

3

Receptores com Redes Neurais Recorrentes

Nos últimos anos, redes neurais têm sido utilizadas no projeto de receptores para sistemas de comunicações devido à sua capacidade de classificação, generalização e mapeamento não linear. Essas estruturas são capazes de lidar de modo eficaz com as incertezas encontradas no sinal recebido, provocadas pelo canal de comunicações, interferência de outros usuários e pelo ruído do receptor [35]. Especificamente, os receptores neurais mostram-se superiores na separação dos sinais de diferentes usuários em presença de canais de comunicações seletivos em frequência e ruído. Os primeiros receptores a incorporar o uso de redes neurais foram os equalizadores de canais [36]-[38]. Dentre as estruturas baseadas em redes neurais aplicadas ao problema da equalização de canais em comunicações digitais destacam-se as redes *perceptron* com múltiplas camadas (MLP) [37], redes baseadas em funções de base radial (RBF) [39]-[40] e redes neurais recorrentes (RNR) [41]-[42]. Essas estruturas de redes neurais empregam funções não lineares para formar regiões de decisões na detecção dos símbolos transmitidos, enquanto os equalizadores convencionais usam funções lineares na formação destas regiões de decisão. Mais tarde, foram propostas estruturas mais eficientes para equalização de canais usando receptores neurais com decisão realimentada (DF) [43, 44], onde são usados uma rede neural na seção direta do receptor e um filtro linear com resposta impulsional finita (*Finite Impulse Response-FIR*) na seção realimentada. De uma maneira geral, os resultados na literatura [41]-[44] indicam que os receptores para equalização baseados em redes neurais recorrentes são superiores àqueles que empregam redes RBF e MLP. Posteriormente ao emprego em equalizadores, as redes neurais também foram adotadas no projeto de detectores multiusuário [17]-[19]. Esses receptores usam o critério de desempenho de mínimo erro médio quadrático (*Minimum Mean Squared Error - MMSE*), têm bom desempenho e oferecem a possibilidade de uma implementação adaptativa. O emprego de estruturas não lineares, como redes neurais e decisão realimentada, pode combater de forma mais efetiva a IES e a IMA.

Em particular, nos sistemas de telefonia celular de terceira geração que utilizam a tecnologia DS-CDMA, os usuários que operam com altas taxas de transmissão podem ser acomodados reduzindo-se o ganho de processamento N e usando-se um fator de espalhamento menor [7, 8]. Nestas situações, a interferência de múltiplo acesso (IMA) é relativamente pequena devido ao reduzido número de usuários, mas a interferência entre símbolos (IES) pode causar uma degradação significativa de desempenho. Embora os receptores neurais sejam mais complexos do que os detectores convencionais que utilizam filtros FIR, o uso de estruturas neurais é viável para situações onde o fator de espalhamento é baixo (o número de elementos de processamento é reduzido) e o número de usuários operando com altas taxas de transmissão é pequeno. Neste caso, o compromisso oferecido pelos detectores neurais entre complexidade computacional e desempenho é bastante atraente. Nos últimos anos, as redes MLP [17], RBF [18] e RNR [19] foram utilizadas no projeto de detectores multiusuário, mostrando desempenhos superiores às estruturas lineares.

Neste capítulo, são apresentados novos receptores multiusuário adaptativos que empregam redes neurais recorrentes, que são diferentes das usadas em [19] pelo fato de serem adaptativas, e que utilizam estruturas de cancelamento de interferência através de decisão realimentada. Uma versão do detector RNN adaptativo sem cancelamento de interferência foi publicada em [49], enquanto que o receptor adaptativo RNN com DF foi relatado em [50, 51]. Os detectores multiusuário adaptativos com e sem cancelamento de interferência que empregam o critério MMSE são examinados com o algoritmo LMS [45, 46] e comparados aos receptores neurais propostos, que operam com o algoritmo baseado no gradiente estocástico denominado RTRL (*Real Time Recurrent Learning*), proposto por Williams e Zipser [47].

3.1

Receptores com Decisão Realimentada e Filtros Lineares

O emprego de estruturas DF na construção de receptores multiusuário pode combater de forma mais efetiva a IES e a IMA [1]-[4]. Nesta seção, são descritos receptores multiusuário com decisão realimentada (MUD-DF) e as suas implementações adaptativas. A utilização de uma seção DF em um receptor multiusuário aumenta a sua capacidade de cancelar a IMA e a IES [12]. De fato, a estrutura realimentada minimiza os efeitos da IMA e da IES, ao tentar cancelar a contribuição dos interferentes nos instantes de decisão. Além disso, os sistemas baseados em realimentação, como o

instantâneos dessas expressões em uma técnica de gradiente descendente para obter:

$$\mathbf{w}_k(i+1) = \mathbf{w}_k(i) + \mu_w e_k^*(i) \mathbf{u}(i) \quad (3-2)$$

$$\mathbf{f}_k(i+1) = \mathbf{f}_k(i) + \mu_f e_k^*(i) \hat{\mathbf{b}}(i) \quad (3-3)$$

onde o sinal de erro é $e_k(i) = b_k(i) - (\mathbf{w}_k^H(i) \mathbf{u}(i) - \mathbf{f}_k^H(i) \hat{\mathbf{b}}(i))$, $b_k(i)$ é o sinal ou símbolo desejado para o k -ésimo usuário retirado de uma seqüência de treinamento, o asterisco denota conjugado complexo e μ_w e μ_f são os passos do algoritmo para as seções direta e realimentada, respectivamente. O maior problema do algoritmo LMS é a sua relativamente lenta taxa de convergência e sua conhecida degradação de desempenho quando há uma dispersão significativa entre o maior e o menor autovalor da matriz de autocorrelação da observação $E[\mathbf{u}(i) \mathbf{u}^H(i)]$ [45, 46]. Dentre as vantagens do LMS e outros algoritmos baseados no gradiente, destacamos a sua simplicidade e facilidade de implementação. Uma outra possibilidade é o emprego de algoritmos mais rápidos no que se refere à taxa de convergência como o *Recursive Least Squares* (RLS) e o *Affine Projection* (AP) [45, 46]. Note que expressões para o receptor linear podem ser obtidas ao fazermos $\mathbf{f}_k(i) = 0$, desconsiderando a seção realimentada.

3.2 Receptores Neurais com Decisão Realimentada

As redes neurais recorrentes (RNR) possuem uma ou mais conexões realimentadas, onde cada neurônio artificial é conectado aos outros neurônios, como mostrado na Figura 3.2. As estruturas RNR são adequadas aos problemas e aplicações de equalização e detecção multiusuário, já que elas podem tratar de forma eficaz funções de transferência de canais de comunicações que exibem nulos espectrais profundos, formando regiões de decisões ótimas [41]-[43].

A estrutura neural recorrente da Figura 3.2 pode ser explicada por um modelo de espaço de estados, onde o vetor de estados é descrito por:

$$\mathbf{x}(i+1) = \begin{bmatrix} \varphi(\mathbf{w}_1^H \boldsymbol{\xi}(i)) \\ \vdots \\ \varphi(\mathbf{w}_j^H \boldsymbol{\xi}(i)) \\ \vdots \\ \varphi(\mathbf{w}_q^H \boldsymbol{\xi}(i)) \end{bmatrix} \quad (3-4)$$

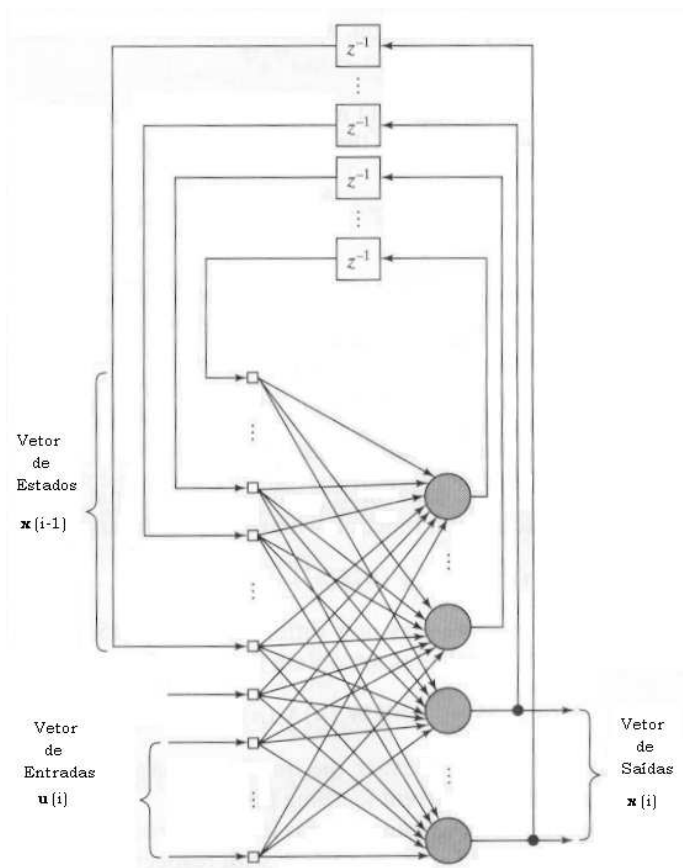


Figura 3.2: Estrutura da seção direta do receptor multiusuário adaptativo baseada em uma rede neural recorrente.

onde supõe-se que todos os neurônios têm uma função de ativação $\varphi(\cdot)$ comum. O vetor \mathbf{w}_j de dimensão $(q + m + 1) \times 1$ é o vetor de coeficientes complexos do neurônio j na rede recorrente, ou de forma equivalente

$$\mathbf{w}_j(i) = \begin{bmatrix} \mathbf{w}_{a,j}(i) \\ \mathbf{w}_{b,j}(i) \end{bmatrix}, \quad j = 1, 2, \dots, q \quad (3-5)$$

onde $\mathbf{w}_{a,j}$ e $\mathbf{w}_{b,j}$ são as j -ésimas colunas das matrizes de coeficientes transpostas \mathbf{W}_a^T e \mathbf{W}_b^T , respectivamente, que formam a matriz $\mathbf{W} = [\mathbf{W}_a \mathbf{W}_b]$, de dimensão $q \times (q+m+1)$. O vetor $\boldsymbol{\xi}(i)$ de dimensão $(q+m+1) \times 1$ é definido por:

$$\boldsymbol{\xi}(i) = \begin{bmatrix} \mathbf{x}(i-1) \\ \mathbf{u}(i) \end{bmatrix} \quad (3-6)$$

onde $\mathbf{x}(i)$ é o vetor de estados de dimensão $q \times 1$ e $\mathbf{u}(i)$ é o vetor de observações de dimensão $(m+1) \times 1$, cujo primeiro elemento é o viés aplicado ao neurônio j . Na prática, pode-se não utilizar o viés, reduzindo a dimensão

da estrutura neural. A estimativa dada pela estrutura neural recorrente é dada por:

$$\mathbf{y}(i) = \mathbf{C}\mathbf{x}(i) = \mathbf{C}\varphi(\mathbf{W}_a\mathbf{x}(i-1) + \mathbf{W}_b\mathbf{u}(i)) \quad (3-7)$$

onde \mathbf{C} é uma matriz de dimensão $p \times q$ que seleciona e combina os estados da rede para fornecer uma estimativa $\mathbf{y}(i)$ de dimensão $p \times 1$.

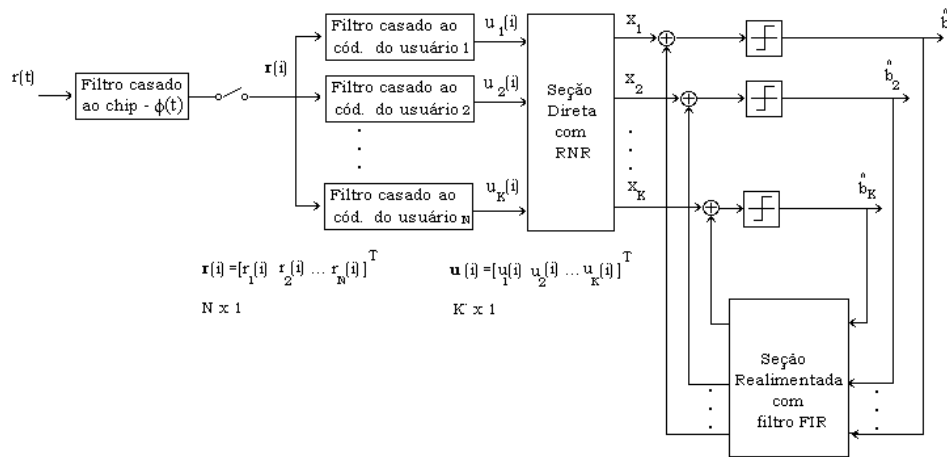


Figura 3.3: Diagrama em blocos do receptor multiusuário adaptativo com decisão realimentada e uma rede neural recorrente na seção direta e um filtro linear FIR na seção realimentada.

Para descrever os receptores DF com RNR, como o mostrado na Figura 3.3, adota-se uma abordagem por espaço de estados e adapta-se a estrutura descrita pelas equações (3-4) a (3-7) ao receptor proposto, onde o vetor $\mathbf{x}_k(i)$ tem dimensão $K \times 1$ corresponde aos K estados da rede neural recorrente do usuário k , o vetor de observação $\mathbf{u}(i)$ de dimensão $K \times 1$ e a saída do receptor neural com decisão realimentada $\hat{b}_k(i)$ é dada por:

$$\boldsymbol{\xi}_k(i) = \begin{bmatrix} \mathbf{x}_k(i-1) \\ \mathbf{u}(i) \end{bmatrix} \quad (3-8)$$

$$\mathbf{x}_k(i) = \varphi(\mathbf{W}_k^H(i)\boldsymbol{\xi}_k(i)) \quad (3-9)$$

$$\hat{b}_k(i) = \text{sgn}\left(\Re\left[\mathbf{C}\mathbf{x}_k(i) - \mathbf{f}_k^H(i)\hat{\mathbf{b}}(i)\right]\right) \quad (3-10)$$

onde $\varphi(\cdot)$ é a função de ativação da rede neural, a matriz $2K \times K$ $\mathbf{W}_k(i)$ contém os coeficientes da seção direta do receptor neural para o usuário k , enquanto o vetor $\mathbf{f}_k(i)$ de dimensão $K \times 1$ reúne os parâmetros da seção realimentada que realiza o cancelamento de interferência do detector

multiusuário, e a matriz $\mathbf{C} = [1 \ 0 \ \dots \ 0]$ de dimensão $1 \times K$ define o número de saídas da rede neural. Note que neste documento e ao longo da nossa pesquisa, a estrutura de recepção neural proposta possui apenas uma saída $\hat{b}_k(i)$ por vetor de observações $\mathbf{u}(k)$, que corresponde à abordagem *one shot*, e que a função de ativação escolhida é a tangente hiperbólica $\varphi(\cdot) = \tanh(\cdot)$.

3.3 Algoritmos Adaptativos para o Receptor Neural DF

Para ajustar os parâmetros do receptor multiusuário neural com decisão realimentada, é empregada uma técnica adaptativa baseada no gradiente estocástico. A diferença básica deste algoritmo e o RTRL [47] é que ele considera a seção realimentada do receptor, ao passo que o RTRL foi desenvolvido para uma estrutura exclusivamente neural e recorrente. O algoritmo de nosso interesse considera a função custo dada por $J(\mathbf{w}_{k,j}(i), \mathbf{f}_k(i)) = |\epsilon_k(i)| = |e_k(i)|^2$, que utiliza o critério MMSE a partir dos valores de erro instantâneos da expressão $e_k(i) = b_k(i) - (\mathbf{C}\mathbf{x}_k(i) - \mathbf{f}_k^H(i)\hat{\mathbf{b}}(i))$. Um algoritmo baseado no gradiente estocástico pode ser deduzido ao calcularmos os termos do gradiente em relação a \mathbf{W}_k e \mathbf{f}_k . Considera-se primeiramente a derivada de $\epsilon_k(i)$ com relação ao complexo conjugado do vetor $\mathbf{w}_{k,j}(i)$ de dimensão $2K \times 1$, que forma a matriz \mathbf{W}_k :

$$\frac{\partial \epsilon_k(i)}{\partial \mathbf{w}_{k,j}^*(i)} = \left(\frac{\partial e_k(i)}{\partial \mathbf{w}_{k,j}^*(i)} \right) e_k^*(i) = -\mathbf{C} \left(\frac{\partial \mathbf{x}_k(i)}{\partial \mathbf{w}_{k,j}^*(i)} \right) e_k^*(i) = -\mathbf{C}\mathbf{\Lambda}_{k,j}(i)e_k^*(i) \quad (3-11)$$

onde a matriz $\mathbf{\Lambda}_{k,j}(i)$ de dimensão $K \times 2K$ contém as derivadas parciais do vetor de estados $\mathbf{x}_k(i)$ com respeito a $\mathbf{w}_{k,j}(i)$. Para obter as expressões de atualização da matriz $\mathbf{\Lambda}_{k,j}(i)$, considera-se a atualização do vetor de estados $\mathbf{x}_k(i)$ dada por (3-8) e (3-9). Usando a regra da cadeia de cálculo em (3-9), obtemos a seguinte recursão que descreve a dinâmica do processo de aprendizagem do receptor neural:

$$\mathbf{\Lambda}_{k,j}(i+1) = \mathbf{\Phi}_k(i) \left(\mathbf{W}_k^{1:K}(i)\mathbf{\Lambda}_{k,j}(i) + \mathbf{U}_{k,j}(i) \right), \quad j = 1, 2, \dots, K \quad (3-12)$$

onde a matriz $\mathbf{W}_k^{1:K}(i)$ de dimensão $K \times K$ corresponde a uma sub-matriz de $\mathbf{W}_k(i)$, formada pelas primeiras K linhas de $\mathbf{W}_k(i)$, e a matriz $\mathbf{\Lambda}_{k,j}(i)$ de dimensão $K \times K$ possui uma estrutura diagonal onde os elementos da diagonal principal correspondem à derivada parcial da função de ativação $\varphi(\cdot)$ com respeito ao seu argumento em $\mathbf{w}_{k,j}^H(i)\boldsymbol{\xi}_k(i)$ conforme expresso por:

$$\Phi_k(i) = \text{diag} \left(\varphi'(\mathbf{w}_{k,1}^H(i)\boldsymbol{\xi}_k(i)), \dots, \varphi'(\mathbf{w}_{k,j}^H(i)\boldsymbol{\xi}_k(i)), \dots, \varphi'(\mathbf{w}_{k,K}^H(i)\boldsymbol{\xi}_k(i)) \right) \quad (3-13)$$

e a matriz $\mathbf{U}_{k,j}(i)$ de dimensão $K \times 2K$ apresenta todas as linhas com elementos iguais a zero, exceto a j -ésima linha que é igual ao vetor $\boldsymbol{\xi}_k(i)$:

$$\mathbf{U}_{k,j}(i) = \begin{bmatrix} \mathbf{0}^T \\ \boldsymbol{\xi}_k^T(i) \\ \mathbf{0}^T \end{bmatrix}, \quad j = 1, 2, \dots, K \quad (3-14)$$

A equação de atualização dos coeficientes da seção direta do receptor neural DF $\mathbf{w}_{k,j}$ é obtida substituindo-se a expressão obtida em (3-11) na regra do gradiente descendente $\mathbf{w}_{k,j}(i+1) = \mathbf{w}_{k,j}(i) - \mu_n \nabla \epsilon_{\mathbf{w}_{k,j}}$ e é expressa por:

$$\mathbf{w}_{k,j}(i+1) = \mathbf{w}_{k,j}(i) + \mu_n \mathbf{C} \boldsymbol{\Lambda}_{k,j}(i) e_k^*(i) \quad (3-15)$$

onde μ_n é o passo do algoritmo. Para calcular a regra de ajuste dos coeficientes da seção realimentada do receptor neural DF \mathbf{f}_k , calculamos a derivada de $\epsilon_k(i)$ com relação a \mathbf{f}_k e procedemos de forma análoga à seção direta do receptor, obtendo a seguinte expressão:

$$\mathbf{f}_k(i+1) = \mathbf{f}_k(i) + \mu_f e_k^*(i) \hat{\mathbf{b}}(i) \quad (3-16)$$

Note que as expressões obtidas para a adaptação dos parâmetros do receptor neural DF também podem ser usadas para um receptor neural sem decisão realimentada, fazendo-se $\mathbf{f}_k = 0$. É importante observar que a expressão obtida em (3-16) é idêntica à obtida em (3-3). Entretanto, o sinal de erro usado em (3-16), que é função de uma rede neural recorrente, é diferente daquele usado em (3-3), que é dependente de um filtro linear FIR. Uma outra observação importante é sobre a função de ativação $\varphi(\cdot)$, para a qual foi escolhida a tangente hiperbólica ($\tanh(\cdot)$), em função de ser diferenciável e pelo fato de ter uma expressão analítica para a sua derivada, que é a secante hiperbólica ao quadrado ($\frac{d \tanh(x)}{dx} = \text{sech}^2(x)$).

3.4 Simulações

Nesta seção, são realizados experimentos através de simulações para avaliar e comparar o desempenho em termos da taxa de erro de bits (*Bit*

Error Rate - BER) dos receptores multiusuário lineares e neurais com e sem decisão realimentada; o detector convencional de um único usuário (SUD) com ganho de processamento N e usando modulação BPSK em um dado canal, o que equivale ao filtro casado à assinatura do usuário; e o limiar de desempenho de um único usuário (SU-Bound), que corresponde ao SUD em um sistema com apenas um usuário e sem IMA. Devido à grande dificuldade de analisar teoricamente os algoritmos e a estrutura neural com decisão realimentada proposta, o emprego de simulações nos pareceu a abordagem mais adequada para o estudo destas técnicas e a verificação de sua eficácia no projeto de receptores.

Em primeiro lugar, são analisados os receptores multiusuário com apenas a seção direta, ou seja, sem a seção realimentada ($\mathbf{f} = \mathbf{0}$) para examinar os receptores neurais e compará-los aos MUD lineares e ao SUD. As simulações se concentram no enlace reverso de um sistema DS-CDMA síncrono e centralizado, cujas seqüências de assinaturas são geradas aleatoriamente, com um ganho de processamento $N = 8$, passos $\mu_w = 0.01$ e $\mu_n = 0.01$ para os algoritmos adaptativos e um cenário onde supõe-se um controle de potência perfeito (os sinais dos usuários chegam com igual potência à estação rádio-base). Os parâmetros de convergência dos algoritmos μ_n e μ_w , foram sintonizados de modo a garantir um bom desempenho dos receptores para as diversas situações analisadas a seguir. É importante destacar que os passos de convergência funcionam bem para uma grande faixa de valores e o desempenho não é muito sensível a pequenas variações destes parâmetros. Os algoritmos baseados no gradiente estocástico são treinados com 200 símbolos durante a transmissão de uma seqüência de treinamento e, em seguida, os seus coeficientes são mantidos fixos durante a fase que os receptores processam os símbolos de dados. Note que o desempenho em termos de BER mostrado nos resultados refere-se à BER média dos K usuários em questão. Um outro aspecto importante a ser ressaltado é que os canais são normalizados em todas as simulações de modo a garantir potência unitária no receptor ao longo do experimento.

Para analisar o desempenho em termos de BER dos receptores adaptativos em um canal de ruído aditivo gaussiano branco (AWGN), foram realizadas simulações onde os receptores processam 10^4 símbolos de dados, e são tiradas as médias de 100 experimentos independentes. O desempenho em termos de BER versus a razão sinal-ruído ou E_b/N_0 para $K = 3$ usuários é mostrado na Figura 3.4.

As curvas da Figura 3.4 mostram que o receptor neural usando apenas a seção direta ($\mathbf{f} = \mathbf{0}$) com o algoritmo RTRL é superior ao MUD linear




Figura 3.4: Desempenho em termos de BER para os receptores em um canal AWGN com $K = 3$ usuários.

com o algoritmo LMS, economizando até 0.4 dB de potência para o mesmo desempenho em termos de BER. Em uma outra situação, ilustrada na Figura 3.5, os mesmos receptores são avaliados quando operados com uma potência de $E_b/N_0 = 6dB$ para um número variável de usuários. O receptor neural alcança o melhor desempenho em termos de BER para um número variável de usuários, superando o MUD linear e o SUD.




Figura 3.5: Desempenho em termos de BER dos receptores versus número de usuário em um canal AWGN com $E_b/N_0 = 6dB$.

Para avaliar o desempenho dos receptores adaptativos em um canal

invariante no tempo e seletivo em frequência com AWGN, escolhemos um canal com nulos espectrais cuja função de transferência é dada por $H(z) = 1 - 0.25z^{-1} + 0.4z^{-2}$. Note que os canais utilizados nesta tese (todos são modelados como filtros FIR) são normalizados de modo que $\sum_{n=0}^{L_p-1} h_{k,n}^2 = 1$, onde L_p é o número de percursos do canal. Foram realizadas simulações onde os receptores processaram 10^4 símbolos de dados, e tiradas as médias de 100 experimentos independentes. O desempenho em termos de BER versus E_b/N_0 para um sistema com $K = 3$ usuários é mostrado na Figura 3.6. As curvas da Figura 3.6 mostram que o receptor neural apresenta um melhor desempenho do que o MUD linear, economizando até 1,5 dB para a mesma BER.




Figura 3.6: Desempenho em termos de BER dos receptores em um canal invariante no tempo e seletivo em frequência com função de transferência dada por $H(z) = 1 - 0.25z^{-1} + 0.4z^{-2}$ e AWGN para $K = 3$ usuários.

Em outra situação, os mesmos receptores foram analisados com $E_b/N_0 = 6dB$ e o número de usuários foi variado, conforme ilustrado pela Figura 3.7. O MUD neural consegue o melhor desempenho, superando o MUD linear e o SUD e aumentando a capacidade do sistema.

Nos experimentos seguintes, são investigados os receptores descritos em canais sujeitos ao desvanecimento do tipo Rayleigh. Primeiramente, os receptores são avaliados em um canal plano em frequência e com desvanecimento de Rayleigh com AWGN, sendo que o canal muda a sua característica a cada símbolo transmitido. Todos os receptores processam 10^3 símbolos de dados, e são tiradas as médias de 100 experimentos




Figura 3.7: Desempenho em BER versus número de usuários em um canal invariante no tempo e seletivo em frequência com função de transferência dada por $H(z) = 1 - 0.25z^{-1} + 0.4z^{-2}$ e AWGN com $E_b/N_0 = 8dB$.

independentes. O desempenho em BER versus E_b/N_0 para 3 usuários é mostrado na Figura 3.8.




Figura 3.8: Desempenho em BER versus E_b/N_0 dos MUDs em um canal plano em frequência com desvanecimento de Rayleigh e AWGN para 3 usuários.

As curvas da Figura 3.8 indicam que o receptor neural é superior ao MUD linear e ao SUD. O MUD neural pode economizar até 0,4 dB de potência, para o mesma BER, quando comparado com o MUD neural.

Em uma situação onde fixamos a potência E_b/N_0 em 10dB, a BER

dos receptores foi medida para diferentes números de usuários e um canal plano na frequência com desvanecimento de Rayleigh, como mostrado na Figura 3.9. Os resultados mostram novamente a superioridade do MUD neural sobre o MUD linear e o SUD.




Figura 3.9: Desempenho em BER versus número de usuários dos MUDs em um canal plano em frequência com desvanecimento de Rayleigh e AWGN com $E_b/N_0 = 10dB$.

Em seguida, é examinado o desempenho em termos de BER dos receptores em canais seletivos em frequência com desvanecimento de Rayleigh e AWGN. O canal é modelado com três percursos e o seu perfil de atrasos é discreto com espaçamento de um período de *chip*, onde cada percurso é modelado como independente, com média zero e variáveis aleatórias complexas. A envoltória de cada percurso da resposta impulsional deste canal possui uma distribuição de probabilidade de Rayleigh. O canal é composto por três raios e é descrito por $h_{k,l}(i) = p_{k,l}\alpha_{k,l}(i)$ ($l = 0, 1, 2$), onde $p_{k,0} = 1$, $p_{k,1} = 0.6$, $p_{k,2} = 0.4$ e $\alpha_{k,l}(i)$ é uma seqüência de variáveis aleatórias de Rayleigh utilizada de modo que o canal varie a cada intervalo de símbolos. Os receptores processam 10^3 símbolos de dados e são tiradas médias de 100 experimentos independentes. O desempenho em termos de BER versus E_b/N_0 para $K = 3$ usuários é mostrado na Figura 3.10.

Os resultados mostrados na Figura 3.10 demonstram que o receptor neural é superior ao MUD linear, apresentando economias de até 0.5 dB em potência, para uma mesma BER. Um cenário com diferente número de usuários e uma potência constante em 10 dB foi considerado com o mesmo




Figura 3.10: Desempenho em BER versus E_b/N_0 para os receptores em canais seletivos em frequência com desvanecimento de Rayleigh e AWGN para $K = 3$ usuários.

canal empregado na Figura 3.10. Novamente, os resultados encontrados na Figura 3.11 indicam que o MUD neural é superior aos demais receptores.




Figura 3.11: Desempenho em BER versus número de usuários em canais seletivos em frequência com desvanecimento de Rayleigh e AWGN para $E_b/N_0 = 10dB$.

Para examinar os receptores com decisão realimentada, é considerado um sistema DS-CDMA com seqüências de espalhamento de Gold com comprimento $N = 15$ e com uma largura de banda de 3.84 MHz, típica de sistema DS-CDMA faixa larga e que tem taxa de transmissão de 256

kbps. A frequência de portadora do sistema escolhida foi 1900 MHz. É utilizado um canal típico de comunicações móveis e supõe-se que os canais experimentados por cada usuário são estatisticamente independentes e identicamente distribuídos. A seqüência de coeficientes do canal $h_{k,l}(i) = p_{k,l}\alpha_{k,l}(i)$ ($l = 0, 1, 2$), onde $\alpha_{k,l}(i)$, é uma seqüência de variáveis aleatórias gaussianas complexas obtida a partir da filtragem de ruído complexo gaussiano branco por um filtro com função de transferência aproximada $\beta/\sqrt{1 - (f/f_d)^2}$ onde β é uma constante de normalização, $f_d = v/\lambda_{fc}$ é o máximo deslocamento Doppler, λ_{fc} é o comprimento de onda da frequência da portadora e v é a velocidade do terminal móvel [52]. Esse procedimento corresponde à geração de seqüências correlacionadas de variáveis aleatórias cuja envoltória possui uma distribuição de Rayleigh e potência unitária ($E[|\alpha_{k,l}(i)|^2] = 1$). As simulações avaliam e comparam o desempenho dos receptores, que processam 10^3 símbolos de dados, sendo que são tiradas as médias de 100 experimentos independentes. Os algoritmos são ajustados com 200 símbolos durante a fase de treinamento e depois são chaveados para o modo que utiliza a realimentação das decisões passadas. É importante ressaltar que os resultados em termos de BER referem-se à BER média entre os K usuários. Quanto à sensibilidade dos parâmetros de convergência dos algoritmos μ_n , μ_w e μ_f para os detectores DF, estudos em diversos cenários revelam que estes funcionam bem para uma ampla faixa de valores. Os passos utilizados nos experimentos restantes são indicados nas legendas das figuras.

O desempenho e a convergência em termos de BER dos MUDs são avaliados em um canal plano em frequência com AWGN. O desempenho em termos de convergência de BER é ilustrado na Figura 3.12, enquanto as curvas de BER versus E_b/N_0 e BER versus número de usuários podem ser vistas nas Figuras 3.13 e 3.14. Os resultados da Figura 3.12 corroboram aqueles das Figuras 3.13 e 3.14 e mostram que o receptor neural com decisão realimentada alcança o melhor desempenho, seguido do MUD neural, MUD DF convencional, o MUD linear e o SUD.

Em uma situação onde o canal de comunicações é seletivo em frequência com desvanecimento de Rayleigh, foi analisado o desempenho e a convergência em termos de BER. O canal foi modelado com dois percursos ($L_p = 2$) cujas potências são $p_{k,0} = 1$ e $p_{k,1} = 0.5$ para cada usuário. O desempenho em termos de convergência de BER é ilustrado na Figura 3.15 e as curvas de BER versus E_b/N_0 e BER versus número de usuários são mostradas nas Figuras 3.16 e 3.17. Os resultados das Figuras 3.15, 3.16 e 3.17 indicam que o MUD DF neural é superior ao MUD neural, o MUD




Figura 3.12: Convergência em termos de BER dos MUD em um canal plano em frequência com desvanecimento de Rayleigh e AWGN, $E_b/N_0 = 10$ dB e $K = 4$ usuários em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.005$, $\mu_n = 0.005$ e $\mu_f = 0.0015$.




Figura 3.13: Desempenho em BER versus E_b/N_0 dos MUDs em um canal plano em frequência com desvanecimento de Rayleigh e AWGN, em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.005$, $\mu_n = 0.005$ e $\mu_f = 0.0015$.

DF, o MUD linear e o SUD




Figura 3.14: Desempenho em BER versus número de usuários dos MUDs em um canal plano em frequência com desvanecimento de Rayleigh e AWGN, $E_b/N_0 = 8$ dB em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.005$, $\mu_n = 0.005$ e $\mu_f = 0.0015$.




Figura 3.15: Desempenho em BER dos MUDs em um canal seletivo em frequência com desvanecimento de Rayleigh, $E_b/N_0 = 10$ dB e com $K = 4$ usuários em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.0025$, $\mu_n = 0.0025$ e $\mu_f = 0.0015$.




Figura 3.16: Desempenho em BER versus E_b/N_0 dos MUDs em um canal seletivo em frequência com desvanecimento de Rayleigh, em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.0025$, $\mu_n = 0.0025$ e $\mu_f = 0.0015$.




Figura 3.17: Desempenho em BER versus número de usuários dos MUDs em um canal seletivo em frequência com desvanecimento de Rayleigh, $E_b/N_0 = 8$ dB em um cenário onde os terminais móveis se deslocam com velocidade de 80km/h. Os parâmetros dos algoritmos são $\mu_w = 0.0025$, $\mu_n = 0.0025$ e $\mu_f = 0.0015$.