿真使用Intel i7处理器,16 GB内存,Qt仿真平台。

图3是GA-BP神经网络的预测值和期望输出对比图,图4是MPGA-BP神经网络的预测值和期望输出对比图。从图3可以看出,各测试样点都具有良好的精度,但极个别处的测试样点误差偏大。而图4中MPGA-BP神经网络模型则具有更高的精度,尤其在一些GA-BP神经网络效果不好的点。从以上两个对比图中可以看出,MPGA-BP神经网络模型具有更高的精度,证明了两种BP神经网络模型无线信道预测的精确性。这是因为两种网络的数据集均来自射线跟踪算




图2 导入系统后的环境模型

Fig.2 Environment model after importing the system




图3 GA-BP神经网络输出与期望输出对比图

Fig.3 Comparison between GA-BP neural network output and expected output




图4 MPGA-BP神经网络输出与期望输出对比图

Fig.4 Comparison between MPGA-BP neural network output and expected output



法仿真数据,而射线跟踪算法是一种充分考虑电磁波和周围环境相互作用的确定性模型,通过大量的射线发射数量和必要的射线传播次数,保证了极高的预测精度。因此两种网络均具有较好的预测精确性。

### 3.3 验证改进算法有效性

为验证本文所提出的模型的有效性,本节从两方面进行分析。(1)分别将GA和MPGA优化BP网络前后的结构参数进行对比,验证GA和MPGA优化BP网络的有效性。(2)将GA-BP和MPGA-BP网络模型应用于无线信道多种特征参数的预测,例如接收功率、路径损耗和时延扩展等参数,通过平均绝对误差、标准差和均方根误差等参数对混合模型的预测能力进行比较,验证混合模型进行无线信道预测的有效性。平均绝对误差的定义为

$$\begin{cases} e_i = |RSS_d - RSS_p| \\ \bar{e} = \frac{1}{S_n} \sum_{i=1}^{S_n} e_i \end{cases} \quad (35)$$

式中  $RSS_d$  和  $RSS_p$  分别表示期望值和预测值。 $S_n$  为所预测的样本总数。标准差为

$$\sigma = \sqrt{\frac{\sum_{i=1}^{S_n} (e_i - \bar{e})^2}{S_n - 1}} \quad (36)$$

而均方根误差表示为

$$RMSE = \sqrt{\frac{\sum_{i=1}^{S_n} (RSS_{d_i} - RSS_{p_i})^2}{S_n}} \quad (37)$$

两种网络都具有两层隐藏层的网络结构,隐藏层神经元个数均为11个,种群交叉概率均为0.7,种群变异概率均为0.05,种群迭代次数均为20。传统遗传算法模型种群个体数为400,多种群遗传算法模型种群个体数为20,种群数量为20。分别预测接收功率、路径损耗和时延扩展。通过将两种网络预测结果的平均绝对误差、标准差和均方根误差进行对比,比较两种网络的预测精确度。

图5,6分别给出了GA和MPGA优化BP网络的结构参数前后对比图。从图5,6可以看出,在经过GA和MPGA两种算法优化后,BP网络中的结构参数均有不同程度的变化。展示了GA和MPGA均具有对BP网络中的结构参数进行优化的能力。图5中部分结构参数并未发生改变,图5中参数的变化程度小于图6中参数的变化程度。这是因为MPGA具有更强的基因交换能力,增强的基因交换能力,能够有效改善种群早熟等缺陷。




图5 GA优化BP网络前后的结构参数对比图

Fig.5 Comparison of structure parameters before and after GA optimization of BP network




图 6 MPGA 优化 BP 网络前后的结构参数对比图

Fig.6 Comparison of structure parameters before and after optimizing BP network by MPGA

表 1~3 分别给出了两种模型对于接收功率、路径损失和时延扩展多次实验下的平均预测误差对比。从表 1~3 中可以看出,无论是接收功率、路径损失还是时延扩展,本文所提出的 MPGA-BP 神经网络模型比 GA-BP 神经网络模型都具有更高的预测精度,且具有更小的标准差。这是因为 MPGA 相对于 GA 拥有更多的基因和基因交流次数,给予了 MPGA 更强基因交换能力,而具有更强基因交换能力的 MPGA 的优化能力则更强,进一步提升了模型的预测精确度。就目前所训练的 3 种无线信道特征参数,本文所提出的 MPGA-BPNN 相对于 GA-BPNN 都具有更高的预测精度。

#### 4 结束语

针对传统射线跟踪算法仿真效率低、GA-BP 网络预测精度差的问题,本文改进传统遗传算法,提出了一种基于射线跟踪算法结合 BP 神经网络的无线信道预测方法。改进遗传算法的全局搜索能力使得神经网络连接权值和阈值得到了更精确的调整,得到了最优的 BP 网络算法,MPGA-BP 网络能够高精度对无线信道进行预测。通过比较

可知,所提出的 MPGA-BP 网络相对于 GA-BP 网络具有一定的精确度提升,说明了本文模型的有效性。

然而,实验采用训练集和测试集均为仿真数据,缺少实际信道数据,虽然射线跟踪算法已经是很可靠的无线信道预测模型,但仍与实际信道的测量数据存在差别。另外,由于数据集来源于固定场景的无线信道仿真试验,造成该神经网络只能反映目标场景的无线信道特性,更换场景则需重新进行网络训练,普适性较差。因此,下一步的研究方向主要是进行实际环境的信道分析,并采用多场景的无线信道数据进行神经网络训练。

表 1 两种模型接收功率预测误差比较

Table 1 Comparison of received power prediction errors between two models dBm

网络类型	GA-BPNN	MPGA-BPNN
平均绝对误差	6.311 55	5.534 42
标准差	9.299 03	6.293 45
均方根误差	11.238 67	8.380 77

表 2 两种模型路径损失预测误差比较

Table 2 Comparison of path loss prediction errors between two models dB

网络类型	GA-BPNN	MPGA-BPNN
平均绝对误差	6.207 22	5.610 78
标准差	8.850 85	6.959 08
均方根误差	10.810 51	8.939 22

表 3 两种模型时延扩展预测误差比较

Table 3 Delay spread prediction error comparison of two models s

网络类型	GA-BPNN	MPGA-BPNN
平均绝对误差	1.05E-07	9.57E-08
标准差	1.01E-07	9.82E-08
均方根误差	1.46E-07	1.37E-07

## 参考文献:


- [1] DONG C L, GUO L X, MENG X. An accelerated algorithm based on GO-PO/PTD and CWMFSM for EM scattering from the ship over a sea surface and SAR image formation[J]. *IEEE Transactions on Antennas and Propagation*, 2020, 68(5): 3934-3944.
- [2] 黄一航, 江虹, 韩宾. 基于室内动静结合分割的射线跟踪加速方法[J]. *计算机应用*, 2020, 40(10): 7.  
HUANG Yihang, JIANG Hong, HAN Bin. Acceleration method of ray tracing based on indoor dynamic static segmentation[J]. *Journal of Computer Applications*, 2020, 40(10): 7.
- [3] YANG Y, LI Y, LI K, et al. Deep-learning enabled coverage and capacity optimization for massive MIMO systems[J]. *IEEE Access*, 2018, 6(1): 23361-23371.
- [4] 朱军, 蒋一鸣, 李凯, 等. 基于神经网络的3维无线信道特征预测及评估[J]. *安徽大学学报(自然科学版)*, 2020, 44(6): 36-42.  
ZHU Jun, JIANG Yiming, LI Kai, et al. Prediction and evaluation of three-dimensional wireless channel features based on neural network[J]. *Journal of Anhui University (Natural Science Edition)*, 2020, 44(6): 36-42.
- [5] NAVABI S, WANG C, BURSALIOGLU O Y, et al. Predicting wireless channel features using neural networks[C]// *Proceedings of 2018 IEEE International Conference on Communications (ICC)*. [S.l.]: IEEE, 2018: 1-6.
- [6] BAI L, WANG C X, HUANG J, et al. Predicting wireless mmwave massive MIMO channel characteristics using machine learning algorithms[J]. *Wireless Communications and Mobile Computing*, 2018, 2018: 1-12.
- [7] 杨晋生, 李亚洲. 一种基于模块化神经网络的场强预测方法[J]. *小型微型计算机系统*, 2017, 38(11): 2423-2426.  
YANG Jinsheng, LI Yazhou. Field strength prediction based on modular neural network[J]. *Journal of Chinese Computer Systems*, 2017, 38(11): 2423-2426.
- [8] AYADI M, ZINEB A B, TABBANE S. A UHF path loss model using learning machine for heterogeneous networks[J]. *IEEE Transactions on Antennas & Propagation*, 2017, 65(7): 3675-3683.
- [9] 李双德, 刘芄健, 林乐科, 等. 基于改进射线跟踪法和BP神经网络算法的室外微蜂窝毫米波信道特性研究[J]. *电波科学学报*, 2021, 36(3): 430-442, 452.  
LI Shuangde, LIU Yuanjian, LIN Leke, et al. Millimeter wave channel characteristics of outdoor microcellular based on improved ray tracing method and BP neural network algorithm[J]. *Chinese Journal of Radio Science*, 2021, 36(3): 430-442, 452.
- [10] WANG K. Ricean K-factor estimation based on channel quality indicator in OFDM systems using neural network[EB/OL]. (2018-08-5), [https://www.researchgate.net/publication/327134620\\_Ricean\\_K-factor\\_Estimation\\_based\\_on\\_Channel\\_Quality\\_Indicator\\_in\\_OFDM\\_Systems\\_using\\_Neural\\_Network](https://www.researchgate.net/publication/327134620_Ricean_K-factor_Estimation_based_on_Channel_Quality_Indicator_in_OFDM_Systems_using_Neural_Network).
- [11] LU T J, SUN J, WU K. High-speed channel modeling with machine learning methods for signal integrity analysis[J]. *IEEE Transactions on Electromagnetic Compatibility*, 2018, 60(6): 1957-1963.
- [12] 朱显辉, 于越, 师楠, 等. BP神经网络的分层优化研究及其在风电功率预测中的应用[J]. *高压电器*, 2022, 58(2): 158-163, 170.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on layered optimization of BP neural network and its application in wind power prediction[J]. *High Voltage Apparatus*, 2022, 58(2): 158-163, 170.
- [13] 周利军, 彭卫, 邹芳, 等. 自适应变异粒子群算法[J]. *计算机工程与应用*, 2016, 52(7): 50-55.  
ZHOU Lijun, PENG Wei, ZHOU Fang, et al. Adaptive mutation particle swarm optimization algorithm[J]. *Computer Engineering and Applications*, 2016, 52(7): 50-55.
- [14] 杨利伟, 邢雯雯, 张莉平, 等. 基于GA优化BP神经网络模型的污水管道系统健康状况评估[J]. *给水排水*, 2021, 57(9): 123-131.  
YANG Liwei, XING Wenwen, ZHANG Liping, et al. Health assessment of sewage pipeline system based on GA optimized BP neural network model[J]. *Water & Wastewater Engineering*, 2021, 57(9): 123-131.
- [15] ZHOU Y, TIAN L, LIU L, et al. Fog computing enabled future mobile communication networks: A convergence of communication and computing[J]. *IEEE Communications Magazine*, 2019, 57(5): 20-27.
- [16] YZA B, LING L, LU W, et al. Service-aware 6G: An intelligent and open network based on the convergence of communication, computing and caching-ScienceDirect[J]. *Digital Communications and Networks*, 2020, 6(3): 253-260.
- [17] SAEZ D, ADANA F, GVTIERRE Z, et al. Propagation model based on ray tracing for the design of personal communication

- systems in indoor environments[J]. IEEE Transactions on Vehicular Technology, 2000, 49(6): 2105-2112.
- [18] 李双德,刘莞健,林乐科. 28 GHz室内毫米波信道路径损耗模型研究[J]. 电波科学学报, 2017, 32(5): 602-611.  
LI Shuangde, LIU Wujian, LIN Leke. Path loss models of millimeter-wave channel in indoor environment at 28 GHz[J]. Chinese Journal of Radio Science, 2017, 32(5): 602-611.
- [19] 刘忠玉. 室内外场景下基于射线跟踪算法的无线信道预测研究[D]. 西安:西安电子科技大学, 2013.  
LIU Zhongyu. Research on wireless channel prediction based on ray tracing algorithm in indoor and outdoor scenes[D]. Xi'an: Xidian University, 2013.
- [20] 黄体浩,李俊青,赵海勇. 遗传算法优化的BP神经网络拷贝数变异检测[J]. 计算机工程与应用, 2022, 58(1): 274-281.  
HUANG Tihao, LI Junqing, ZHAO Haiyong. Copy number variation detection of BP neural network based on genetic algorithm [J]. Computer Engineering and Applications, 2022, 58(1): 274-281.
- [21] NURIKA O, HASSAN M, FADZIL Z, et al. A study of fluctuations and confidence of implementation in genetic algorithm optimized network in data centre[J]. Intelligent Decision Technologies: An International Journal, 2018, 12(1): 25-37.
- [22] RAMIREZ J M, MONTOYA D P. A piecewise solution to the reconfiguration problem by a minimal spanning tree algorithm [J]. International Journal of Emerging Electric Power Systems, 2014, 15(5): 419-427.
- [23] SOLTANI A R, TAWFIK H, GOULERMAS J Y, et al. Path planning in construction sites: Performance evaluation of the GA search algorithms[J]. Advanced Engineering Informatics, 2002, 16(4): 291-303.
- [24] 卢月品,赵阳,孟跃强,等. 基于改进遗传算法的狭窄空间路径规划[J]. 计算机应用研究, 2015, 32(2): 413-418.  
LU Yuepin, ZHAO Yang, MENG Yueqiang, et al. Path planning in narrow space based on improved genetic algorithm[J]. Application Research of Computers, 2015, 32(2): 413-418.

## 作者简介:



王智宁(1996-),男,硕士研究生,研究方向:无线信道预测、射线跟踪算法、深度学习, E-mail: 896166884@qq.com。



江虹(1969-),通信作者,男,教授,博士生导师,研究方向:无线认知技术, E-mail: jiangHong@swust.edu.cn。



彭潇祺(2000-),男,硕士研究生,研究方向:通信工程, E-mail: 992930544@qq.com。

(编辑:陈珺)