

基于改进遗传算法优化的 RBF 网络的信道估计

胡一晨, 耿虎军

(中国电子科技集团公司 第 54 研究所, 石家庄 050081)

摘要: 为了提高通信系统信道估计的准确率, 同时适应更大的数据量, 进行更加复杂的数据计算, 引入神经网络的方法进行信道估计, 采用了 BP 和 RBF 神经网络进行实验对比, 与传统信道估计方式相比有明显提升; 在此基础上, 进一步提出基于改进遗传算法优化的 RBF 神经信道估计方法, 目的是帮助确定 RBF 网络的隐藏层参数, 使得网络的参数趋于全局最优解, 信道估计器的性能从而得到提升。经过 Matlab 仿真, 改进后的 RBF 神经网络可以更好地解决信道估计问题, 验证了此方法的可行性。

关键词: OFDM 系统; 遗传算法; RBF 神经网络; 信道估计器; Matlab

Channel Estimation of RBF Networks Based on Improved Genetic Algorithm Optimization

HU Yichen, GENG Hujun

(China Electronics Technology Group Corporation No. 54 Research Institute, Shijiazhuang 050081, China)

Abstract: In order to improve the accuracy of channel estimation in communication systems and adapt to larger data for more complex data calculation, a neural network method was introduced for channel estimation. Experiment comparison is conducted between the radial basis function (RBF) neural network and back propagation (BP) neural network, compared with traditional channel estimation methods, the experimental results show significant improvement. On this basis, an RBF neural channel estimation method based on improved genetic algorithm was also proposed. The purpose is to determine the hidden layer parameters of RBF network, making the network parameters to the universally optimal solution, and then improving the efficacy of the channel estimator. The enhanced RBF neural network effectively resolve the channel estimation by MATLAB simulation, thereby verifying the feasibility of this approach.

Keywords: orthogonal frequency division multiplexing (OFDM) system; genetic algorithm; RBF neural network; channel estimator; Matlab

0 引言

随着无线通信行业发展迅速, 人们对于语音、数据、图形图像和视频等的数据传输速率需求也大大提升。多载波并行传输技术非常适合带宽无线通信系统, 因为它具有一系列特性, 如抵抗信道衰落^[1]、耐受窄带干扰和噪声^[2]、扩大带宽的灵活性以及调整用户速率^[3]的可能性等。近来, 以正交频分复用 (OFDM) 为主的多载波并行传输技术有了显著的发展并被广泛地应用。作为一种并行传输方式, OFDM 将数据分成多个子数据流, 这样每个数据流的速度就降低了, 它具有出色的抵抗多径和窄带干扰的能力, 许多无线通信标准选择它作为物理层的解决方案。随着 OFDM 技术的研究不断被深入, 这项技术已经被广泛用于无线通信^[4]、雷达通信系统、数字广播电视、以及卫星通信等领域。

对于 OFDM 系统来说, 信道估计算法有很多种分类,

根据在信号处理范围可分为: 时域和频域信道估计算法; 根据是否使用辅助导频, 大致将其分为非盲信道估计、盲信道估计和半盲的信道估计。

在 OFDM 系统内, 大多数的信道评估方法选择采用非盲信道评估算法, 亦即通过使用导频或训练序列来对信道进行评估。这种方法是通过在发送端添加导频于合适的位置, 接收端可以利用导频来恢复出信道信息的导频位置, 进而通过插值、过滤, 变换等一系列处理步骤, 获取全部时间段的信道信息。此评估方式可以高效地跟踪信道的动态变化, 对于快速衰减的信道并不敏感, 并且在无线通信领域有着广泛的应用。

传统信道评估手段主要以导频为基础, 涵盖了最小二乘法 (LS, least squares)、最小均方差 (MMSE, minimum mean square error) 及线性最小均方差 (LMMSE, linear minimum mean square error)。而被称为盲信道估计的另一方法, 不需要发送端发送导频信号, 从而减少了系

收稿日期: 2023-08-18; 修回日期: 2023-09-07。

基金项目: 国家自然科学基金青年科学基金项目(62101517)。

作者简介: 胡一晨(1998-), 女, 硕士研究生。

通讯作者: 耿虎军(1971-), 男, 研究员, 研究生导师。

引用格式: 胡一晨, 耿虎军. 基于改进遗传算法优化的 RBF 网络的信道估计[J]. 计算机测量与控制, 2024, 32(1): 165-171, 178.

统的额外消耗，比起基于导频的信道评估，其传输效率更为卓越。但是，它需要接收大量数据来追踪信道，对于快速衰落具有较高的敏感性，必须在静态环境中进行。半盲估计：将以上两类算法有机地融合在一起，只需通过较少的导频信息就能获得相应的盲信道估计初始值，再通过盲信道估计方法来实现对信号的追踪。

虽然对传统的信道估计算法进行了深入研究，但是效果没有达到令人满意的目标。目前，大部分的无线通讯系统都是建立在理想的白噪声基础上的。然而，此类假定条件在现实通讯中很难实现，理想噪声下的检测方法往往会呈现较高的误码率，使得大部分基于此假定的检测方法都不适用。

随着机器学习的不断发展和应用，使得具有数学模型的问题得到不同的解决方式，提供更加准确充分的训练数据来训练学习系统。因此，机器学习及其变种，如基于深度神经网络 (DNN) 的学习，在无线通信领域正受到广泛的关注，以解决定位和定位^[5]、资源分配^[6-7]、通信安全^[8]和信道估计^[9]等问题。

比如近年来出现了将机器学习方式融入信道估计的算法研究。在文献 [10] 中，将 OFDM 调制方式和无线信道都视为黑匣子，将接收到的信号送入训练好的网络，就可以得到实际的发射信号。然而，在文献 [10] 中提出的深度学习不能给出信道脉冲响应 (CIR)。它被设计为隐式估计 CSI，并在接收端直接恢复发送的符号。文献 [11] 主要研究了基于 BP 的多输入多输出正交频分复用系统信道估计方法。该网络的目的是补偿高功率放大器的非线性误差，仿真结果表明其可以通过增加神经网络的数量和网络层数来达到估计性能的改善。

同时在实际应用中，信道估计是一个动态过程，需要不断地对信道进行估计和补偿，以保证 OFDM 系统的稳定性和可靠性。

面对传统通信系统中信道估计不准确这一难题，设计提出应用深度学习技术的 OFDM 通信系统信道估计方案。此方案把信号处理过程转化为回归拟合与自适应优化问题。在回归拟合部分，采用大数据分析策略可实现离线数据的分析和训练，以建立信道和传输参数间的非线性映射，并在此基础上拟制初步信道计算模式；而对于自适应优化环节，从实际数据分析反馈中开展在线实时训练，同时借助集成的学习策略改进模型，有效避免一次性离线训练费用过大的难题。实验结果证实，融入自适应学习的信道估计技术，能够有效挖掘各种环境下信道估计的非线性特质，极大增强了通信系统恢复信号的能力。

虽然 BP 神经网络具备较为强大的自我学习和自我调整能力，但它的学习进程却比较缓慢，也容易陷入局部最优的问题。为此，采用了一种新的方法，即通过引入改进的遗传算法对 RBF 网络的基函数宽度、中心和连接权重进行调节，从而实现了优化 RBF 网络的目标，学习速度大大提升，同时也为解决陷入局部最小值的问题提供了

方法。

1 系统结构及原理

OFDM 系统是一种多载波调制技术，它通过将多个数字信号进行分组，然后在每个分组中使用不同的载波进行传输，以提高传输速率。其次，OFDM 系统可以利用 OFDM 调制技术实现多用户同时通信，这有助于提高系统的吞吐量和可靠性。最后，OFDM 系统还可以利用频率复用技术实现多径传输，但与此同时也会产生符号间干扰，即每个 OFDM 块都需要设置保护间隔来解决此类问题。为确保前一个 OFDM 块的延迟副本不会对下一个 OFDM 块产生干扰，间隔的长度要超过最大时延。保护间隔的创建也打破了载波之间的正交性，结果是不同的子载波开始重叠，从而导致了信道互相干扰的 ICI。

一个可能的解决这个困难问题的方法是，采用保护间隔内做 OFDM 信标循环展开，从而构造循环前缀 CP。为能同时应对多径信道带来的 ISI 和 ICI 问题，要信道的最长时延不超过 CP 的长度。

如图 1 所示，设定 OFDM 系统子信道的数目为 N ，设频带的宽度为 W (Hz) 且符号的长度被定为 T ，设定调制后为 $x_{0,t}, x_{1,t}, \dots, x_{N-1,t}$ ，CP 的长度 T_{CP} ，因此，第 l 个 OFDM 符号的基带形态可以被推导出：

$$s_l(t) = \sum_{k=0}^{N-1} x_{k,t} \Phi_k(t - lT) \quad (1)$$

式中，

$$\Phi_k(t) = \begin{cases} \frac{1}{\sqrt{T - T_{CP}}} e^{j2\pi W/Nk(t - T_{CP})} & t \in [0, T] \\ 0 & \text{other} \end{cases} \quad (2)$$

表示第 k 个子载波的波形。

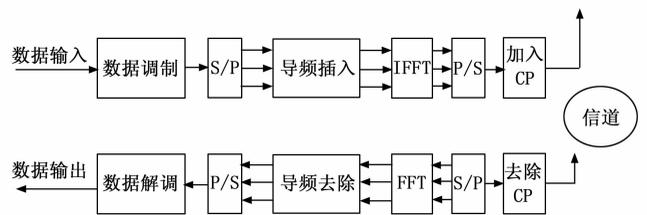


图 1 OFDM 系统基本结构

发射信号 $s(t)$ 可以表示为：

$$s(t) = \sum_{l=-\infty}^{+\infty} s_l(t) = \sum_{l=-\infty}^{+\infty} \sum_{k=0}^{N-1} x_{k,t} \Phi_k(t - lT) \quad (3)$$

如果信道的冲击响应表示为 $h(t)$ ，且信道的最大时延未超过 CP 的长度，接受的信号就可以这样描述：

$$r(t) = h(t) \otimes s(t) + n(t) = \int_0^{T_{CP}} h(\tau) s(t - \tau) d\tau + n(t) \quad (4)$$

式中， $n(t)$ 表示加性高斯白噪声 (AWGN)。

为消除符号间干扰，也可去除循环前缀，选择采用相应的匹配滤波器来采集该载波的信息，该匹配滤波器的表示方法如下：

$$\psi_k(t) = \begin{cases} \Phi_k^*(T-t) & t \in [0, T-T_{cp}] \\ 0 & \text{other} \end{cases} \quad (5)$$

第 k 个匹配滤波器的采样输出为:

$$Y_k = r(t) \otimes \psi_k(t) \Big|_{t=T} = \int_{-\infty}^{+\infty} r(t) \psi_k(T-t) dt = \int_{T_{cp}}^T \left\{ \int_0^{T_{cp}} h(\tau) \left[\sum_{k'}^{N-1} x_{k'} \Phi_{k'}(t-\tau) \right] d\tau \right\} \Phi_k^*(t) dt + \int_{T_{cp}}^T n(t) \Phi_k^*(t) dt \quad (6)$$

经过适当的处理, 可以得到:

$$Y_k = \sum_{k'}^{N-1} x_{k'} H_{k'} \int_{T_{cp}}^T \Phi_{k'}(t) \Phi_k^*(t) dt + N_k \quad (7)$$

式中,

$$H_{k'} = H(k'w/N) = \int_0^{T_{cp}} h(\tau) e^{-j2\pi k'w\tau/N} d\tau \quad (8)$$

$H_{k'}$ 是第 k 个子载波频率处的频率响应, N_k 是 $n(t)$ 通过匹配滤波器的输出。而发射滤波器 $\varphi_k(t)$ 处于正交状态, 即:

$$\int_{T_{cp}}^T \Phi_{k'}(t) \Phi_k^*(t) dt = \delta(k-k') \quad (9)$$

可简化为 $Y_k = x_k H_k + N_k$ 。

通过对接收端的信道参数进行评估, 就能够还原发送的信号 x_k 。

2 神经网络回归模型的建立

在无线通信领域, 信道估计是一项重要的任务。在无线信号通过信道时, 可能会遭遇诸如干扰、衰减、噪声等问题。因此, 评估信道的状态确实至关重要, 这样接收端才能对收到的信号进行精确的解码和操作。

2.1 BP 神经网络的模型

2.1.1 概念定义

当今应用较多的 BP (back propagation) 神经网络是根据误差逆传播算法进行训练的多层前馈型神经网络。它的优势在于不需要明确相关映射关系, 可以对输入-输出的关系进行训练和存储。网络的拓扑结构包括输入、隐含和输出层, 如图 2 所示。

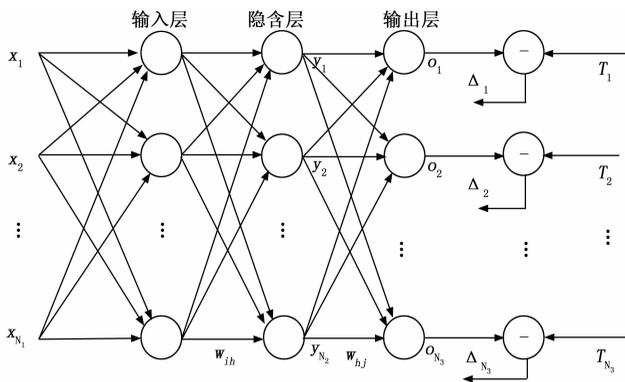


图 2 BP 神经网络结构

网络隐含层和输出层上的某神经元 j 的输出由下式确定:

$$O_j = f_j(\text{net}_j) = f_j\left(\sum_i \omega_{ji} x_i + \theta_j\right) \quad (10)$$

式中, $f_j(\cdot)$ 表示对应神经元的激活函数; x_i 为神经元的输入; ω_{ji} 表示连接权值从神经元 j 到 i 的; 设置激活函数为连续可微的非线性的 Sigmoid 函数: $f(x) = \frac{1}{1+e^{-x}}$, 激活函数要求处处可导。

2.1.2 BP 网络的建立及执行

1) 网络初始化: 选择网络的层数和节点神经元个数分别是 n 、 p 、 q , 本次选择三层结构。参数设置: 学习次数最大值 M , 误差函数 e 、计算精度值 ϵ 和理论预期输出 d_o ; 隐含层的阈值: b_h ; 输出层阈值: b_o ; 激活函数: $f(\cdot)$;

2) 计算选定样本 k 对应的实际输出和期望数值 $x(k) \rightarrow d_o(k)$;

3) 隐含和输出层各神经元的输入和输出:

隐含层表示为 hi 、 ho , 输出层为 yi 、 yo , 网络中的连接权值: w_{ih} 和 w_{ho} ;

$$\begin{cases} hi_h(k) = \sum_{i=1}^n w_{ih} x_i(k) - b_h & h = 1, 2, \dots, p \\ ho_h(k) = f(hi_h(k)) & h = 1, 2, \dots, p \\ yi_o(k) = \sum_{h=1}^p w_{ho} ho_h(k) - b_o & o = 1, 2, \dots, q \\ yo_o(k) = f(yi_o(k)) & o = 1, 2, \dots, q \end{cases} \quad (11)$$

4) 利用期望值 $d_o(k)$ 和实际值 $x(k)$, 计算误差函数对输出层和隐含层的偏导数 $\delta_o(k)$ 、 $\delta_h(k)$:

$$\begin{cases} \frac{\partial e}{\partial w_{ho}} = \frac{\partial e}{\partial yi_o} \frac{\partial yi_o}{\partial w_{ho}} \\ \frac{\partial yi_o(k)}{\partial w_{ho}} = \frac{\partial (\sum_h w_{ho} ho_h(k) - b_o)}{\partial w_{ho}} = ho_h(k) \end{cases} \rightarrow \frac{\partial e}{\partial yi_o} = -(d_o(k) - yo_o(k)) yo'_o(k) \quad (12)$$

$$\frac{\partial e}{\partial w_{ho}} = \frac{\partial e}{\partial yi_o} \frac{\partial yi_o}{\partial w_{ho}} = -\delta_o(k) ho_h(k) \quad (13)$$

5) 利用隐含层输出 ho 和输出层各神经元的 $\delta_o(k)$ 和来修正连接权值 $w_{ho}(k)$:

$$\begin{aligned} \Delta w_{ho}(k) &= -\mu \frac{\partial e}{\partial w_{ho}} = \mu \delta_o(k) ho_h(k) \\ w_{ho}^{N+1} &= w_{ho}^N + \eta \delta_o(k) ho_h(k) \end{aligned} \quad (14)$$

6) 利用输入层的输入向量 x 和隐含层的 $\delta_h(k)$ 修正连接权值 $w_{ih}(k)$:

$$\begin{aligned} \Delta w_{ih}(k) &= -\mu \frac{\partial e}{\partial w_{ih}} = \delta_h(k) x_i(k) \\ w_{ih}^{N+1} &= w_{ih}^N + \eta \delta_h(k) x_i(k) \end{aligned} \quad (15)$$

7) 计算全局误差并判断是否满足误差要求, 当误差符合设定范围或训练次数超过 M 时, 结束训练, 否则重复步骤 3, 直到满足:

$$E = \frac{1}{2m} \sum_{k=1}^m \sum_{o=1}^q (d_o(k) - y_o(k))^2 \quad (16)$$

2.2 RBF 神经网络的模型

本节讨论使用径向基函数神经网络 (RBF) 来进行信

道估计。这是一种高性能的前馈网络，它具有良好的处理局部最小值的问题的能力，这是源于多元插值的径向基函数方法在数学分析中的应用。在这种网络结构中，理论上 RBF 神经网络可以模拟任何未知函数，特点是非线性 and 线性基函数的运用。由此，径向基函数可以被看作是将原有的非线性特征空间转换成一个高维空间，通过合理的转换，使得新空间中的原始问题具有线性可分的可能性。

基于上述作用，引入信道估计问题，它可以通过学习已知信道状态信息 (CSI) 和接收信号的映射来进行信道估计。具体地，RBF 神经网络可以将接收信号作为输入，将已知的 CSI 作为输出，并通过训练来学习信道的映射关系。运用 RBF 神经网络进行信道估计，可以使其准确度和鲁棒度均有所增强，进一步提升了通信系统的效能。系统整体如图 3 展示。

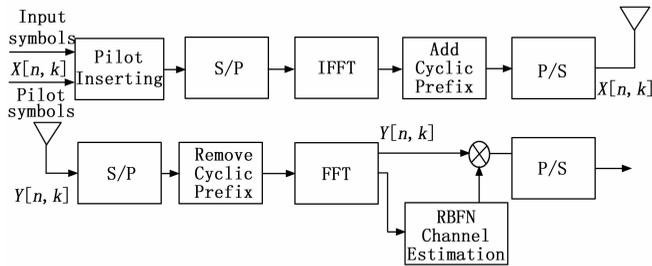


图 3 加入网络的结构

除此之外，RBF 神经网络还可以用于自适应信道均衡，通过学习信道的动态变化，实现对信道的自适应均衡，从而进一步提高通信系统的性能。RBF 网络是一种三层前馈型结构网络，其独特所在为它将输入信号转化为输出信号，属非线性变换过程，但在隐藏层以至输出空间的转变中，则呈现线性映射。这样的架构提高了学习效能以及杜绝了局部最小值的问题。如图 4 所示。

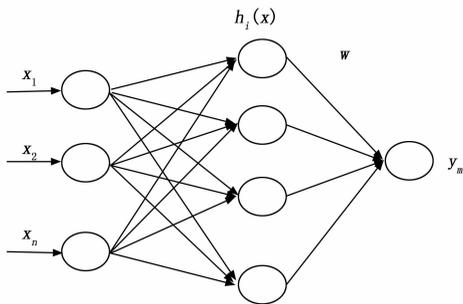


图 4 RBF 神经网络结构

在 RBF 网络模型中，输入信号设置为 $x = [x_1, x_2, \dots, x_n]^T$ 向量来构成。设定径向基向量 $h = [h_1, h_2, \dots, h_m]^T$ 时，选用高斯基函数 h_j 作为运算方法。

$$h_j = \exp\left(-\frac{\|x - c_j\|^2}{2b_j^2}\right), j = 1, 2, \dots, m \quad (17)$$

其中：网络的第 j 个节点的中心矢量为：

$$C_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T, i = 1, 2, \dots, n \quad (18)$$

假定网络的基宽向量定义为 $B = [b_1, b_2, \dots, b_m]^T$ ，节点 j 的基宽度参数表示为 b_j ，并且是一个大于零的数值。网络的权重向量定义为：

$$W = [[w_1, w_2, \dots, w_m]]^T \quad (19)$$

网络的输出为：

$$y_m(k) = w_1 h_1 + w_2 h_2 + \dots + w_m h_m \quad (20)$$

采用 Jacobian 信息的辨识算法，辨识器的性能指标函数为：

$$J = \frac{1}{2} (y(k) - y_m(k))^2 \quad (21)$$

根据梯度降低法，迭代算法可计算出权重、节点中心和节点基宽参数如下：

$$\Delta w_j(k) = \eta (y(k) - y_m(k)) h_j \quad (22)$$

$$w_j(k) = w_j(k-1) + \Delta w_j(k) + \alpha (w_j(k-1) - w_j(k-2)) \quad (23)$$

$$\Delta b_j(k) = \eta (y(k) - y_m(k)) w_j h_j \frac{\|X - C_j\|^2}{b_j^3} \quad (24)$$

$$b_j(k) = b_j(k-1) + \Delta b_j(k) + \alpha (b_j(k-1) - b_j(k-2)) \quad (25)$$

$$\Delta c_{ji}(k) = \eta (y(k) - y_m(k)) w_j \frac{x_{ji} - c_{ji}}{b_j^2} \quad (26)$$

$$c_{ji}(k) = c_{ji}(k-1) + \Delta c_{ji}(k) + \alpha (c_{ji}(k-1) - c_{ji}(k-2)) \quad (27)$$

式中， η 为学习速率， α 为动量因子。

本算法是以 Jacobian 矩阵为基础的：

$$\frac{\partial y(k)}{\partial \Delta u(k)} \approx \frac{\partial y_m(k)}{\partial \Delta u(k)} = \sum_{j=1}^m w_j h_j \frac{c_{ji} - x_{1j}}{b_j^2} \quad (28)$$

式中， $x_1 = \Delta u(k)$ 。

2.3 模型的效果对比

在考虑误码率 (BER) 与信噪比 (SNR)、均方误差 (MSE) 与信噪比准则的基础上，通过计算机仿真比较了所提出的 BP 神经网络、径向基函数 (RBF) 神经网络 LMMSE、LS 算法的性能。采用 QPSK 调制方式，设置了 [0, 200, 600, 1 600, 2 400, 5 000] ns 相对延迟和 SNR 设置范围为 [0, 20]，数据传输信道为瑞利信道。为了证明这些估计器的性能，使用相同的传输条件。一个 MLP 网络由一个包含 10 个神经元的隐层构成。在隐层中采用 sigmoid 激活函数，输出设置为线性激活函数。RBF 神经网络有一个隐层，隐层有 64 个神经元，具有高斯激活函数。实验结果如下。

如图 5 所示，LS 算法的误码率比其他的性能最差，LMMSE 其次。不论低信噪比或高信噪比条件下，BP 和 RBF 神经网络估计器的性能都优于传统的 LS 和 LMMSE 算法，说明使用的神经网络的方法可以有效改善信道估计的性能。

图 6 显示了均方误差 (MSE) 与信噪比的关系。为了表示估计量的性能，标出 Cramer Rao 界。从图 6 可以看出，在每个信噪比值下，LS 算法的信道估计误差都大于其他估计方法。在相同的信噪比时，深度学习的训练方法性能明

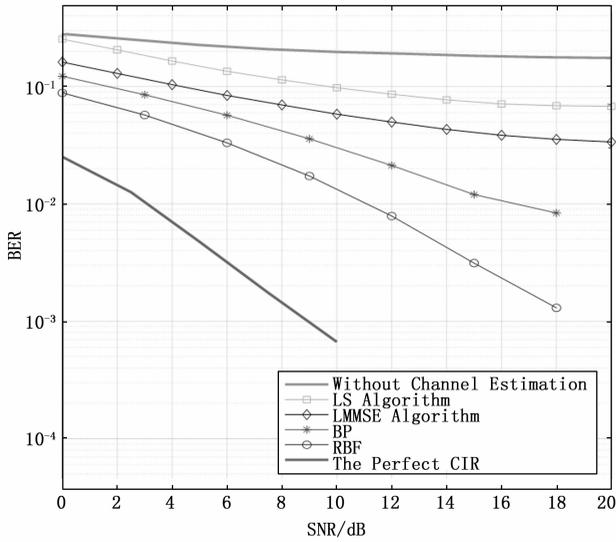


图 5 SNR 和 BER 的曲线图

显好于 LS 和 LMMSE 算法, 随着信噪比的增大, 差距更加的明显, 效果提升更好。

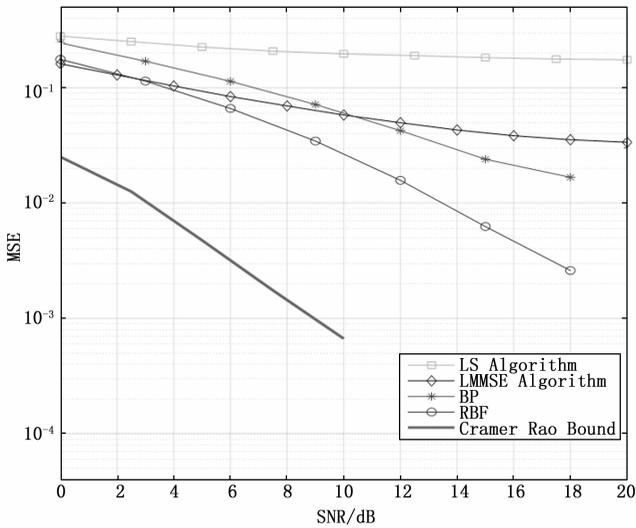


图 6 SNR 和 MSE 的曲线图

3 改进的遗传算法模型

3.1 遗传算法的改进思路

遗传算法^[12] (GA, genetic algorithm) 是一种利用自然选择和生物遗传原理进行搜索优化的方法。在此策略中把“优胜劣汰、适者生存”演化原则落实在参数改善过程的编码集合上。通过遗传操作及适合度函数对各项进行筛选, 让那些适应度较高的因子得以保留, 构成新的编码集合, 使新编码集合中的所有项目的适应性逐步强化, 直到满足特定的极限条件。在这一点上, 现有最高适应度的项目便是参数优化的最优答案。遗传算法特殊的工作机制, 使其能在复杂的情境中进行全局最优化搜索, 且具有较优的鲁棒能力。遗传算法除了可以用来优化网络结构, 还可

用 GA 来学习其权重。

所以可以在上述 RBF 系统中对信道进行估计时, 遗传算法的加入用来使得系统得以进一步优化。这个优化的目标主要在于利用遗传算法将高斯函数 h 的中心矢量、权值及网络结构, 以及基宽向量的初始值在群体中进行优化。本文希望通过这种方式来优化 RBF 网络的参数并训练信道估计器。这样优化后的 RBF 神经网络会降低实际输出和期望输出间的误差, 有利于提高训练效率以及系统精确性。

遗传算法是一类高效的全局寻优方法, 但其收敛特性受交叉概率 P_c 、突变概率 P_m 等因素的选择所决定, 而不恰当的参数选择会导致算法提前收敛, 效果较差。但在传统遗传算法运算过程中, P_c 和 P_m 大多为固定值。参数的设置对算法的收敛速度影响较大, 如果 P_c 过大则会容易导致过早收敛, 而陷入局部极值的问题。

为此, 操作时依据当前个体的适应度和迭代次数自适应地动态调整二者。即引入了一种新的基于进化思想的基因优化方法, 该方法能根据个体的变化而动态地调节 P_c 和 P_m , 从而达到更好的运算结果。

将个体适应度考虑其中, 交叉概率 P_c 和变异概率 P_m 采用如下计算公式:

$$P_c = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f' - f_{avg})}{f_{min} - f_{avg}} (f' < f_{avg}) \\ P_{c1} (f' \geq f_{avg}) \end{cases}$$

$$P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f_{min} - f')}{f_{min} - f_{avg}} (f < f_{avg}) \\ P_{m1} (f \geq f_{avg}) \end{cases} \quad (29)$$

式中, 交叉操作中较小的适应度值为 f' ; 变异过程中适应度值 f ; 每代群体平均适应度值 f_{avg} 和最小适应度值 f_{min} 。

在这两个操作过程中起决定作用的为交叉、变异算子, 保证了种群的多样性, 增加了算法的局部搜索能力。

3.2 遗传算法改进 RBF 神经网络

本节介绍使用遗传算法对 RBF 神经网络进行改进, 使网络的参数具有更好的适应性, 并进行信道估计的方法。系统流程图如图 7 所示。

改进遗传算法的步骤简化如下:

1) 种群 P 的初始化设置及编码: 设定交叉规模、交叉概率 P_c 、突变概率 P_m , 并对 W_{i,H_i} 和 W_{H_i,O_i} 初始化数值, 采用实数编码方式;

2) 计算每个实体的评价函数和适应度函数, 确定是否满足收敛条件; 个体的选择可以根据以下公式的概率值进行:

$$p_s = f_i / \sum_{i=1}^N f_i \quad (30)$$

个体的适配值可以通过误差平方和 E 的值进行评估, 也就是说, 适配值是由这种方式确定的为 f_i :

$$f(i) = 1/E(i) \quad (31)$$

$$E(i) = \sum_p \sum_k (V_k - T_k)^2 \quad (32)$$

其中: $i = 1, \dots, N, k, p, T_k$ 分别代表染色体的数量、输

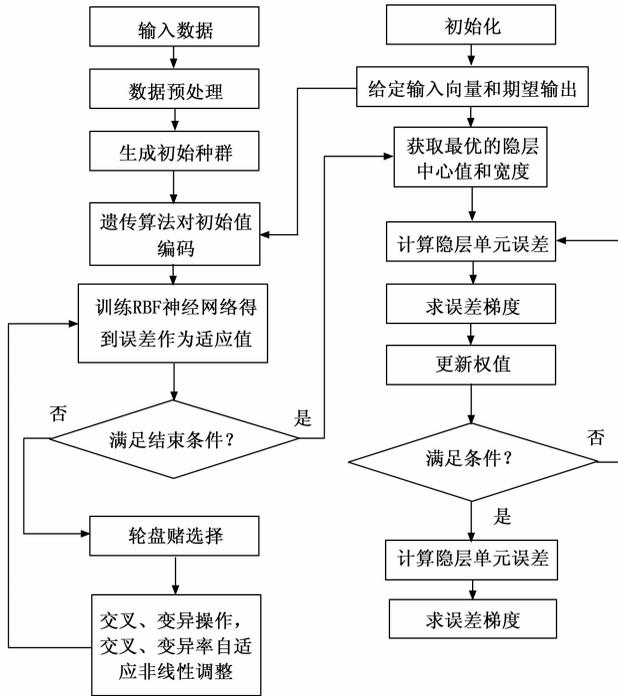


图 7 软件设计流程

出层的节点数量、学习的样本数量和期待的输出。

3) 是否满足输出的条件 (精度或者进化迭代的次数), 满足输出, 否则继续以下程序;

4) 交叉与变异的计算: 利用概率 P_m 突变产生 G_j 的新个体 G'_j ; 这两种操作的目标是产生新的配对组合, 根据交叉重组概率从集群中任意选择两个个体进行配对, 并运用合适的交叉算子, 从而生成两个新的个体。

5) 将新个体加入到群体中, 同时计算新个体的评估函数;

6) 如果找到了满意的个体结束, 否则继续。

当满足预定的性能目标后, 解析群体中的最优成员, 便能获得被优化过的网络链接权值。因此, 采用遗传算法对神经网络进行优化, 主要集中在权重的优化上。

4 实验结果与分析

4.1 实验仿真结果

仿真实验中, 采用 MATLAB 平台进行程序设计, 在传输信道背景为瑞利衰落信道的情况下, 检验改进方法训练的 RBF 神经网络的模型测试效果。发送端产生一组四进制的随机数字, 将每个四进制数字对应为一个复数, 然后将其插入导频, 并将最高和最低的四个子频带作为保护频段, 再通过希尔伯特变换生成发射信号的复基带。同时传输信道设置为瑞利信道特性参数。然后在该算法中加入设定的高斯白噪声, 删除循环前缀 CP, 并对该算法进行了等时间间隔采样, 最终通过傅立叶变换得到输出信号。根据本文所设定的估计方法, 展开信道估计, 完成均衡, 并计算出误比特率的值, 与传统的信道估计方式进行比较和分析。仿真参数的设置: QPSK 的调制方式, 多径数为 6,

信道参相关延迟向量为 [200, 300, 400, 500, 900, 13 000] ns, SNR 设置范围 [-8, 20], 最大多普勒频移 0.008。RBF 神经网络的结构初始设置输入层数量 12, 隐藏层 64, 输出层 12。下一步, RBF 神经网络将进行遗传算法的优化处理, 此遗传算法将进行 100 次迭代, 种群规模是 20, 其中 $P_{c1} = 0.8$; $P_{c2} = 0.6$; $P_{m1} = 0.1$, $P_{m2} = 0.01$, 学习率为 0.02。

4.2 结果分析

本文实验测试结果选择误码率进行效果展示, 同时加入传统信道估计方法进行效果对比, 如图 8 所示。

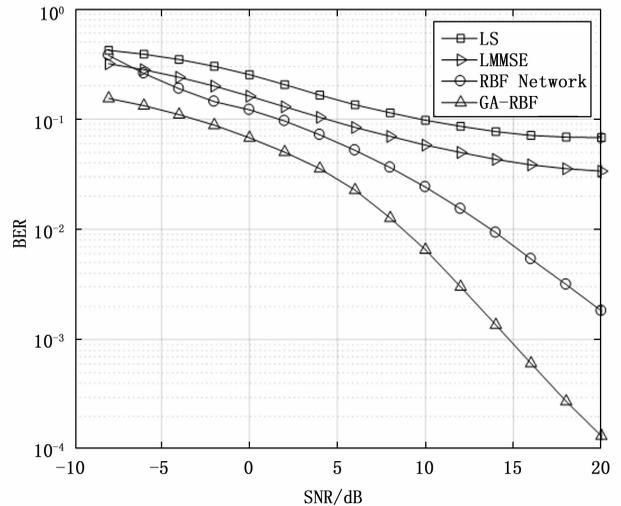


图 8 信噪比和误码率的曲线图

从图 7 仿真的结果来看, 将深度学习的方法引入信道估计系统后, RBF 神经网络的效果明显优于传统的信道估计算法; 同时, 上述模型基础中使用改进的遗传算法进行网络优化的方案, 可以进一步提升信道估计的性能, 误码率进一步降低。

除此之外, 还可以考虑设置中继器, 中继器的作用可以进行信号的放大, 是否对估计效果有影响, 可以进行再次的对比。

如图 9 所示, 有中继器时改进后的 RBF 网络结构同样更适合进行信道估计, 有更好的估计准确率。图 10 也说明, 中继器有放大器的作用, 可以更好地反应实验数据。

除此之外, 信道传输的数据量可以成为一项对比标准, 结果如下。

如图 11 所示, 改进后的 RBF 网络算法可以更好的传输发送信号, 计算数据量的明显提升可以更好的进行信道估计, 具有较高的准确率, 达到更好的信道均衡效果, 进而恢复发送信号。

5 结束语

实验设计将 OFDM 信道估计问题转化为预测信道传输函数, 并在 OFDM 通信系统的信道估计中运用深度学习技术, 成功进行信道估计。同时, 利用改进的遗传算法对

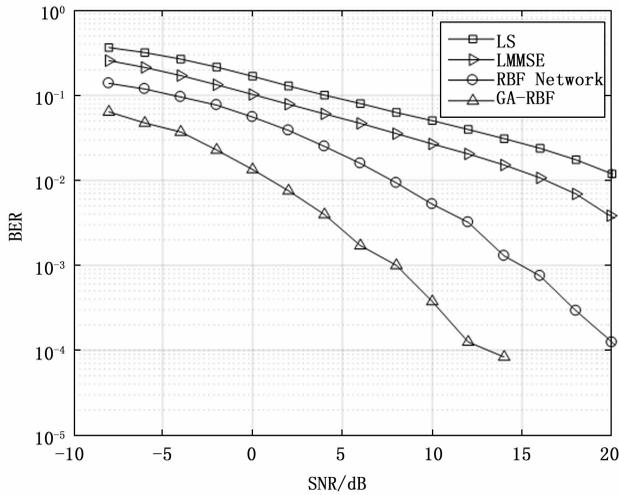


图 9 信噪比和误码率的曲线图 (中继器)

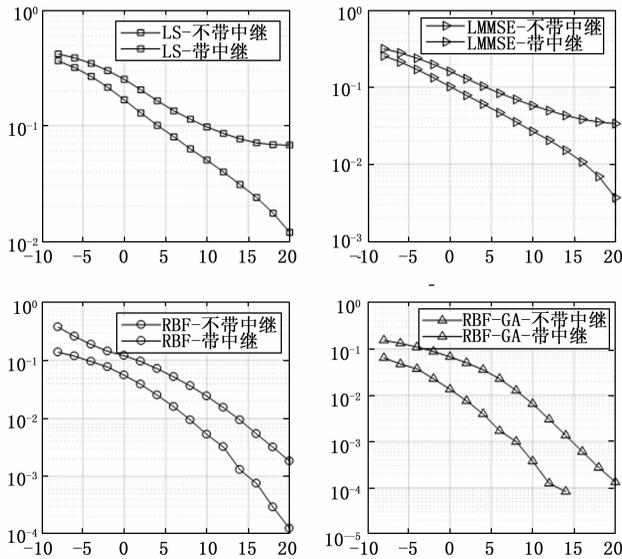


图 10 信噪比和误码率的曲线图 (不同算法单独对比)

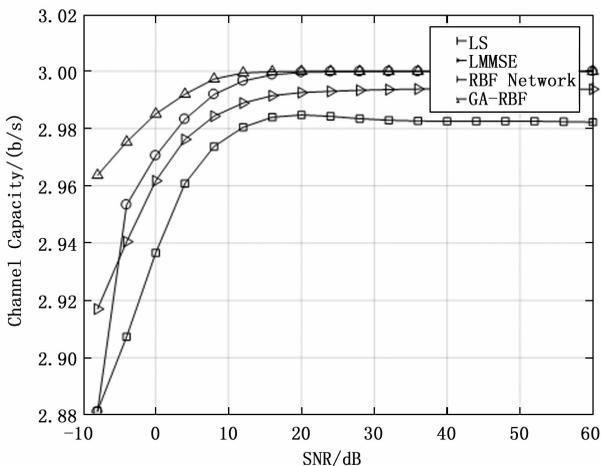


图 11 信噪比和信道容量的曲线图

RBF 网络进行优化, 实现信道估计效果提升。这个优化策略有助于确定 RBF 网络的隐藏参数, 使网络参数更接近全局最优解。且遗传算法改进后, 显著提升了网络训练的精确度, 解决了训练算法的无法完全收敛的问题。在设定的瑞利衰落信道的假设环境下进行了实验, 实验数据展示, 基于改进遗传算法的 RBF 网络模型能实现高精度的估计, 从而完成了信道估计。

参考文献:

[1] 赵珺洁, 张海林. OFDM 系统原理及关键技术 [J]. 现代电子技术, 2007, 30 (3): 43 - 45.

[2] DANG W, TAO M, MU H. Subcarrierpair Based Resource Allocation For Cooperative Multi - relay OFDM Systems [J]. Wireless Communications, IEEE Transactions on, 2010, 9 (5): 1640 - 1649.

[3] DAS S S, DE CARVALHO E, PRASAD R. Performance Analysis of OFDM Systems with Adaptive Subcarrier Bandwidth [J]. Wireless Communications, IEEE Transactionson, 2008, 7 (4): 1117 - 1122.

[4] CHANG R W, GIBBY R A. A Theoretical Study of Performance of An Orthogonal Multiplexing Data Transform [J]. IEEE Transations Communication, 1968, 16 (4): 529 - 540.

[5] WANG X, GAO L, MAO S, et al. CSI-based fingerprinting for indoor localization: A deep learning approach [C] // IEEE Transactions on Vehicular Technology, 2016, 66 (1): 763 - 776.

[6] GAO J, Khandaker M R A, TARIQ F, et al. Deep neural network based resource allocation for V2X communicateons [C] // IEEE 90th Vehicular Technology Conference (VTC2019-Fall), 2019.

[7] JAKOB A, WEISS E C, KNOLL T, et al. Silicon based GHz acoustic lenses for time resolved acoustic microscopy [C] // Ultrasonics Symposium, 2007: 1605 - 1608.

[8] SADEGHI M, LARSSON E G. Adversarial attacks on deeplearning based radio signal classification [C] // IEEE Wireless Communications Letters, 2018, 8 (1): 213 - 216.

[9] LI T, KHANDAKER M R A, TARIQ F, et al. Learning the wireless V2I channels using deep neural networks [C] // IEEE 90th Vehicular Technology Conference (VTC2019-Fall), 2019.

[10] YE H, LI G Y, JUANG B H, et al. Power of deep learning for channel estimation and signal detection in OFDM systems [C] // IEEE Wireless Communications Letters, 2017, 7 (1): 114 - 117.

[11] TASPINAR N, SEYMAN M N. Back propagation neural network approach for channel estimation in OFDM system [C] // 2010 IEEE International Conference on Wireless Communications, 2010: 265 - 268.

[12] HAN G J, GUAN Y L, KONG L J, et al. Construction of irregular QC-LDPC codes via masking with ACE optimization [J]. IEEE Commun. Letters, 2014, 18 (2): 348 - 351.

(下转第 178 页)