

# An Adaptive MIMO Receiver Based on Neural Network with Interference Recognition

Yingzhu Zhao\*, Yushu Zhang, Hongwen Yang

Beijing University of Posts and Telecommunications, Beijing  
Email: \*zhaoyingzhu@bupt.edu.cn

Received: Aug. 4<sup>th</sup>, 2019; accepted: Aug. 23<sup>rd</sup>, 2019; published: Aug. 30<sup>th</sup>, 2019

---

## Abstract

For Multiple Input Multiple Output (MIMO) system, the increasing demand for large amount of data has motivated researchers to pursue novel techniques to reduce decoding computational complexity while ensuring accuracy. In this paper, we study the application of machine learning for proposing an adaptive interference aware receiver. For typical MIMO receivers, Interference Rejection Combining (IRC) provides better performance with regard to interference rejection, but its computational complexity is higher than Maximum Ratio Combining (MRC). Considering the tradeoff between performance and computational complexity, we propose a neural network based adaptive receiver, which can switch between MRC and IRC adaptively according to the channel condition. In our proposed receiver, the extracted features from interference covariance matrix and corresponding class label through performance analysis are used to train the neural network. Then the receiver can recognize interference level and select the appropriate receiver automatically. Simulation results demonstrate that our proposed receiver achieves higher classification accuracy, lower computational complexity and the similar performance as IRC.

## Keywords

Adaptive Receiver, MIMO, Neural Network, Interference Recognition

---

# 一种具有干扰识别功能的基于神经网络的自适应MIMO接收机

赵映竹\*, 张羽书, 杨鸿文

北京邮电大学, 北京  
Email: \*zhaoyingzhu@bupt.edu.cn

收稿日期: 2019年8月4日; 录用日期: 2019年8月23日; 发布日期: 2019年8月30日

\*通讯作者。

## 摘要

对于多输入多输出(MIMO)系统,对数据量增长的需求促使科研者提出可以减少解码计算量并且保证接收准确性的新型技术。本文研究了基于机器学习的应用以提出一种自适应的干扰感知接收机。对于典型的接收机,干扰抑制合并(IRC)因其可以抑制干扰而能提供更好的性能,但其复杂度要高于最大比合并(MRC)。考虑到性能和计算复杂度的折中,本文提出了一种基于神经网络的自适应接收机,其可以根据信道状态在MRC和IRC间自适应切换。在本文提出的接收机中,从干扰相关矩阵中提取的特征及通过性能分析计算相应的标签用于训练神经网络。该接收机可以自动识别干扰等级并且选择合适的接收机。仿真表明本文提出的接收机可以实现更高的分类准确性,更低的计算复杂度及同IRC相近的性能。

## 关键词

自适应接收机, MIMO, 神经网络, 干扰识别

Copyright © 2019 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

对于无线通信系统,高速率和低失真已经成为基本的要求。多输入多输出(MIMO)系统可以提升系统容量并且正交频分复用(OFDM)技术可以抵抗多径衰落,因此 MIMO-OFDM 的结合已经得到广泛的应用 [1] [2]。

在实际的 MIMO-OFDM 系统中,由于存在衰落,干扰及噪声使得接收端收到的信号受到很大影响。因此采取有效的信道均衡技术来抑制干扰并提升 MIMO-OFDM 系统性能是很有必要的。非线性接收机可以提供优秀的性能但其计算复杂度过大将增加接收机所需功率损耗及处理时间。相比于非线性接收机,线性接收机可以提供较好的性能并且其复杂度较低。一些典型的线性接收机如最大比合并(MRC) [3] [4] 和干扰抑制合并(IRC) [5] [6]得到较广泛的应用。IRC 因其可以抑制干扰可以提供更好的性能,因此更适用于干扰较大的场景。同 IRC 相比, MRC 更容易实施且计算复杂度较低,但其不能有效抑制干扰,因此更适用于干扰较小的场景。

尤其在 5G 场景下,干扰热噪声等级(Interference over Thermal noise, IoT)由于波束赋形而变化很快,因此如何在信道条件不同且多变的条件下选择合适的接收机是一个急需解决的问题。A. M. Kuzminskiy 提出了一种基于期望似然准则的硬切换方法,但其复杂度过大并且性能有限,尤其是在天线数目较大的情况 [7]。[8]中提供一种自适应干扰意识接收机,但其门限值难以确定且自适应能力较差。近些年,随着机器学习的快速发展,其与传统通信的结合为许多问题带来了更好的解决方案 [9] [10]。

基于上述本文提出了一种基于神经网络的自适应干扰感知接收机。考虑到性能和计算复杂度的折中,该接收机可以随着信道条件变化在 MRC 和 IRC 间自动地切换。我们提出了三种特征提取方法从干扰相关矩阵中提取所需特征。基于样本传输数据的训练,分类特性可以被神经网络学习并且应用于干扰识别以及接收机判决。此外,子载波组内信道相似性的应用可以进一步减小计算复杂度。仿真结果表明本文提出的自适应干扰感知接收机可以实现接收机分类高准确性,低复杂度及同 IRC 相似的性能。

## 2. 系统模型

### 2.1. MIMO 通信系统模型

本文中MIMO系统包括主基站及 $L$ 个干扰基站,发射端有 $N_T$ 根发射天线,用户端有 $N_R$ 根接收天线。不失一般性,将主基站记为0,来自 $L$ 个干扰基站的信号构成对用户的干扰,因此接收信号可以如下表示:

$$\mathbf{y}_k = \sqrt{\rho_0} \mathbf{H}_{0,k} \mathbf{p}_{0,k} x_{0,k} + \sum_{i=1}^L \sqrt{\rho_i} \mathbf{H}_{i,k} \mathbf{p}_{i,k} x_{i,k} + \mathbf{n}_k \quad (1)$$

上述信道模型中 $k$ 为子载波编号, $k \in \{1, 2, \dots, N_{sc}\}$ ,其中 $N_{sc}$ 为子载波总数。 $\mathbf{y}_k \in \mathbb{C}^{N_R \times 1}$ 为用户接收信号。 $\rho_0$ 和 $\rho_i$ 表示主基站和干扰基站的发送功率。 $\mathbf{H}_{0,k} \in \mathbb{C}^{N_R \times N_T}$ 及 $\mathbf{H}_{i,k} \in \mathbb{C}^{N_R \times N_T}$ 分别表示用户和主基站间及用户和第 $i$ 个干扰基站间的信道矩阵。信道矩阵每个元素服从独立的高斯分布,均值为0,方差为1。 $\mathbf{p}_{0,k} \in \mathbb{C}^{N_T \times 1}$ 和 $\mathbf{p}_{i,k} \in \mathbb{C}^{N_T \times 1}$ 为预编码向量。 $x_{0,k}$ 代表发送数据符号, $x_{i,k}$ 代表干扰数据符号。不失一般性,假定传输比特星座映射为单位功率的QPSK符号。噪声向量 $\mathbf{n}_k \in \mathbb{C}^{N_R \times 1}$ 服从均值为0,方差为 $\sigma^2$ 的高斯分布。

预编码向量 $\mathbf{p}_{0,k}$ 利用信道矩阵 $\mathbf{H}_{0,k}$ 奇异值分解(SVD)求得。 $\mathbf{H}_{0,k} = \mathbf{U}_k \mathbf{\Lambda}_k \mathbf{V}_k^H$ 表示信道矩阵的SVD分解,其中 $\mathbf{U}_k \in \mathbb{C}^{N_R \times N_R}$ 和 $\mathbf{V}_k \in \mathbb{C}^{N_T \times N_T}$ 为酉矩阵, $\mathbf{\Lambda}_k$ 为对角矩阵,即 $\mathbf{\Lambda}_k = \text{diag}(\lambda_{k,1}, \dots, \lambda_{k,q})$ ,其中 $q$ 为信道矩阵 $\mathbf{H}_{0,k}$ 的秩。不失一般性,本文取 $\mathbf{V}_k$ 矩阵的第一列作为预编码向量 $\mathbf{p}_{0,k}$ ,多层时对应取 $\mathbf{V}_k$ 矩阵的列向量即可。

为了简化表达,定义等效信道变量表示如下:

$$\mathbf{g}_{i,k} = \sqrt{\rho_i} \mathbf{H}_{i,k} \mathbf{p}_{i,k}, i = 0, 1, \dots, L \quad (2)$$

为了恢复目标信号,在用户端使用MRC/IRC接收机检测接收信号并恢复目标信号。检测过程可以描述为接收信号与接收机加权向量 $\mathbf{w}_k \in \mathbb{C}^{1 \times N_R}$ 相乘恢复出目标信号,公式形式表示如下:

$$\tilde{x}_k = \mathbf{w}_k \mathbf{y}_k = \mathbf{w}_k \left( \mathbf{g}_{0,k} x_{0,k} + \sum_{i=1}^L \mathbf{g}_{i,k} x_{i,k} + \mathbf{n}_k \right) \quad (3)$$

### 2.2. MRC 接收机

MRC是一种常见信号合并方法,按照各接收天线上的信号强度进行合并,信噪比越大,加权系数越大,导致对合并后的信号贡献越大,接收端加权向量可以如下表示:

$$\mathbf{w}_k = \mathbf{g}_{0,k}^H \quad (4)$$

经用户端MRC接收机处理后,其信干噪比(SINR)可表示为:

$$\gamma_k^{MRC} = \frac{\mathbf{g}_{0,k}^H \mathbf{g}_{0,k}}{\sum_{i=1}^L |\mathbf{g}_{0,k}^H \mathbf{g}_{i,k}|^2 / \mathbf{g}_{0,k}^H \mathbf{g}_{0,k} + \sigma^2} \quad (5)$$

### 2.3. IRC 接收机

若式(5)中分母的干扰项为0,则MRC接收机可以得到最大化信噪比(SNR)。若其干扰项不为0,IRC接收机可以最大化SINR,其加权向量可以表示如下:

$$\mathbf{w}_k = \mathbf{g}_{0,k}^H \left( \mathbf{g}_{0,k} \mathbf{g}_{0,k}^H + \mathbf{R}_k \right)^{-1} \quad (6)$$

其中  $\mathbf{R}_k = \mathbf{E}[\mathbf{s}_k \mathbf{s}_k^H] = \sum_{i=1}^L \mathbf{g}_{i,k} \mathbf{g}_{i,k}^H + \sigma^2 \mathbf{I}_{N_R}$  定义为干扰相关矩阵,  $\mathbf{s}_k = \sum_{i=1}^L \mathbf{g}_{i,k} x_{i,k} + \mathbf{n}_k$  为干扰加噪声向量。

同样, 经用户端 IRC 接收机处理后的信干噪比(SINR)可表示为:

$$\gamma_k^{IRC} = \mathbf{g}_{0,k}^H \mathbf{F}_k (\mathbf{F}_k^H \mathbf{R}_k \mathbf{F}_k)^{-1} \mathbf{F}_k^H \mathbf{g}_{0,k} \quad (7)$$

其中  $\mathbf{F}_k^H$  可表示为:

$$\mathbf{F}_k^H = \mathbf{H}_{0,k}^H \boldsymbol{\Sigma}_{y_k}^{-1} \quad (8)$$

其中  $\boldsymbol{\Sigma}_{y_k} = \mathbf{g}_{0,k} \mathbf{g}_{0,k}^H + \mathbf{R}_k$ 。

### 3. 基于神经网络的检测方案

接收机类型判决可以首先基于传统的数据信号处理算法, 需要预先提取足够的干扰相关信息。然而在很多情况下(例如干扰来自未与服务小区同步的其他小区), 无法预先提取到足够信息来进行干扰判决, 这种情况下传统的检测方案无法工作或性能很差。因此亟需一些其他的解决方案。在这种情况下, 基于神经网络的自适应接收机可以取得很好的性能, 神经网络可以从干扰相关矩阵中提取到足够的信息来进行干扰识别从而进行接收机判决。

#### 3.1. 特征提取

采用一个包含  $T$  个训练样本的训练集去训练神经网络, 该训练集可以记为  $\{\mathbf{u}^t, \mathbf{w}^t\}_{t=1}^T$ , 其中  $\mathbf{u}^t$  和  $\mathbf{w}^t$  分别表示第  $t$  个训练样本的特征集和标签集, 其中  $t \in \{1, 2, \dots, T\}$ 。

特征集需要从对通信性能有影响的信息中提取。干扰相关矩阵在不同 IoT 等级场景下包含不同特性, 因此可以用于提取特征以用于训练神经网络模型。基于此, 集合  $\mathbf{u}^t$  可从干扰相关矩阵中提取, 特征提取过程可以表示如下:

$$\mathbf{R}_k^t = \begin{bmatrix} r_{1,1,k}^t & r_{1,2,k}^t & \cdots & r_{1,N_R,k}^t \\ r_{2,1,k}^t & r_{2,2,k}^t & \cdots & r_{2,N_R,k}^t \\ \vdots & \vdots & \ddots & \vdots \\ r_{N_R,1,k}^t & r_{N_R,2,k}^t & \cdots & r_{N_R,N_R,k}^t \end{bmatrix} \quad (9)$$

其中  $\mathbf{R}_k^t$  代表第  $t$  个训练样本中第  $k$  个子载波上的干扰相关矩阵。为实现有效的特征提取, 基于  $\mathbf{R}_k^t \in \mathbb{C}^{N_R \times N_R}$ , 我们提出了三种特征提取方法, 可以如下表示:

方法 1:

$$\mathbf{u}^t = \left[ |r_{1,1,k}^t|, \dots, |r_{N_R,1,k}^t|, |r_{1,2,k}^t|, \dots, |r_{N_R,2,k}^t|, |r_{1,N_R,k}^t|, \dots, |r_{N_R,N_R,k}^t| \right] \quad (10)$$

方法 2:

$$\mathbf{u}^t = \left[ r_{1,1,k}^t, \dots, r_{N_R,1,k}^t, r_{2,2,k}^t, \dots, r_{N_R,2,k}^t, r_{3,3,k}^t, \dots, r_{N_R,3,k}^t, \dots, r_{N_R,N_R,k}^t \right] \quad (11)$$

方法 3:

$$\mathbf{u}^t = \left[ r_{1,1,k}^t, r_{2,2,k}^t, \dots, r_{N_R,N_R,k}^t \right] \quad (12)$$

方法 1 中,  $\mathbf{u}^t \in \mathbb{C}^{1 \times N_R^2}$ 。对于干扰相关矩阵  $\mathbf{R}_k^t$  中的每个元素, 其模值可以作为特征来训练神经网络。该特征提取方法可以实现很高的分类准确性。为了简化算法, 可以选取干扰相关矩阵  $\mathbf{R}_k^t$  的子集进行训练。如方法 2 所示, 干扰相关矩阵的主对角线及其以上的元素被选择, 因此  $\mathbf{u}^t \in \mathbb{C}^{1 \times (N_R^2 + N_R)/2}$ 。该方

法同样可以实现很高的准确性。为进一步简化计算复杂度，我们提出了方法3。只选取干扰相关矩阵  $\mathbf{R}_k^i$  主对角线上的元素进行特征提取， $\mathbf{u}^i \in \mathbb{C}^{1 \times N_R}$ ，该方法可以在实现较低的复杂度的同时具有较高的预测准确性。

为了进行信道干扰状态判决，接收端处理后的 SINR 可以作为代价函数。基于该代价函数，标签  $w^i$  可由下式确定：

$$w^i = \begin{cases} w^{MRC}, & \text{if } \gamma^{IRC} - \gamma^{MRC} \leq \Delta \\ w^{IRC}, & \text{otherwise} \end{cases} \quad (13)$$

其中  $\Delta$  为考虑到性能及计算复杂度折中的一个阈值，其可以表征信道干扰和噪声状态。当  $\gamma^{IRC} - \gamma^{MRC} \leq \Delta$  时，说明信道干扰较小，此时应该采用 MRC 接收机，在保证检测性能的同时降低计算复杂度。当  $\gamma^{IRC} - \gamma^{MRC} > \Delta$  时，说明信道干扰较大，此时应该采用 IRC 接收机以获得更好的性能。基于以上过程描述，可得到训练数据集  $\{\mathbf{u}^i, w^i\}_{i=1}^T$  以用于训练神经网络模型。

### 3.2. 基于神经网络的自适应接收机及神经网络训练

该自适应接收机可基于神经网络进行信道干扰状态识别，图1为基于神经网络的自适应接收机的结构图。基于参考信号进行信道估计以得到信道矩阵和干扰相关信息。由此可得到干扰相关矩阵以进行特征提取，同时可基于性能分析进行标签分配，特征和标签构成训练数据集。基于训练集训练后可得到神经网络，学习到的分类特征可应用于未来的干扰识别及接收机判决。

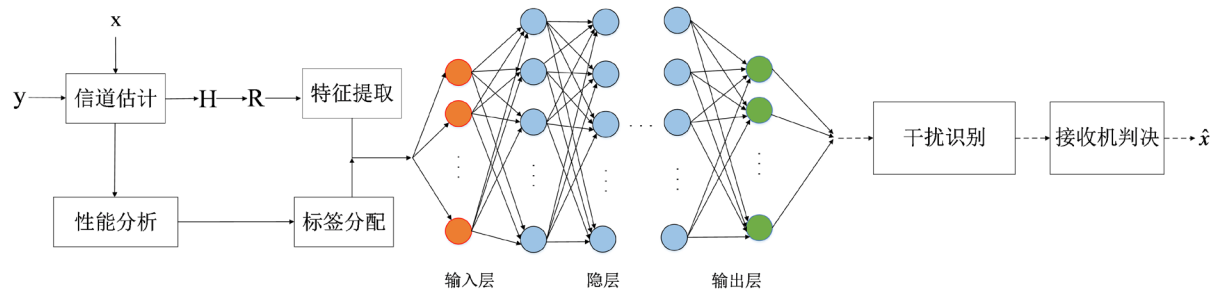


Figure 1. Basic structure of the multi-layer neural network based adaptive receiver

图1. 基于多层神经网络的接收机的基本结构

神经网络的结果可分为输入层，隐层和输出层。每层包含若干节点，其可以从前一层的节点或直接从输入层得到输入信号，并且输出信号到下一层节点或输出层，输入输出关系可表示如下：

$$a_j^{[l]} = f \left( \sum_r w_{jr}^{[l]} a_r^{[l-1]} + b_j^{[l]} \right) \quad (14)$$

其中  $w_{jr}^{[l]}$  表示连接第  $l-1$  层的第  $r$  个节点和第  $l$  层的第  $j$  个节点的权值， $b_j^{[l]}$  表示第  $l$  层的第  $j$  个节点的偏差。 $a_r^{[l-1]}$  表示第  $l-1$  层的第  $r$  个节点的输入信号， $f(x)$  表示激活函数。

在本文中采用多层感知器(Multi-Layer Perceptron, MLP)作为神经网络进行干扰识别，因为其具有非常紧凑的拓扑结构，并且可以在较少的迭代次数中得到训练。本文中应用的神经网络是全连接的，该神经网络包括两个隐层，第一层有 16 个节点，第二层有 8 个节点。隐层的激活函数采用修正线性单元(rectified linear unit, relu)函数，输出层的激活函数采用 Logistic 函数。

此外，为了进一步降低计算复杂度，可将信道变化相似的子载波划分为一个子载波组，从而可以划分为  $M$  个子载波组(如图2所示)。于是可用  $\bar{\mathbf{R}}_m$  代替子载波组中各个子载波的干扰相关矩阵  $\mathbf{R}_k$  进行特征

提取以用于训练神经网络，其中  $k$  属于子载波组  $m$ 。  $\bar{\mathbf{R}}_m$  可由下式表示：

$$\bar{\mathbf{R}}_m = \frac{1}{k_m} \sum_{k=1}^{k_m} \mathbf{R}_k \tag{15}$$

其中  $k_m$  是子载波组  $m$  中的子载波数目。




Figure 2. Structure of  $\bar{\mathbf{R}}_m$  in subcarrier group  $m$ , where  $m \in \{1, 2, \dots, M\}$

图 2. 子载波组  $m$  中  $\bar{\mathbf{R}}_m$  结构，其中  $m \in \{1, 2, \dots, M\}$

因此同一个子载波组中的子载波只需要一次基于神经网络的干扰识别来进行接收机判决，可以大大降低计算复杂度。此外，在神经网络训练中，我们在损失函数中加入正则化项，通过缩小模型参数以防止过拟合现象，可以进一步降低计算复杂度。

为初始化所用的神经网络的权值和偏差，将提取的特征  $\mathbf{u}'$  (如方法 1，方法 2 或方法 3) 和相应的接收机标签  $w'$  输入到神经网络。分类特性可以基于训练数据得以学习，并且可应用于未来的接收判决，该神经网络可由下述算法 1 得到：

**Algorithm 1.** Training method for neural network

**算法 1.** 神经网络训练算法

输入参数：  $T = 10000$ ，  $\Delta = 1$  dB

```

1: for  $t = 1:T$  do
2:   for  $m = 1:M$  do
3:     for  $k = 1:k_m$  do
4:       获取第  $t$  个样例在子载波  $k$  上的干扰相关矩阵  $\mathbf{R}_k^t$ 
5:       根据 (5) 计算使用 MRC 接收时 SINR  $\gamma_k^{MRC}$ 
6:       根据 (7) 计算使用 IRC 接收时 SINR  $\gamma_k^{IRC}$ 
7:     end for
8:     根据 (15) 计算子载波组等效干扰相关矩阵  $\bar{\mathbf{R}}_m^t$ 
9:     根据方法 1，方法 2 或者方法 3 获取特征  $\mathbf{u}_m^t$ 
10:     $\gamma_m^{MRC} = \frac{1}{k_m} \sum_{k=1}^{k_m} \gamma_k^{MRC}$ 
11:     $\gamma_m^{IRC} = \frac{1}{k_m} \sum_{k=1}^{k_m} \gamma_k^{IRC}$ 
12:    if  $\gamma_m^{IRC} - \gamma_m^{MRC} < \Delta$  then
13:       $w_m^t = w^{MRC}$ 
14:    else
15:       $w_m^t = w^{IRC}$ 
16:    end if
17:  end for
18: end for
19: 基于样本  $\{\mathbf{u}_m^t, w_m^t\}_{t=1}^T$  训练神经网络
    
```

### 3.3. 接收机实际应用判决

训练好的神经网络可被存储下来，并在后续的实际场景下执行干扰识别及接收机判决。在每个传输周期内，接收端根据该训练好的神经网络和当前提取到的特征信息得到当前干扰信息并且做出接收机判决，可以有效的随信道状态进行改变，得到很好的性能提升，可以表示为**算法 2**：

**Algorithm 2.** Receiver decision based on neural network

**算法 2.** 基于神经网络的接收机判决

```

1: for  $m = 1:M$  do
2:   根据 (15) 计算子载波组等效干扰相关矩阵  $\bar{\mathbf{R}}_m$ 
3:   根据方法 1, 方法 2 或者方法 3 获取特征  $\mathbf{u}_m$ 
4:   基于神经网络通过  $\mathbf{u}_m$  获得接收机标签  $w_m$ 
5:   if  $w_m = w_m^{MRC}$  then
6:     for  $k = 1:k_m$  do
7:       根据 (4) 计算  $\mathbf{w}_k = \mathbf{w}_k^{MRC}$ 
8:       根据 (3) 恢复信号  $\hat{x}_k$ 
9:     end for
10:  else
11:    for  $k = 1:k_m$  do
12:      根据 (6) 计算  $\mathbf{w}_k = \mathbf{w}_k^{IRC}$ 
13:      根据 (3) 恢复信号  $\hat{x}_k$ 
14:    end for
15:  end if
16: end for

```

### 3.4. 硬判决方案

此外，常见的一种硬判决方法是基于干扰加噪声协方差矩阵的对角加载方法，通过矩阵的迹和非对角线元素和的比值来识别干扰等级，具体公式可由如下表示：

$$\eta = \frac{Tr(\mathbf{R}_k)}{\sum_{n \neq m} |r_{n,m,k}|} \quad (16)$$

其中  $\sum_{n \neq m} |r_{n,m,k}|$  表示干扰相关矩阵的非主对角线上元素的和。基于该比值，接收机的判决可根据以下准则：

$$\mathbf{w}^f = \begin{cases} \mathbf{w}^{MRC}, & \text{if } \eta \leq \theta \\ \mathbf{w}^{IRC}, & \text{if } \eta > \theta \end{cases} \quad (17)$$

其中  $\theta$  是一个与信道状态相关的阈值，可以根据信道条件决定。可以看出不同信道条件下  $\theta$  的最优值显然是不同的，考虑到实际通信系统中信道条件是不断变化的，固定的  $\theta$  值会带来比较明显的性能损失，因此基于神经网络的干扰感知自适应接收机提供了更优的性能。

## 4. 实验仿真与结果分析

本节给出计算仿真示例来验证本文提出算法的性能。仿真场景参数设置如下：信道设置为 9 径，最大时延为 2.51 us，此外  $\Delta = 1$  dB， $L = 1$ ， $\rho_0 = 1$ ，SINR 设置为 -10 dB 到 10 dB，可由此计算出干扰和噪声功率以用于不同场景下的功率分配。为得到充足的训练数据，干扰受限和噪声受限的场景都需要构建。因此，将干扰功率和噪声功率比例设置为  $\alpha_i$  和  $\alpha_n = 1 - \alpha_i$ ，在 50% 的训练数据中，设置  $0 \leq \alpha_i \leq 0.5$ ，同时在另外 50% 的训练数据中，设置  $0.5 < \alpha_i \leq 1$ ，由此不同 IoT 场景因不同的  $\alpha_i$  及  $\alpha_n$  取值得以构建。收发

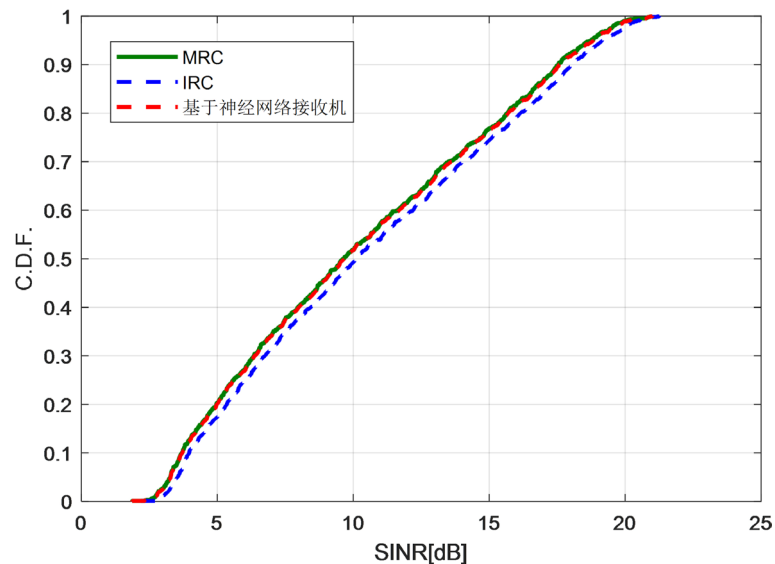
天线分别设置为 8 和 2。不同接收机的性能以接收端处理后的 SINR 作为衡量标准。产生了 20,000 组数据作为训练集及测试集。

**Table 1.** Accuracy of detection type classification based on machine learning and hard switching

**表 1.** 基于机器学习和硬判决方法的检测分类准确性

$\alpha_i$	opt.	方法 1	方法 2	方法 3	硬判决
0		100%	100%	100%	99.9%
0.05		100%	100%	100%	99.3%
0.1		100%	100%	100%	98.5%
0.15		100%	100%	99.9%	95.5%
0.2		100%	100%	99.2%	88.9%
0.25		99.9%	99.6%	99.0%	79.9%
0.3		99.1%	99.8%	97.2%	71.1%
0.35		97.1%	97.5%	93.9%	62.4%
0.4		92.3%	92.6%	89.7%	56.3%
0.45		88.4%	88.9%	85.1%	54.1%
0.5		86.7%	83.2%	82.4%	50.2%

表 1 示出在不同 IoT 等级的仿真场景下,基于机器学习和基于硬判决的接收机检测类型分类准确性。测试集与上述的训练集数据有同样的功率分配的比例结构,因此当  $0.5 < \alpha \leq 1$  时,其检测分类的准确性等于  $1 - \alpha$  ( $0 < \alpha < 0.5$ )。经仿真分析,取  $\theta = 1$ ,此时硬判决方案得到最优性能。从表 1 可以看出,基于机器学习的接收机判决的准确性高于硬判决,尤其是当干扰功率和噪声功率差别较大时更为明显。对于基于神经网络的检测方案,综合分类性能及实施复杂度分析,方法 3 是最佳的方案,其保证了较高的接收机检测准确性并且具有较低的实施复杂度。



**Figure 3.** CDF of SINR performance in low IoT cases

**图 3.** 低 IoT 场景下 SINR 的 CDF






Figure 4. CDF of SINR performance in high IoT cases

图 4. 高 IoT 场景下 SINR 的 CDF

图 3, 图 4 和图 5 示出仿真结果。图中示出基于神经网络的自适应接收机、MRC、IRC 的接收端得到的 SINR 的累积密度函数(CDF)曲线。方法 3 选取为特性提取方法。图 3 中, 干扰功率比例设置为  $\alpha_i = 0.25$ , 即该信道条件下噪声功率较大。由图 3 可以看出本文提出的自适应接收机的性能接近 MRC 接收机, 说明在低 IoT 等级场景下自适应接收机选取 MRC 作为接收方法。图 4 中, 设置  $\alpha_i = 0.75$ , 该信道条件下干扰功率大于噪声功率。由图 4 可以看出, 在这种信道条件下, IRC 接收机被采取作为接收方法。




Figure 5. CDF of SINR performance in mixed IoT cases

图 5. 混合 IoT 场景下 SINR 的 CDF

图 5 中, 对于 50%的测试数据集, 将干扰功率比例设置为  $\alpha_i = 0.25$ , 在另外 50%的测试数据集中, 干扰功率比例设置为  $\alpha_i = 0.75$ 。由图 5 可以看出本文提出的基于神经网络的自适应接收机的性能优于基于硬切换的接收机。同时可以看出该基于神经网络的接收机的性能接近 IRC 接收机, 这源于在 IoT 较小

的场景下，选择了 MRC 接收机，MRC 和 IRC 性能接近；而在 IoT 较大的场景下，选择了 IRC 接收机，且 IRC 性能远优于 MRC 接收机，从而进一步说明该自适应的接收机分类得到很高的准确性。

## 5. 结论

本文提出了一种基于干扰感知的接收机，该接收机可以在不同的 IoT 等级场景下自适应地在 MRC 和 IRC 间进行切换，该切换基于对性能及计算复杂度的折中。此外，本文提出了三种特征提取方法进行特征的提取。本文还提出了子载波组中信道相似性的应用进一步减小复杂度。仿真结果表明本文提出的基于神经网络的自适应接收机性能优于现有的硬切换方法，是一种高效的接收机分类方案。

## 参考文献

- [1] Gao, S., Zhang, M. and Cheng, X. (2017) Precoded Index Modulation (PIM) for Multi-Input Multi-Output of DM. *IEEE Transactions on Wireless Communications*, **17**, 17-28. <https://doi.org/10.1109/TWC.2017.2760823>
- [2] Aggarwal, P. and Bohara, V.A. (2017) A Nonlinear Downlink Multiuser MIMO-OFDM Systems. *IEEE Wireless Communications Letters*, **6**, 414-417. <https://doi.org/10.1109/LWC.2017.2699195>
- [3] Ganji, M. and Jafarkhani, H. (2017) On the Performance of MRC Receiver with Unknown Timing Mismatch—A Large Scale Analysis. *IEEE International Conference on Communications*, Kansas City, 1-6. <https://doi.org/10.1109/ICC.2018.8422920>
- [4] Beiranvand, J. and Meghdadi, H. (2018) Analytical Performance Evaluation of MRC Receivers in Massive MIMO Systems. *IEEE Access*, **6**, 53226-53234. <https://doi.org/10.1109/ACCESS.2018.2866795>
- [5] Ren, B., Wang, Y., Sun, S., Zhang, Y., Dai, X. and Niu, K. (2017) Low-Complexity MMSE-IRC Algorithm for Uplink Massive MIMO Systems. *Electronics Letters*, **53**, 972-974. <https://doi.org/10.1049/el.2017.1133>
- [6] Liu, F., Zhao, H.Z., Quan, X., Liu, Y. and Tang, Y. (2016) Eigen Domain Interference Rejection Combining Algorithm for MIMO Systems. *IEEE Communications Letters*, **20**, 850-853. <https://doi.org/10.1109/LCOMM.2016.2538258>
- [7] Kuzminskiy, A.M., Abramovich, Y.I., Xiao, P. and Tafazolli, R. (2016) Uniform Expected Likelihood Solution for Interference Rejection Combining Regularization. *IEEE International Conference on Acoustics, Speech and Signal Processing*, Shanghai, 3286-3290. <https://doi.org/10.1109/ICASSP.2016.7472285>
- [8] Kim, M. and Kim, J. (2015) Adaptive Interference-Aware Receiver for Multi-User MIMO Downlink in IEEE 802.11ac. *IEEE International Conference on Consumer Electronics*, Las Vegas, 645-646. <https://doi.org/10.1109/ICCE.2015.7066562>
- [9] Dong, Z., Shi, J., Wang, W. and Gao, X. (2018) Machine Learning Based Link Adaptation Method for MIMO System. *IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications*, Bologna, 1226-1231. <https://doi.org/10.1109/PIMRC.2018.8580924>
- [10] Huang, Y., Liang, P.P., Zhang, Q. and Liang, Y. (2018) A Machine Learning Approach to MIMO Communications. *IEEE International Conference on Communications*, Kansas City, 1-6. <https://doi.org/10.1109/ICC.2018.8422211>

### 知网检索的两种方式：

1. 打开知网首页：<http://cnki.net/>，点击页面中“外文资源总库 CNKI SCHOLAR”，跳转至：<http://scholar.cnki.net/new>，搜索框内直接输入文章标题，即可查询；  
或点击“高级检索”，下拉列表框选择：[ISSN]，输入期刊 ISSN：2163-3983，即可查询。
2. 通过知网首页 <http://cnki.net/> 顶部“旧版入口”进入知网旧版：<http://www.cnki.net/old/>，左侧选择“国际文献总库”进入，搜索框直接输入文章标题，即可查询。

投稿请点击：<http://www.hanspub.org/Submission.aspx>

期刊邮箱：[hjwc@hanspub.org](mailto:hjwc@hanspub.org)