

EMPREGO DE MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN NO PROJETO DE DECISORES EM SISTEMAS DE COMUNICAÇÃO DIGITAL

CRISTIANO MAGALHÃES PANAZIO, HELDER CANHADAS BERTAN, ROMIS RIBEIRO DE FAISSOL ATTUX

Depto. de Comunicações
Fac. de Eng. Elétrica e de Computação – Universidade Estadual de Campinas (Unicamp)
Caixa Postal 6101, CEP: 13083-970, Campinas SP – Brasil
Tel.: 19-7883703, Fax: 19-2891395
{panazio, hcbertan, romisri}@decom.fee.unicamp.br

SUMÁRIO

Neste trabalho, é proposto um decisor adaptativo baseado em redes neurais artificiais de Kohonen, capaz de gerar autonomamente as classes correspondentes a cada símbolo de um esquema digital genérico, na presença de ruído aditivo, gaussiano e branco (AWGN). Mais especificamente, é utilizado o conceito de auto-organização no ajuste dos parâmetros da rede, visando a condição de operação ótima segundo o critério de máxima verossimilhança (ML).

Para se avaliar o desempenho do método proposto, o mesmo foi aplicado a um canal que também impunha alterações de ganho e rotação de fase ao sinal transmitido. Após a exposição do esquema, foram realizados alguns testes para se avaliar o desempenho do mesmo, tanto em canais estáticos quanto dinâmicos (com desvanecimento). As modulações utilizadas foram a 4-PSK e a 16-QAM. Os resultados das simulações são discutidos, de modo a se clarificar a aplicabilidade do método.

1. INTRODUÇÃO

Para canais do tipo AWGN (*Additive White Gaussian Noise*), o projeto do decisor ótimo é feito usualmente através do critério de máxima verossimilhança (ML). Porém, quando o canal introduz outros tipos de distorção, como mudança de amplitude e rotação de fase, torna-se necessário o uso de dispositivos capazes de combatê-las, para que não haja um significativo aumento na probabilidade de erro de detecção. Dentre os possíveis dispositivos, podemos citar o CAG (Controle Automático de Ganho) e o PLL (*Phase-Locked Loop*).

Um exemplo significativo de sistema para o qual ocorrem as distorções citadas acima é o canal rádio-móvel. Isto pois a ocorrência de desvanecimento, uma das mais marcantes características deste canal, impõe tais tipos de degradação ao sinal transmitido.

Neste trabalho, propomos o uso de uma rede neural que emprega mapas auto-organizáveis de Kohonen como uma paradigma para se obter um decisor ótimo adaptativo, dispensando o emprego do CAG e do PLL. Este esquema pode ser utilizado para qualquer tipo de modulação digital. Contudo, nossa análise irá se restringir a modulações 4-PSK (*Phase-shift Keying*) 16-QAM (*Quadrature Amplitude Modulation*).

Serão analisados dois casos principais de distorção: um caso estático, no qual altera-se a fase por um valor fixo, e um caso

dinâmico, onde amplitude e fase são modificados continuamente por um ruído multiplicativo, que é o modelo mais usual de desvanecimento rápido. Para que pudéssemos ter um parâmetro de comparação de desempenho, implementamos o CAG e o PLL descritos na referência [1].

A seção 2 deste trabalho descreve a regra de decisão ótima para canais AWGN. A seção 3 descreve como obter o decisor ótimo tendo por base uma rede auto-organizável de Kohonen, bem como seu funcionamento. A seção 4 versa sobre a aplicação da técnica proposta a esquemas de modulação 4-PSK e 16-QAM. Na seção 5 realizamos uma avaliação do custo computacional do esquema proposto. Em seguida, a seção 6 mostra e discute os resultados obtidos através das simulações. Finalmente a seção 7 estabelece nossas conclusões.

2. DECISORES ÓTIMOS

O objetivo de um sistema de comunicações é permitir que haja um fluxo de informação entre dois pontos. Quando a informação é transmitida através de um alfabeto finito de símbolos, fala-se em um esquema digital de comunicação.

Uma das formas de se transmitir esta informação é através de diferentes sinais, com parâmetros distintos, que indiquem qual o conteúdo da mensagem que se enviou.

Uma forma de se realizar esta tarefa é através do uso de uma base de N funções ortonormais, na qual se representam os diferentes sinais de informação. Portanto, cada sinal pode ser visto, neste contexto, com um ponto num espaço N -dimensional. Matematicamente, temos:

$$x(t) = \sum_{i=1}^N x_i \phi_i(t) \quad (1)$$

onde $\phi_i(t)$ é a i -ésima função da base ortonormal e x_i a i -ésima componente de $x(t)$ nesta base. Pode-se pensar nos N componentes de $x(t)$ como um vetor $\mathbf{x} = (x_1, \dots, x_N)$.

Em diversos esquemas de modulação digital, como M-PSK e QAM, por exemplo, utiliza-se uma base formada pelas funções ortogonais seno e cosseno.

O sinal transmitido, porém, sofre influência do canal pelo qual se propaga. Um modelo bastante usual para canais de comunicação

é o AWGN, onde a saída do mesmo é igual à entrada adicionada a um processo gaussiano branco.

Podemos então escrever:

$$y(t) = x(t) + n(t) \quad (2)$$

O ruído gaussiano pode ser visto como pertencendo a um espaço de dimensão infinita. Podemos então decompô-lo em uma parcela pertencente ao espaço N-dimensional dos sinais, e em uma outra parcela, pertencente ao subespaço dual [2]. Matematicamente:

$$n(t) = n_s(t) + n_D(t) \quad (3)$$

onde $n_s(t)$ representa a parcela projetada no “espaço de sinais” e $n_D(t)$ representa a parcela complementar.

Como os dois espaços são ortogonais, e os processos são gaussianos, as duas parcelas são independentes. Consideremos agora apenas a parcela $n_s(t)$, que podemos escrever como:

$$n_s(t) = \sum_{i=1}^N n_i \phi_i(t) \quad (4)$$

onde n_i é a i-ésima componente de $n_s(t)$ na base ortonormal. Podemos pensar nestas componentes como elementos de um vetor $\mathbf{n}_s = (n_1, \dots, n_N)$.

Temos que:

$$E[n_i] = 0 \text{ e } E[n_i n_j] = (N_0/2) \delta_{ij} \quad (5)$$

onde δ_{ij} é a função delta de Kronecker (que vale um para $i = j$ e zero para $i \neq j$).

A densidade de probabilidade conjunta das coordenadas do vetor de ruído é:

$$p_n(n_1, n_2, \dots, n_N) = (1/\mathbf{p}N_0)^{N/2} \exp\left[(-1/N_0) \left\{ \sum_{i=1}^N n_i^2 \right\}\right] = \quad (6)$$

$$= (1/\mathbf{p}N_0)^{N/2} \exp(-\|\mathbf{n}_s\|^2 / N_0)$$

Consideremos agora o sinal $y(t)$ na saída do canal. A partir de (1), (2) e (4), e levando em conta apenas a parcela de $y(t)$ projetada no espaço de sinais, temos:

$$y_s(t) = x(t) + n_s(t) = \sum_{i=1}^N (x_i + n_i) \phi_i(t) \quad (7)$$

Vetorialmente, temos:

$$\mathbf{y}_s = \mathbf{x} + \mathbf{n}_s \quad (8)$$

Portanto, a densidade de probabilidade do vetor de saída \mathbf{y} dado que foi transmitido o vetor \mathbf{x} é dada por:

$$p_N(y_s/x) = [1/\pi N_0]^{N/2} \exp(-\|\mathbf{y}_s - \mathbf{x}\|^2 / N_0) \quad (9)$$

Pelo critério de máxima verossimilhança (ML), obtemos a seguinte estimativa de \mathbf{x} :

$$\mathbf{x}_{ML} = \max_{\mathbf{x} \in \chi} \{p_N(y_s/x)\} = \min_{\mathbf{x} \in \chi} \|\mathbf{y}_s - \mathbf{x}\|^2 \quad (10)$$

Esta expressão mostra como deve operar nosso decisor, buscando sempre comparar a distância entre o símbolo recebido e possíveis símbolos do alfabeto do transmissor, decidindo em favor do que levar à menor distância.

Na sequência, iremos eliminar o subscrito “s” das variáveis y e n .

3. AUTO-ORGANIZAÇÃO EM DECISORES

A partir do que foi exposto na seção anterior, foi pensado em um esquema baseado no conceito de auto-organização de Kohonen [3]. A aplicabilidade deste paradigma ao projeto de decisores decorre da expressão obtida para o estimador ML (10).

No esquema padrão de auto-organização de Kohonen, uma rede neural linear é alimentada com diversos estímulos (padrões), e para cada um deles, há um processo de competição entre os neurônios. O neurônio que tiver o seu vetor de pesos mais próximo do vetor de entrada é declarado vencedor. Este e seus vizinhos (o emprego da vizinhança pode ser muito relevante, dependendo da aplicação) têm seu vetor de pesos aproximado do padrão. Desta forma, após o treinamento da rede, há a formação de classes. Isto quer dizer que a rede se organizou de acordo com as entradas que lhe foram apresentadas, de maneira não-supervisionada.

A partir disto, pode-se vislumbrar a aplicação desta técnica ao projeto de decisores ótimos. O processo de estabelecimento de um decisor é justamente o de se criar classes que correspondam aos símbolos passíveis de terem sido enviados em uma transmissão. Além do mais, o processo de formação de classes é baseado justamente na minimização da distância entre os vetores de peso da rede e os padrões de entrada, de forma análoga a (10).

Não empregando a idéia de vizinhança, haverá uma correspondência única entre classes e neurônios, ou seja, cada neurônio será associado a uma das possibilidades de transmissão. Para tanto, é necessário que haja uma inicialização adequada, que não permita que um mesmo neurônio vença a competição para dois estímulos pertencentes a classes distintas. Por fim, quando o decisor estiver devidamente ajustado, o processo de decisão irá consistir em observar qual neurônio apresenta o vetor de pesos mais próximo da entrada, e optar pela classe associada ao mesmo. Isto corresponde ao tipo de decisão tomada no critério ML. Porém, aplicando o algoritmo de Kohonen, é possível projetar o decisor sem se conhecer, *a priori*, as distorções introduzidas pelo canal.

A seguir, descreveremos sequencialmente o procedimento de projeto apresentado. Em primeiro lugar, é preciso notar que a rede, fazendo papel de decisor, tem por entrada a saída do demodulador. Portanto, a mesma atua sobre o vetor de componentes \mathbf{y} (8). O algoritmo pode ser expresso pelos seguintes passos:

3.1. Preparação da Rede e Fase de Inicialização:

3.1.1 Escolher um número adequado de neurônios para a rede neural (de acordo com o número de hipóteses).

3.1.2 Transmitir N_{IN} vezes cada um dos símbolos da constelação. É preciso conhecer a mensagem transmitida no receptor, o que torna esta fase supervisionada. Uma vez recebidos os símbolos, é feita uma média aritmética entre as amostras correspondentes a cada um deles, o que nos dá uma estimativa inicial de cada um dos símbolos da constelação distorcida. Algumas particularizações deste passo serão comentadas na seção 4.1.

3.1.3 As estimativas obtidas no passo anterior são então usadas como condição inicial para a rede neural. Com isto, os neurônios já estarão identificados com cada um dos símbolos transmitidos.

3.2. Treinamento:

Esta fase serve para que seja refinada, se constatada tal necessidade, a estimativa inicial obtida na fase anterior, antes que a rede comece a operar.

3.2.1. Separar um conjunto de N_T vetores $\mathbf{y}(k)$ recebidos para o treinamento e ajuste da rede neural.

3.2.2. Para cada vetor $\mathbf{y}(k)$, obter o índice do neurônio vencedor, através de:

$$i = \arg \min_j (\| \mathbf{w}_j(k) - \mathbf{y}(k) \|) \quad (11)$$

onde $\mathbf{w}_j(k)$ é o vetor do j -ésimo neurônio no instante k .

3.2.3. Uma vez obtido o índice i , utilizar a seguinte fórmula de atualização dos pesos do i -ésimo neurônio:

$$\mathbf{w}_i(k+1) = \mathbf{w}_i(k) + \alpha[\mathbf{y}(k) - \mathbf{w}_i(k)] \quad (12)$$

onde α é o passo de adaptação.

3.2.4. Se julgar-se necessário, embaralhar os N_T padrões e voltar a 3.2.1.

3.3. Operação:

Após as duas fases anteriores, considera-se que a rede está apta a operar como decisor ótimo (de acordo com o critério ML). O processo de decisão consiste em se determinar, para cada vetor recebido $\mathbf{y}(k)$, o neurônio que tem o vetor de pesos mais próximo desta entrada. Como os neurônios já foram devidamente identificados, o símbolo correspondente ao vencedor é a estimativa de nosso decisor.

É muito importante que a rede continue a ser adaptada nos moldes de 3.2.2 e 3.2.3 para todos os símbolos, para compensar eventuais modificações do canal. Isto caracteriza a operação "on-line" do decisor já devidamente treinado.

4. APLICAÇÃO A SISTEMAS 4-PSK E 16-QAM COM VARIAÇÕES DE GANHO E FASE

Dentre as muitas possíveis escolhas para uma base ortonormal, iremos concentrar-nos neste trabalho em apenas uma: uma base formada por duas senóides de mesma frequência e defasadas de noventa graus (cosseno e seno). Esta escolha permite-nos abranger uma ampla classe de esquemas de modulação digital.

Iremos concentrar nossa análise em dois exemplos significativos: modulações 4-PSK e 16-QAM. No primeiro caso, a informação está embutida na fase da portadora senoidal. No segundo, a informação encontra-se na fase e na amplitude da portadora.

A componente associada ao termo cossenoidal da base é chamada de componente em fase, e o outro termo denomina-se componente em quadratura. O conjunto de possíveis vetores de componentes do alfabeto do transmissor denomina-se constelação.

Na exposição a seguir, foi arbitrado o valor da energia de cada símbolo, sem perda de generalidade, e este valor foi usado no resto do trabalho.

4.1. Esquema para a modulação 4-PSK

Na modulação 4-PSK, há 4 possibilidades para as componentes de \mathbf{x} :

$$X_{4-PSK} = \{ [-1; -1], [-1; 1], [1; -1], [1; 1] \} \quad (13)$$

Analisando esta constelação, percebe-se que a mesma é simétrica. Isto permite que exploremos esta característica para otimizar o algoritmo descrito na seção 3. Mais especificamente, o passo 3.1.2 pode ser alterado. Ao invés de enviarmos os quatro símbolos desta constelação, basta que enviemos um deles (N_{IN} vezes). Feita a média, temos a condição inicial de um dos neurônios. Para obtermos a dos outros, basta imprimir 3 deslocamentos de 90° sucessivos, sendo que o vetor resultante de cada deslocamento é considerado como condição inicial de um dos 3 neurônios restantes. A isto denominamos *inicialização ortogonal da rede*, que então estará pronta para a fase 3.2.

4.2. Esquema para a modulação 16-QAM

Na modulação 16-QAM, há dezesseis possíveis símbolos:

$$X_{16-QAM} = \{ [-3; -3], [-3; -1], [-3; 1], [-3; 3], [-1; -3], [-1; -1], [-1; 1], [-1; 3], [1; -3], [1; -1], [1; 1], [1; 3], [3; -3], [3; -1], [3; 1], [3; 3] \} \quad (14)$$

Os quadrantes do plano no qual se encontra a constelação expressa em (14) serão denominados por nós *quadrantes maiores*. Dentro de cada um destes, podemos definir outros quadrantes, de modo a ser ter cada um dos quatro símbolos da constelação, simetricamente distribuídos, em um dos chamados *quadrantes menores*. Portanto, cada símbolo pode ser caracterizado pela indicação dos seus quadrantes maior e menor.

A princípio, pode-se propor um decisor baseado em 16 neurônios (um por símbolo), de forma análoga ao caso anterior. Podemos, porém, explorar as características de simetria da constelação 16-QAM para reduzir este número.

Neste artigo, propomos um esquema baseado em quatro neurônios para obter uma aproximação do decisor ótimo. Novamente, utilizamos a idéia de inicialização ortogonal, descrita na seção 4.1, sendo transmitido apenas o símbolo de maior potência de um dos quadrantes. Isto permite a realização do passo 3.1.2 na melhor SNR possível, tornando o algoritmo mais robusto ao efeito do ruído.

Vale lembrar que um esquema com 16 neurônios seria a implementação mais próxima da idéia do critério de otimalidade ML, mas consideramos que a implementação proposta, por seu custo computacional mais baixo, é mais atraente para os casos enfocados.

Uma vez terminado as fase 3.1 (com as modificações discutidas), cada peso estará em um dos quadrantes. Multiplicando cada um deles por um fator de 2/3, os vetores estarão próximos do “centro de massa” dos símbolos pertencentes a cada quadrante maior. Pode então ser realizado o passo 3.2. Na fase 3.3, para cada símbolo a ser identificado, determina-se o quadrante maior diretamente a partir da rede treinada. Após isto, restam-nos quatro alternativas (correspondentes aos quadrantes menores). Se subtrairmos do símbolo recebido o vetor de pesos correspondente ao neurônio vencedor, teremos os quadrantes menores em torno da origem dos eixos principais. Portanto, temos uma situação idêntica à da decisão do quadrante maior (a menos de um fator de escala 0.5), e podemos, portanto, utilizar a mesma rede neural para fazer a segunda decisão. Feita esta ressalva, o processo de identificação é idêntico ao do caso anterior.

4.3 O Problema da Variação de Amplitude e Fase

Quando um esquema de modulação é coerente, faz-se necessário estimar a fase da portadora no receptor. Isto pode ser feito através de um PLL, dispositivo amplamente usado em sistemas de comunicação. Num esquema de modulação do tipo QAM, é necessário ainda o emprego de um controle automático de ganho (CAG), pois a informação também está embutida na amplitude do sinal.

Caso estes dois dispositivos não funcionem adequadamente, o processo de decisão será comprometido, o que levará à operação em condição sub-ótima.

Enfocaremos dois problemas específicos neste artigo: um caso de falha na estimação de fase, ou seja, uma rotação fixa da mesma, e a operação do decisor num canal com desvanecimento, que introduz variações contínuas de amplitude e fase.

O esquema neural proposto é capaz de contornar estes problemas, pois não precisa conhecer *a priori* os efeitos da atuação do canal para classificar os símbolos recebidos. Portanto, mostraremos que o método dispensa o emprego do CAG e do PLL, fazendo também o papel destes.

4.4. Condição de Ortogonalidade

Para as modulações digitais utilizadas, podemos mostrar, através do método de máxima verossimilhança, que as fronteiras das regiões de decisão são ortogonais. Desta forma, podemos inserir essa restrição na nossa rede. Isto é feito inicializando-se os pesos ortogonalmente e fazendo com que a alteração no neurônio vencedor (que ocorre no item 3.2.3 do algoritmo) seja repassada aos demais neurônios, levando-se em conta a condição de ortogonalidade.

Com isto, o rastreamento de canais variantes melhora, pois todo sinal recebido ajuda na atualização de todos os pesos, e não somente do vencedor.

4.5. Uma Forma Alternativa de Inicialização

Caso deseje-se inicializar a rede ortogonalmente, usando o algoritmo descrito na seção 3 com as modificações comentadas em 4.1 e 4.2, mas não se disponha de uma transmissão sequencial de um único símbolo, há uma forma alternativa de inicialização. Em primeiro lugar, escolhe-se um símbolo como referência. A cada símbolo recebido, verifica-se a qual quadrante da constelação original ele pertence. De posse desta informação, introduz-se a defasagem adequada (90, 180 ou 270 graus) para que todos os símbolos fiquem com a mesma fase da referência. Tira-se a média de todos, e então realiza-se a inicialização ortogonal, da forma exposta em 4.1.

5. CUSTO COMPUTACIONAL

O custo computacional da rede utilizada foi baseado no número de ciclos de clock necessários para a execução de uma atualização dos pesos da rede num DSP Analog Devices 21062, com codificação feita em C. Para efeito de comparação, também é mostrada o número de ciclos necessários no CAG e PLL implementados por [1].

	Kohonen 16-QAM	Kohonen 4-PSK	Ref. [1] 16-QAM/4-PSK
Ciclos	89	55	144

Tabela 1. Custo Computacional em número de ciclos de processamento do ADSP-21062

Esse custo mais elevado do esquema de [1] se deve principalmente a uma operação de raiz quadrada e ao cálculo de um seno e um cosseno. Por exemplo, o cálculo de um seno ou um cosseno requer 55 ciclos, e o da raiz quadrada, 10 ciclos. Se o cosseno fosse tabelado, conseguiríamos baixar este valor de 144 para aproximadamente 53 ciclos, em um possível método proposto, à custa de se usar memória para tabelar os valores da senóide. Neste caso, o número de ciclos seria equivalente ao da rede para modulação 4-PSK.

6. RESULTADOS

As primeiras simulações realizadas se deram a partir de um modelo de canal AWGN com alterações estáticas, a fim de comparar o desempenho do decisor neural com o limitante teórico.

Foram realizadas algumas simulações para ilustrar o desempenho da técnica aplicada ao problema de decisão em um ambiente com somente uma rotação fixa de fase de 45 graus.

Na primeira, o esquema de modulação empregado foi o 4-PSK. Foram utilizados 20 símbolos na fase de inicialização, para garantir uma boa inicialização em baixas SNRs, e 2000 na fase de teste. Foram utilizados esquemas com e sem restrição de ortogonalidade. O valor do passo foi escolhido a posteriori. Não julgamos necessário aplicar o passo 3.2. Na Fig. 4, encontram-se as curvas SNR x Taxa de Erro de Símbolo, para duas situações.

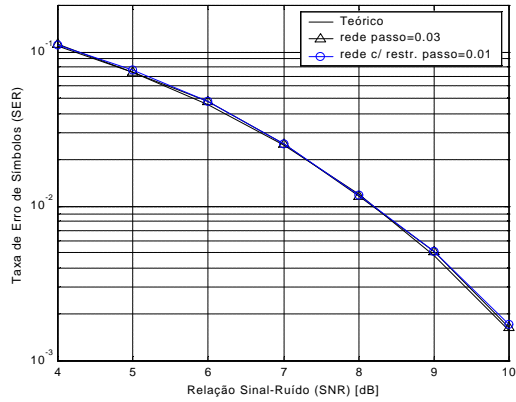


Figura 4. Rotação de 45° / 4-PSK

Podemos perceber, pela Fig. 4, que os esquemas neurais têm uma boa performance, praticamente coincidindo com o limitante teórico. A introdução da restrição de ortogonalidade não modificou o desempenho da rede.

Para o caso da modulação 16-QAM, foram utilizados 5 símbolos na fase de inicialização, e 2000 na de teste. Também foram utilizados os dois modelos de rede neural (com e sem restrição de ortogonalidade). Os resultados das simulações estão na Fig. 5.

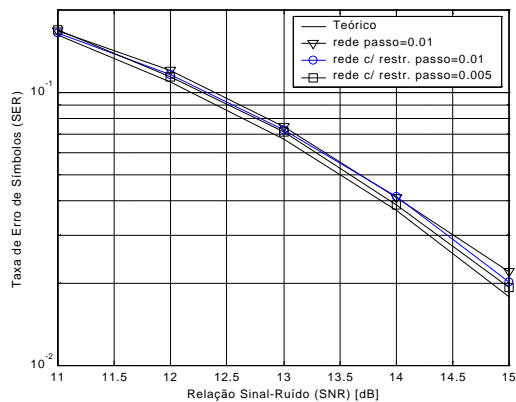


Figura 5. Rotação de 45° / 16-QAM

Novamente todos os casos tiveram um bom desempenho, sendo que a rede com restrição de ortogonalidade e menor passo foi a mais próxima do limitante. A melhor performance para um menor passo de adaptação se deveu ao ruído de adaptação mais baixo, que foi o fator preponderante, já que a boa inicialização torna pouco importante o fator velocidade de convergência.

As simulações para teste da capacidade de rastreamento do decisor implementado foram realizadas segundo o modelo da Fig. 6. Na figura, $x(k)$ é o símbolo transmitido, $\rho(k)$ é um desvanecimento gerado pelo modelo de Jakes, $n(k)$ é um ruído aditivo gaussiano branco, e $y(k)$ é a saída do canal.

Os parâmetros para frequência de portadora e taxa de transmissão foram retiradas da norma IS-136 [5], o que permite que tenhamos uma referência da taxa de desvanecimento.

Para efeito de comparação de desempenho, usamos a proposta de CAG e PLL da referência [1]. Os mesmos vetores de símbolos transmitidos, desvanecimento e ruído eram usados em ambas técnicas (Kohonen e ref. [1]), de forma que a comparação fosse a mais precisa possível.




Figura 6. Modelo de canal com desvanecimento, utilizado para análise da capacidade de rastreamento.

Os procedimentos da simulação foram os seguintes:

- ao se sortear um vetor de desvanecimento, este tinha sua fase inicial deslocada até zero. Tal procedimento serve para evitar toda a fase de inicialização dos neurônios pois, só desejamos ver como as técnicas se comportam no rastreamento do sinal. Neste caso, inicializamos os pesos com os valores de cada símbolo no caso 4-PSK e com os valores dos “centros de massa” no 16-QAM.
- ao total de cada simulação, são transmitidos 1100 símbolos através do canal, dos quais 100 são utilizados para que se faça, sem supervisão, a correção de ganho, além de acompanhar as mudanças de fase. Os demais 1000 símbolos são utilizados para se obter a taxa de símbolos errados.

Os parâmetros de passo de cada técnica foram obtidos a partir de várias simulações preliminares.

Para obtenções destas taxas, foram transmitidos 200000 símbolos para cada SNR. Os resultados da simulação estão na Fig. 7.

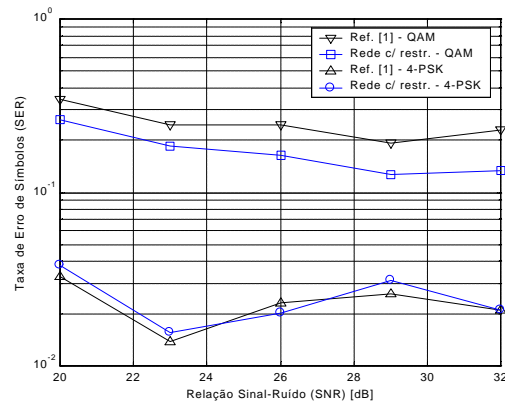


Figura 7. Desempenho para velocidade de 8 km/h para modulações 16-QAM e 4-PSK. QAM: $\alpha_{Koh}=0.06$, $\alpha_{CAG}=0.01$ e $\alpha_{PLL}=0.02$; 4-PSK: $\alpha_{Koh}=0.15$, $\alpha_{CAG}=0.06$ e $\alpha_{PLL}=0.01$

A razão da taxa se manter tão elevada é a de quando se dá a ocorrência de desvanecimento profundos, a fase e a amplitude sofrem rápida variação, que não é acompanhada por nenhuma das duas técnicas. Neste caso, ocorre uma troca nas zonas de decisão implicando em altas taxas de erro. Se estes

desvanecimentos profundos ocorrem logo no começo de cada bloco, maior será a taxa de erro. Outro aspecto, é a presença de uma oscilação nesta taxa. Tal fato advém da ocorrência de desvanecimentos no começo da transmissão, um fator que influencia mais que o ruído aditivo. Assim, se em um ensaio o número de ocorrências deste fenômeno for menor que em outro com maior SNR, a taxa de erro poderá ser menor. Nestes casos, é mais interessante utilizar na prática um esquema de modulação diferencial.

No caso da modulação 4-PSK, ambas técnicas tiveram desempenho semelhante. Contudo, para a modulação QAM, a rede de Kohonen apresentou desempenho superior ao implementado por [1].

7. CONCLUSÕES

Neste trabalho, propusemos uma técnica de projeto de um decisor adaptativo aplicável a sistemas de comunicação digital. O projeto deste dispositivo foi baseado no paradigma da auto-organização de Kohonen.

Especificamente, o esquema foi aplicado a esquemas de modulação 4-PSK e 16-QAM, em dois tipos de canal: um canal com variação estática de fase e um com variação dinâmica de amplitude e fase (desvanecimento).

Para o primeiro tipo de canal, o esquema apresentou um desempenho, para ambas modulações, muito próximo do limitante teórico para um canal AWGN. Portanto, o decisor neural operou em condições ótimas nestes casos.

Em condições onde ocorrem variações contínuas de ganho e fase, o desempenho, quando comparado com a técnica proposta por [1], se mostra praticamente o mesmo, com a vantagem de que a proposta da rede possui um menor custo computacional na adaptação. Embora os valores de taxa de erro sejam altos, os mesmos já são bem menores que no caso de um decisor estático. Isto indica que as técnicas implementadas têm uma boa capacidade de rastreamento.

Acreditamos que o principal problema deste método é a necessidade de transmissão de uma sequência de treinamento (passo 3.1.2), o que pode não ser viável para algumas aplicações.

Um próximo passo pode ser analisar o desempenho desta rede atuando em conjunto com equalizadores autodidatas do tipo GCMA [6] ou equalizadores realimentados como o apresentado na referência [1]. A presença do decisor neural poderia então corrigir distorções de ganho e amplitude na saída destes dispositivos, garantindo uma substancial melhora no desempenho do sistema.

Tivemos contato, após a conclusão do artigo, com outras duas implementações de decisores baseados em redes neurais, sendo que [8] também se baseia no paradigma da auto-organização de Kohonen, apresentando, porém, diferenças conceituais e de aplicação em relação a este trabalho.

8. BIBLIOGRAFIA

- [1] Rocha C. A. F., *Técnicas Preditivas para Equalização Autodidata*, Tese de Doutorado, FEEC/Unicamp
 - [2] Palazzo R., *Transmissão Digital: Fundamentos e Aplicações*, Material do curso de Transmissão de Dados, FEEC, Unicamp
 - [3] Haykin S., *Neural Networks: A Comprehensive Foundation*, MacMillan
 - [4] Proakis J. G., *Digital Communications*, Third Edition, McGraw-Hill
 - [5] EIA/TIA IS-136;800 MHz TDMA Cellular- Radio Interface- Mobile Station-Base Station Compatibility- Digital Control Channel, Dezembro;1994
 - [6] Cavalcanti F.R.P., Brandão A.L., Romano J.M.T. "A Generalized Constant Modulus Algorithm for Blind Equalization", Global Telecommunications Conference (GLOBECOM), Sidney, 1998.
 - [7] Fernandes M.A.C., Bezerra J.B., Neto A.D.D. "Implementação do Receptor de Sistemas de Modulação Digital através de Redes Neurais", Simpósio Brasileiro de Telecomunicações (SBT), Recife, 1997.
 - [8] T. Kohonen, K. Raivio, O. Simula, O. Ventä e J. Henriksson "Combining Linear Equalization and Self-Organizing Adaptation in Dynamic Discrete-Signal Detection"- - Proceedings of the International Joint Conference on Neural Networks, pp. 223-228, 1990.
- Agradecimentos:**
- Os autores gostariam de agradecer ao contribuinte brasileiro, que através da CAPES e do CNPq financia este trabalho.
 - Gostaríamos de agradecer ao professor João Batista Destro Filho, que revisou este paper e contribuiu com suas valiosas sugestões.
 - Agradecemos aos professores João Marcos T. Romano e Luís Geraldo P. Meloni pelo apoio e orientação.
 - Nossos agradecimentos ao prof. Fernando Von Zuben, que ministrou o curso de Redes Neurais que deu origem a este paper.
 - Por fim, agradecemos ao prof. Reginaldo Palazzo Júnior, que muito contribuiu para a concepção teórica do método.