

DOI:10.20079/j.issn.1001-893x.221129002

无蜂窝大规模 MIMO 系统接入点动态选择算法*

申 敏, 裘德市

(重庆邮电大学 通信与信息工程学院, 重庆 40065)

摘 要:在无蜂窝大规模多输入多输出 (Multiple-Input Multiple-Output, MIMO) 系统中,所有接入点 (Access Point, AP) 为用户提供服务的方式会造成较大的功率消耗和增加前传链路压力。以“用户为中心”的 AP 选择方案为每个用户选择最佳的 AP 集合,使系统频谱效率和能量效率得以提升。为了给每个用户选择最佳的 AP 集合,提出了一种基于反向传播 (Back Propagation, BP) 神经网络的接入点动态选择算法。将 AP 与用户之间的大尺度衰落向量作为输入,AP 与用户之间的连接关系作为 BP 神经网络输出的预测向量,同时,针对 BP 神经网络初始化权值,提出了一种改进的自适应遗传算法以提高算法的收敛速度和收敛性能。仿真结果表明,改进后的 BP 神经网络预测结果更接近于实际值,并且比全连接和启发式的 AP 选择方案具有更高的系统和速率。

关键词:无蜂窝大规模 MIMO;接入点选择;遗传算法;BP 神经网络

开放科学 (资源服务) 标识码 (OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN929.5 文献标志码:A 文章编号:1001-893X(2024)03-0416-07

A Dynamic Access Point Selection Algorithm in Cell-free Massive MIMO Systems

SHEN Min, QIU Deshi

(School of Communication and Information Engineering, Chongqing University of Posts and
Telecommunications, Chongqing 400065, China)

Abstract: In a cell-free massive multiple-input multiple-output (MIMO) system, all access points (APs) provide services to users, resulting in high power consumption and increased pressure on the fronthaul link. The “user-centric” AP selection scheme selects the best AP set for each user, which improves the system spectrum efficiency and energy efficiency. In order to select the best AP set for each user, a dynamic access point selection algorithm based on Back Propagation (BP) neural network is proposed. The large-scale fading vector between the AP and the user is used as the input, and the connection relationship between the AP and the user is taken as the prediction vector of the output of BP neural network. At the same time, an improved adaptive genetic algorithm is proposed for the initial weight of BP neural network to improve the convergence speed and convergence performance. Simulations show that the predicted result of the improved BP neural network is closer to the actual value, and it has higher system sum rate than fully connected and heuristic AP selection schemes.

Key words: cell-free massive MIMO; access point selection; genetic algorithm; BP neural network

* 收稿日期:2022-11-29;修回日期:2023-01-17
基金项目:国家科技重大专项 (2018ZX03001026-002)
通信作者:裘德市 Email:1435090518@qq.com

0 引言

无蜂窝大规模多输入多输出 (Multiple-Input Multiple-Output, MIMO) 系统是文献[1]中引入的一个新概念,大量地理分布的接入点 (Access Point, AP) 为少量用户 (User Equipment, UE) 共同提供服务。每个 AP 通过前传链路连接到中央处理单元 (Central Processing Unit, CPU),该单元主要用于信号处理。在传统蜂窝网络中小区边缘用户会受到邻近小区的干扰,而无蜂窝大规模 MIMO 系统通过消除蜂窝边界抑制小区间干扰,因此无蜂窝大规模 MIMO 系统可以为其覆盖范围的用户提供统一的服务质量。

该系统早期的设想是所有 AP 都为每个 UE 提供服务,然而这会增加 CPU 信号处理的计算复杂度和前传链路的负载,随着 AP 和 UE 数量的增加,使系统的可扩展性大大降低,难以实际实现。为了解决这个问题,文献[2]提出了一种以“用户为中心”的无蜂窝大规模 MIMO 系统,该系统中的每个 UE 由一组具有最佳信道条件的 AP 子集提供服务,不仅大大降低了前传链路的压力,并且以“用户为中心”的 AP 选择方案,其系统和速率和能量效率均优于全连接方案^[3]。近几年来,许多文献研究了无蜂窝大规模 MIMO 系统 AP 选择算法^[4-8],但是,文献[4]算法主要问题是系统和速率不是最优的;文献[5]算法未考虑每个 AP 服务 UE 的最大数量,当主 AP 服务的 UE 数量较多时,应当选择次优 AP 作为主 AP;文献[6]算法其竞争原则是 AP 优先选择具有最大尺度衰落系数的 UE,若 UE 数量小于等于正交导频的数量时,该算法与全连接方案一致;文献[7]算法通过连续凸优化实现 AP 选择,仿真结果表明具有较好的系统,计算复杂度较高;文献[8]算法在 AP 数量较多时预测准确率有所下降。总之,AP 选择是一个全局优化问题,应当考虑系统和速率、能量效率、用户公平性等其他因素,并且能够在某些动态场景下为 UE 选择最佳的 AP 集合。

反向传播 (Back Propagation, BP) 神经网络是一种按误差反向传播训练的多层前馈网络,其算法称为 BP 算法。该算法的基本思想是梯度下降法,利用梯度搜索技术,使网络的实际输出值和期望输出值的误差均方差为最小。标准 BP 神经网络对初始权重的选取很敏感,可以采用一些启发式的算法 (例如遗传算法) 来初始化权重以提高 BP 神经网络的性能。

遗传算法 (Genetic Algorithm, GA) 是模仿自然

界生物进化机制发展起来的搜索最优解的方法^[9]。标准遗传算法的交叉率和变异率是固定的,这导致其搜索过程迭代慢,容易陷入局部最优。自适应遗传算法 (Adaptive Genetic Algorithm, AGA) 通过自适应改变交叉率和变异率,能够很好地解决这个问题。

本文提出了一种无蜂窝大规模 MIMO 系统 AP 动态选择算法,首先利用改进的自适应遗传算法为每个 UE 选择最佳的 AP,将其作为 BP 神经网络的实际值;然后利用 BP 神经网络为不同地理位置分布的 UE 选择最佳的服务 AP 集合,BP 神经网络的输入为 AP 和 UE 之间的大尺度衰落系数向量,输出为 AP 与 UE 连接关系预测向量,通过该预测向量来为用户选择最佳服务 AP 集合。仿真结果表明,改进的自适应遗传算法较遗传算法收敛速度更快,更不易陷入局部最优,利用改进的自适应遗传优化的 BP 神经网络比未优化权值的 BP 神经网络泛化性能更好。所提的 AP 动态选择算法比全连接和现有的一些 AP 选择算法具有更好的系统和速率。

1 系统模型

如图 1 所示,无蜂窝大规模 MIMO 系统由 M 个 AP 和 K 个 UE 组成,并且 $M \gg K$ 。AP 和 UE 均匀分布在 $(D \times D)$ 区域内,假设所有 AP 和 UE 都配置单天线,所有 AP 通过前传链路链接到 CPU,系统工作在时分双工 (Time Division Duplex, TDD) 模式下,即上下行信道具有互易性。每帧分为上行信道估计、下行数据传输、上行数据传输 3 个阶段。帧长为 τ_c ,上行训练长度为 τ_p ,上行数据传输长度为 τ_u ,下行数据传输长度为 τ_d ,并且满足 $\tau_c = \tau_p + \tau_u + \tau_d$ 。




图 1 无蜂窝大规模 MIMO 系统模型
Fig. 1 Cell-free massive MIMO system model

第 m 个 AP 到第 k 个 UE 之间的信道系数 $\mathbf{g}_{m,k}$ 可表示为

$$\mathbf{g}_{m,k} = \beta_{m,k}^{1/2} \cdot \mathbf{h}_{m,k} \quad (1)$$

式中: $\mathbf{h}_{m,k} \sim \mathcal{CN}(0, 1)$ 为小尺度衰落系数; $\beta_{m,k}$ 为大尺度衰落系数, 包含阴影衰落和路径损耗。路径损耗模型采用三斜率模型^[10]。路径损耗为

$$L_{p_{m,k}} = \begin{cases} -L - 35\lg(d_{m,k}), & \text{if } d_{m,k} > d_1 \\ -L - 15\lg(d_1) - 20\lg(d_{m,k}), & \text{if } d_0 < d_{m,k} \leq d_1 \\ -L - 15\lg(d_1) - 20\lg(d_0), & \text{if } d_{m,k} < d_0 \end{cases} \quad (2)$$

式中: $d_{m,k}$ 表示第 m 个 AP 到第 k 个 UE 的距离; 在该路径损耗模型下, d_1 和 d_0 取值分别为 50 m 和 10 m; L 的表达式为

$$L = 46.3 + 33.9\lg(f) - 13.82\lg(h_{AP}) - (1.1\lg(f) - 0.7)h_{UE} + (1.56\lg(f) - 0.8) \quad (3)$$

式中: f 为载波频率; h_{AP} 为 AP 的高度; h_{UE} 为 UE 的高度。

1.1 信道估计

在上行训练阶段, 所有 UE 同时向 AP 发送长度为 τ_p 的导频序列, 导频向量可表示为

$$\mathbf{y}_{p,m} = \sqrt{\tau_p \rho_p} \sum_{k=1}^K \mathbf{g}_{m,k} \varphi_k + \mathbf{w}_{p,m} \quad (4)$$

式中: ρ_p 为每个导频符号的归一化信噪比; $\mathbf{w}_{p,m}$ 为第 m 个 AP 处的加性噪声向量, 每个元素为服从 $\mathcal{CN}(0, 1)$ 的随机分量; φ_k 为第 k 个 UE 发送的导频序列, 满足 $\sqrt{\tau_p} \varphi_k \in \mathbb{C}^{\tau_p \times 1}$ 。CPU 根据本地导频信号的埃尔米特 (Hermite) 转置与接收到的导频信号相乘以进行信道估计, 表示为

$$\tilde{\mathbf{y}}_{p,m,k} = \sqrt{\tau_p \rho_p} \mathbf{g}_{m,k} + \sqrt{\tau_p \rho_p} \sum_{k' \neq k}^K \mathbf{g}_{m,k'} \varphi_{k'}^H \varphi_k + \varphi_k^H \mathbf{w}_{p,m} \quad (5)$$

信道 $\mathbf{g}_{m,k}$ 的最小均方误差估计量 (Minimum Mean Square Error, MMSE) $\hat{\mathbf{g}}_{m,k}$ 为

$$\hat{\mathbf{g}}_{m,k} = \frac{\mathbb{E}\{\tilde{\mathbf{y}}_{p,m,k}^H \mathbf{g}_{m,k}\}}{\mathbb{E}\{|\tilde{\mathbf{y}}_{p,m,k}|^2\}} \tilde{\mathbf{y}}_{p,m,k} = \gamma_{m,k} \tilde{\mathbf{y}}_{p,m,k} \quad (6)$$

$$\gamma_{m,k} = \frac{\sqrt{\tau_p \rho_p} \beta_{m,k}}{\tau_p \rho_p \sum_{k'=1}^K \beta_{m,k'} |\varphi_k^H \varphi_{k'}|^2 + 1} \quad (7)$$

1.2 上行数据传输

在上行传输阶段, 假设 UE 向所有 AP 发送载波数据符号 x_k (满足 $\mathbb{E}\{|x_k|\} = 1$), 功率控制系数为 η_k (满足 $0 \leq \eta_k \leq 1$), 则第 m 个 AP 接收到的信号为

$$y_{u,m} = \sqrt{\rho_u} \sum_{k=1}^K \mathbf{g}_{m,k} \sqrt{\eta_k} x_k + w_{u,m} \quad (8)$$

为了解调第 k 个 UE 发送的符号数据, 第 m 个 AP 将信道估计的共轭 $\hat{\mathbf{g}}_{m,k}^*$ 与接收到的信号 $y_{u,m}$ 相乘并通过前传链路发送给 CPU, CPU 接收到的信号为

$$r_{u,k} = \sum_{m=1}^M \hat{\mathbf{g}}_{m,k}^* y_{u,m} = \sum_{k'=1}^K \sum_{m=1}^M \sqrt{\rho_u \eta_{k'}} \hat{\mathbf{g}}_{m,k}^* \cdot \mathbf{g}_{m,k'} x_{k'} + \sum_{m=1}^M \hat{\mathbf{g}}_{m,k}^* \cdot w_{m,k} \quad (9)$$

第 k 个 UE 的上行速率为

$$\begin{cases} R_{u,k} = \lg \left(1 + \frac{\rho_u \eta_k (\sum_{m=1}^M \gamma_{m,k})^2}{A+B} \right) \\ A = \rho_u \sum_{k' \neq k}^K \eta_{k'} \left(\sum_{m=1}^M \gamma_{m,k} \frac{\beta_{m,k'}}{\beta_{m,k}} \right)^2 |\varphi_k^H \varphi_{k'}|^2 \\ B = \rho_u \sum_{k'=1}^K \eta_{k'} \sum_{m=1}^M \gamma_{m,k} \beta_{m,k'} + \sum_{m=1}^M \gamma_{m,k} \end{cases} \quad (10)$$

1.3 AP 动态选择问题

文献[11]提出了一种无蜂窝大规模 MIMO 系统动态协作分簇 (Dynamic Cooperation Cluster, DCC) 的概念, 即 UE 由 AP 的子集 M_k 提供服务, 该子集可根据时变特征 (例如 UE 移动性、信道时变特征) 进行改变。如果全部考虑这些时变特征, 算法复杂度较高, 并且实现困难, 所以本文只考虑在 AP 和 UE 位置随机分布的动态场景下, 为 UE 选择最佳的服务 AP 子集。AP 与 UE 的连接关系可由矩阵 $\mathbf{D} \in \mathbb{C}^{M \times K}$ 表示:

$$D_{m,k} = \begin{cases} 1, & m \in M_k \\ 0, & m \notin M_k \end{cases} \quad (11)$$

当 $D_{m,k} = 1$, 表示 UE 和 AP 存在连接。当为全连接方案时, $\mathbf{D}$ 为单位矩阵。

在上行数据传输阶段, 通过 AP 动态选择后, 只有部分 AP 向 CPU 传输数据, 减轻了前传链路数据传输和 CPU 信号处理的压力。将式 (11) 代入到式 (10), 可知在 AP 动态选择情况下, 第 k 个 UE 的上行速率表达式为

$$\begin{cases} R'_{u,k} = \lg \left(1 + \frac{\rho_u \eta_k (\sum_{m=1}^M \gamma_{m,k} D_{m,k})^2}{C+D} \right) \\ C = \rho_u \sum_{k' \neq k}^K \eta_{k'} \left(\sum_{m=1}^M \gamma_{m,k} D_{m,k} \frac{\beta_{m,k'}}{\beta_{m,k}} \right)^2 |\varphi_k^H \varphi_{k'}|^2 \\ D = \rho_u \sum_{k'=1}^K \eta_{k'} \sum_{m=1}^M \gamma_{m,k} D_{m,k} \beta_{m,k'} + \sum_{m=1}^M \gamma_{m,k} D_{m,k} \end{cases} \quad (12)$$

系统的上行和速率为

$$R_{\text{sum}} = \sum_{k=1}^K R'_{u,k} \quad (13)$$

为了最大化系统上行和速率,则优化问题可以建模为

$$\begin{aligned} \max_{\boldsymbol{D}} \quad & R_{\text{sum}} \\ \text{s. t.} \quad & D_{m,k} \in \{0,1\} \\ & \sum_{m=1}^M D_{m,k} \leq N, \forall k \in \{1,2,\cdots,K\} \end{aligned} \quad (14)$$

式中: N 为每个 AP 可服务的最大 UE 数量。

2 AP 动态选择算法

为了解决 AP 和 UE 随机分布动态场景下的 AP 选择问题,本文设计了一个基于 BP 神经网络的预测模型(图 2),根据 AP 与 UE 之间的大尺度衰落系数来预测 AP 与 UE 的连接关系从而最大化无蜂窝大规模 MIMO 系统的上行和速率。如图 2 所示,该模型由输入层、隐藏层、输出层组成,通过反向传播调节网络的权重和阈值来最小化均方误差^[12]。




图 2 BP 神经网络模型
Fig. 2 BP neural network model

2.1 数据预处理

在无蜂窝大规模 MIMO 系统中,由式(2)可知,AP 与 UE 间的大尺度衰落决定了信号的传输质量,也就是说在一定程度上能够反映 AP 与 UE 间的连接关系,因此可将 AP 与 UE 的大尺度衰落矩阵向量作为模型的输入。根据式(2)可知,大尺度衰落系数和距离成正比,会出现较大或较小的值,如果采用标准归一化,会导致部分归一化后的数据接近于 0,影响 BP 神经网络的泛化能力(实际仿真也表明采用标准归一化的神经网络的泛化性能比采用标准差归一化的神经网络的泛化性能差),所以利用标准差对输入数据进行归一化处理:

$$X = \frac{\beta_{m,k} - \mu}{\sigma} \quad (15)$$

式中: μ 为输入数据的均值; σ 为输入数据的方差。

BP 神经网络输出层的激活函数采用 sigmoid 函

数,误差函数为均方误差函数(Mean Square Error, MSE):

$$f(x) = \frac{1}{1 + e^{-x}} \quad (16)$$

$$\text{MSE}(y, y_{\text{true}}) = \frac{\sum_{i=1}^n (y - y_{\text{true}})^2}{n} \quad (17)$$

式中: y 为 BP 神经网络的输出; y_{true} 为真实值。这两个向量转换为矩阵之后,都可以表示 AP 与 UE 的连接关系矩阵 $\boldsymbol{D}$ 。由式(17)可知,系统上行和速率优化问题是一个多维离散优化问题,求解难度较高。为了获得真实值,本文提出了一种改进的自适应遗传算法,简称为 AGA 算法。该算法由种群初始化、计算适应度、选择、交叉、变异、产生下一代种群、交叉率和变异率自适应调整交叉率和变异率等步骤组成,主要对交叉、变异、自适应调整交叉率和变异率等步骤进行了改进。由于种群中的个体采用了二进制编码,在算法迭代后期可能存在大量相似的个体,导致交叉和变异操作无效,容易陷入局部最优,于是本文对交叉和变异操作后的结果进行判断以决定是否需要重新交叉或重新变异。同时本文利用对数函数的性质来自适应改变交叉率和变异率,以提升算法的收敛速度,并且防止陷入局部最优。算法流程如图 3 所示。




图 3 改进的自适应遗传算法流程
Fig. 3 Improved AGA algorithm flow

算法具体步骤如下:
步骤 1 种群初始化:种群中的每个个体为 AP 和 UE 之间的连接矩阵 $\boldsymbol{D}$,初始种群为 $\Omega = \{\boldsymbol{D}_1, \boldsymbol{D}_2,$

$\cdots, D_{NP}\}$, NP 为种群的数量。每个个体中的元素随机生成,并且需要满足每列元素不全为 0。

步骤 2 计算适应度:适应度为无蜂窝大规模 MIMO 系统的上行和速率。

步骤 3 选择:采用轮盘赌方法选择 $\frac{NP}{2}$ 数量的个体,并且复制这些个体用于交叉和变异操作。

步骤 4 交叉:交换两个个体相同位置的子矩阵。因为矩阵中的元素取值只有 0 和 1,在迭代后期,可能存在许多相似的个体,所以在交叉操作之前,需要判断两个个体的子矩阵是否相同,相同则重新交叉。

步骤 5 变异:随机选择个体矩阵中的一个元素,如果其值为 0,则改变值为 1;如果其值为 1,改变其值为 0。为了确保个体向最优的方向变异,计算变异后的个体适应度。如果变异后的个体适应度大于变异前的个体适应度,则认为本次变异有效,否则重新变异。

步骤 6 产生下一代种群:将交叉和变异后的 $\frac{NP}{2}$ 个个体与轮盘赌方法选取的 $\frac{NP}{2}$ 个个体组成一个种群。

步骤 7 自适应调整变异率和交叉率:本文利用对数函数的性质来自适应改变交叉率和变异率,表达式为

$$\text{CrossRate} = 0.9 - \text{lb}(1 + \text{IterN} / \text{IterSum}) \times 0.9 \quad (18)$$

$$\text{VariationRate} = 0.1 + \text{lb}(1 + \text{IterN} / \text{IterSum}) \times 0.9 \quad (19)$$

式中:CrossRate 和 VariationRate 表示交叉率和变异率,初始值为 0.9 和 0.1;IterN 和 IterSum 表示当前迭代次数和总迭代次数。随着迭代次数的增加,交叉率逐渐减小,变异率逐渐增大。在迭代初期,交叉率较大,利于全局搜索最优解。在迭代后期,变异率较大,不易陷入局部最优。

BP 神经网络的初始权重对网络的训练效果影响很大,随机初始化权重往往训练效果不是最佳,所以为了提高模型训练的效果,本文利用所提的改进自适应遗传算法优化 BP 神经网络的初始权重,此时每个个体为 BP 神经网络的权值,适应度函数为 BP 神经网络的均方误差,其余步骤与上述类似,不再赘述。

2.2 基于 AGA-BP 神经网络的 AP 动态选择算法

当 BP 神经网络训练完成后,可以代入测试输入数据。BP 神经网络输出值的取值范围为 $[0, 1]$,而 AP 与 UE 的连接矩阵 D 元素取值为 0 或 1,所以为了得到预测输出值,需要进行转换,表达式为

$$y_{\text{predict}} = \begin{cases} 1, & y \geq 0.5 \\ 0, & y < 0.5 \end{cases} \quad (20)$$

此时预测输出值可以表示 AP 与 UE 之间的连接关系,代入式 (13),便可以得到在预测情况下的系统上行和速率。

综上所述,本文提出的基于 AGA-BP 神经网络的 AP 动态选择算法如图 4 所示,具体步骤如下:

1) 训练阶段

步骤 1 在设定的仿真环境下,随机生成不同 AP 与 UE 分布位置下的大尺度衰落系数数据,将其归一化后作为 BP 神经网络的输入。

步骤 2 使用改进的自适应遗传算法获取 BP 神经网络的初始权值,使用改进的自适应遗传算法为 UE 选择最佳 AP 以作为 BP 神经网络的实际值。

步骤 3 训练 BP 神经网络。

2) 预测阶段

步骤 1 输入归一化后的大尺度衰落数据,BP 神经网络输出值并进行转换得到 AP 与 UE 的连接关系矩阵 D 。

步骤 2 UE 根据连接关系矩阵 D 为 UE 选择服务的 AP。




图 4 基于 AGA-BP 神经网络的 AP 动态选择示意

Fig. 4 Schematic of AP dynamic selection based on AGA-BP neural network

3 仿真结果及分析

通过利用蒙特卡罗仿真对所设计的 AP 选择算法进行分析。考虑一个 1 km×1 km 的无蜂窝大规模 MIMO 通信区域,AP 和 UE 的位置随机均匀分布在该区域。利用环绕技术模拟无限大的通信区域,以消除边界的影响。BP 神经网络的输入层大小为 $M \times K$,隐藏层大小为 $2 \times M \times K + 1$,输出层大小为 $M \times K$ 。训练数据为 20 000 个输入值和实际值,训练数据和验证数据分别占总数据的 80% 和 20%,测试数据为单独生成的 1 000 个输入值与实际值。主要仿真参数如表 1 所列。

表 1 仿真参数	
Tab. 1 Simulation parameters	
参数	数值
M	30
K	10
带宽/MHz	20
正交导频数量 τ_p	5

图 5 给出了当 $M=30, K=10$ 时,GA 算法和本文提出的改进自适应遗传算法(简称为 AGA 算法)的最大适应度的变化曲线,最大适应度为系统上行和速率。从图中可以看出,GA 算法刚开始时的最大适应度增长较快,之后增长缓慢,可能陷入了局部最优。AGA 算法在前一半的迭代过程最大适应度都增长较快,后期收敛。迭代结束后,AGA 算法的最大适应度比 GA 算法大。这表明所提的 AGA 算法比 GA 算法收敛更快,不易陷入局部最优。




图 5 GA 算法和 AGA 算法的最大适应度随迭代次数的变化曲线

Fig. 5 The maximum fitness curve of GA algorithm and AGA algorithm varying with the number of iterations

图 6 给出了 AGA-BP 神经网络训练过程中训练集、验证集、测试集的误差变化曲线,可以看出随着训练次数的增加,训练集、验证集、测试集的误差慢慢降低,在训练到第 988 次时收敛。测试集和验证

集的误差曲线基本重合,并且与训练集的误差曲线十分接近。这表明 BP 神经网络参数设置较为合理,训练效果较好,神经网络的泛化性能较好。




图 6 AGA-BP 神经网络训练的误差曲线

Fig. 6 The error curve of AGA-BP neural network training

图 7 给出了在相同神经网络参数设置,相同输入数据、测试数据、实际数据等条件下,连续训练 5 次神经网络,AGA-BP 神经网络与 BP 神经网络的平均训练误差对比图。从图中可以看出,经过 AGA 算法初始化权重之后,神经网络的平均误差更小,AGA-BP 神经网络的性能比 BP 神经网络好。




图 7 AGA-BP 神经网络与 BP 神经网络的平均训练误差曲线

Fig. 7 Average training error curve of AGA-BP neural network and BP neural network

图 8 给出了当 $M=30, K=10$ 时,所提出的 AP 动态选择算法与其他 AP 选择算法的上行用户速率累计分布图。从图中可以看出,两种 AP 选择方案的性能比较接近,但是可扩展性方案实际使用到的 AP 数量小于全连接方案,这表明少量的 AP 也能为 UE 提供较好的服务质量。由于 BP 神经网络拟合的不完全性,动态选择方案相比较于其实际值所代表的 AGA 算法方案性能稍差,但是优于竞争方案和可扩展性方案。联合功率分配的 AP 选择方案由于其相比较与其他方案进行了功率分配,降低了 UE 间的干扰,理论上性能是最优的。实际仿真结果也

表明该方案优于其他方案,但是其计算复杂度较高,不利于实际实现;当 UE 位置发生移动后,需要重新求解凸优化的解,算法的动态适应性较低。本文所提的动态选择方案,只需输入 AP 和 UE 的大尺度算法系数,通过预先训练好的 BP 神经网络便可为 UE 选择合适的 AP,算法的动态适应性较好。




图 8 不同 AP 选择方案的上行用户速率累计分布
Fig. 8 Cumulative distribution of uplink spectrum efficiency of user equipment with different AP selection schemes

4 结束语

本文针对无蜂窝大规模 MIMO 系统中的 AP 选择问题,提出了一种基于 BP 神经网络的 AP 动态选择算法。首先,利用自适应遗传算法为每个 UE 选择最佳的服务 AP 集合以最大化系统上行和速率。针对 AP 和 UE 随机分布的动态场景,利用 BP 神经网络来预测 AP 与 UE 之间的连接关系。BP 神经网络的输入为 AP 与 UE 之间的大尺度衰落向量,输出为 AP 与 UE 之间连接关系的预测向量,并将自适应遗传算法的 AP 选择结果作为实际值。仿真结果表明,所提的自适应遗传算法比传统的遗传算法收敛更快,且不易陷入局部最优。BP 神经网络的预测效果接近于自适应遗传算法的性能,且优于现有的一些启发式算法和全连接的方案,提升了系统的上行和速率。

在后续工作中,我们将进一步研究 AP 选择和功率控制的联合优化问题,进一步提升系统的能量效率。

参考文献:

[1] NGO H Q, ASHIKHMIN A, YANG H, et al. Cell-free massive MIMO: uniformly great service for everyone [C]//Proceedings of 2015 IEEE 16th International Workshop on Signal Processing Advances in Wireless Communications. Stockholm: IEEE, 2015: 201–205.
[2] BUZZI S, D’ ANDREA C. Cell-free massive MIMO: user-

centric approach [J]. IEEE Wireless Communications Letters, 2017, 6(6): 706–709.
[3] MENDOZA C F, SCHWARZ S, RUPP M. Cluster formation in scalable cell-free massive MIMO networks [C]//Proceedings of 2020 16th International Conference on Wireless and Mobile Computing, Networking and Communications. Thessaloniki: IEEE, 2020: 62–67.
[4] GARCIA-MORALES J, FEMENIAS G, RIERA-PALOU F. Energy-efficient access-point sleep-mode techniques for cell-free mmWave massive MIMO networks with non-uniform spatial traffic density [J]. IEEE Access, 2020, 8: 137587–137605.
[5] BJÖRNSON E, SANGUINETTI L. Scalable cell-free massive MIMO systems [J]. IEEE Transactions on Communications, 2020, 68(7): 4247–4261.
[6] CHEN S, ZHANG J, BJÖRNSON E, et al. Structured massive access for scalable cell-free massive MIMO systems [J]. IEEE Journal on Selected Areas in Communications, 2020, 39(4): 1086–1100.
[7] VU T X, CHATZINOTAS S, SHAHBAZPANAHI S, et al. Joint power allocation and access point selection for cell-free massive MIMO [C]//Proceedings of 2020 IEEE International Conference on Communications. Dublin: IEEE, 2020: 1–6.
[8] RANASINGHE V, RAJATHEVA N, LATVA-AHO M. Graph neural network based access point selection for cell-free massive MIMO systems [C]//Proceedings of 2021 IEEE Global Communications Conference. Madrid: IEEE, 2021: 1–6.
[9] 申敏, 石晓枫, 何云. 基于遗传算法的毫米波大规模 MIMO 系统混合预编码 [J]. 电讯技术, 2019, 59(5): 501–506.
[10] NGO H Q, ASHIKHMIN A, YANG H, et al. Cell-free massive MIMO versus small cells [J]. IEEE Transactions on Wireless Communications, 2017, 16(3): 1834–1850.
[11] DEMIR Ö T, BJÖRNSON E, SANGUINETTI L. Foundations of user-centric cell-free massive MIMO [J]. Foundations and Trends in Signal Processing, 2021, 14(3/4): 162–472.
[12] ZHAO B, WU T, FANG F, et al. Prediction method of 5G high-load cellular based on BP neural network [C]//Proceedings of 2022 8th International Conference on Mechatronics and Robotics Engineering. Munich: IEEE, 2022: 148–151.

作者简介:

申 敏 女, 1963 年生于贵州遵义, 1992 年于北京邮电学院获硕士学位, 现为教授、博士生导师, 主要研究方向为新一代移动通信系统、通信核心芯片、协议与系统应用技术。
裘德市 男, 1998 年生于江西南昌, 硕士研究生, 主要研究方向为新一代移动通信技术。