

COMBINAÇÃO AFIM DE FILTROS ADAPTATIVOS RLS-LMS PARA CONFORMAÇÃO DE FEIXES EM ANTENAS INTELIGENTES COM SINTONIA PARAMÉTRICA BASEADA EM REDES NEURAIIS.

ANTÔNIO HENRIQUE DOS SANTOS RIBEIRO*, JOÃO VIANA DA FONSECA NETO*. FRANCISCO DAS CHAGAS DE SOUZA**

**Universidade Federal do Maranhão, São Luís, MA, Brasil, Departamento de Engenharia de Eletricidade, Laboratório de Controle Inteligente e Sistemas Embarcados*

E-mail: scfcahenriquer@gmail.com; jviana@dee.ufma.br

***Universidade Federal do Maranhão, São Luís, MA, Brasil, Departamento de Engenharia de Eletricidade, Laboratório de Sistemas Adaptativos e Processamento de Sinais*

E-mail: francisco.souza@ufma.br

Abstract: In this article, a Feed Forward Artificial Neural Network is applied to the RLS-LMS adaptive algorithm, with the objective of tuning the weight parameters, calculating the ideal or optimal weights used in the signal input of the linear filters that adapt the pattern of uniform linear array antenna radiation, directing multiple narrow beams to desired users and nullifying interference or unwanted users. The application of this neural network provides the ability to increase the efficiency and optimize the use of smart antennas. The results obtained are presented. This article is based on the work of (Ribeiro et al, 2019) taking the results obtained in the use of the combination of two adaptive filters LMS (Least mean-square) and RLS (recursive least-square) combined to obtain an adaptive algorithm RLS- LMS that surpassed classical algorithms in terms of convergence speed and stability.

Keywords: Affine combination, adaptive filters, beamforming, smart antennas, neural networks, adaptive algorithm RLS-LMS.

Resumo: Neste artigo, aplica-se uma Rede Neural Artificial Feed Forward ao algoritmo adaptativo RLS-LMS, com o objetivo de sintonizar os parâmetros dos pesos, calculando os pesos ideais ou ótimos utilizados na entrada do sinal dos filtros lineares que adaptam o padrão de radiação da antena do arranjo linear uniforme, direcionando vários feixes estreitos para os usuários desejados e anulando a interferência ou usuários indesejados. A aplicação dessa rede neural proporciona a capacidade de aumentar a eficiência e otimizar o uso das antenas inteligentes. Os resultados obtidos são apresentados. Esse artigo baseia-se no trabalho de (Ribeiro et al, 2019) tomando os resultados obtidos na utilização da combinação de dois filtros adaptativos LMS (Least mean-square) e RLS (recursive least-square) combinados obtendo um algoritmo adaptativo RLS-LMS que superou os algoritmos clássicos em termos de velocidade de convergência e estabilidade.

Palavras-chave: Combinação afim, filtros adaptativos, conformação de feixes, antenas inteligentes, redes neurais, algoritmo adaptativo RLS-LMS.

1. INTRODUÇÃO

A conformação de feixe adaptativo é um importante tópico de pesquisa que contribui de maneira significativa para que se possa criar condições de soluções relativas à interferências no sistema de antenas inteligentes. As antenas inteligentes consistem geralmente de um sistema de comutação de feixe e de um sistema adaptativo formador de feixe. Um sistema de comutação de feixe opera em vários padrões de feixes fixos. Já os sistemas adaptativos de formação de feixes têm a capacidade de permitir que a antena guie o feixe em qualquer direção de interesse, neste caso, a direção desejada, assim como de forma contínua, apresenta o sinal de interferência. A

função dos sistemas adaptativos é a de formar diagramas de irradiação. Em um sistema de antena inteligente, os pesos da conformação de feixe podem ser ajustados para formar uma quantidade de feixe adaptável para rastrear usuários correspondentes automaticamente e ao mesmo tempo minimizar a interferência de outros usuários através da introdução de valores nulos em suas direções (Gross, 2005). As técnicas de conformação de feixe adaptativo foram usadas para aplicações comerciais, incluindo os sistemas de celulares, radar e sonar (Ribeiro et al, 2019).

O rastreamento do sinal depende exclusivamente do algoritmo de conformação de feixe (Srar, 2009). Dentre eles, pode-se destacar os algoritmos da classe LMS (Mínimo Quadrado Médio) e RLS (Mínimo Quadrado Recursivo), e inclusive a combinação RLMS (Mínimo Quadrado Médio Recursivo) (Srar, 2009). Nos últimos anos, vários pesquisadores

* O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa e Desenvolvimento Científico do Maranhão (FAPEMA), da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

(Bershad, 2008), (Candido, 2008), têm investigado como melhorar a convergência do LMS, RLS e suas variantes a fim de reduzir a complexidade com base no filtro adaptativo. A implementação de filtros combinados, de acordo com suas próprias características é uma forma mais eficaz de solucionar o problema existente entre o desempenho do filtro e sua complexidade. Esquemas de combinação afim têm sido estudados em vários trabalhos e explorados em aplicações como a conformação em arranjo de antenas (Lu et al., 2012).

O esquema de gradiente estocástico $\rho\eta - LMS$ (Cândido et al., 2010) e o resultado encontrado em (Srar et al., 2009), aborda o uso da combinação afim nos algoritmos clássicos RLS e LMS para um maior número de elementos no arranjo de antenas e variação da relação sinal ruído mais interferência (SNIR).

A formação de feixe adaptável é um dos aspectos principais e mais famosos no desenvolvimento de tecnologias de antenas inteligentes. Usa-se diferentes topologias e algoritmos para identificar os sinais desejados e separar a interferência de um canal. Algoritmos como Mínimo Quadrado Recursivo (RLS) e Algoritmo de Mínimo Quadrado Médio (LMS) comprovaram sua eficiência em técnicas adaptativas de formação de feixes. Porém, os crescentes requisitos em sistemas de comunicação implicam em mais foco na implementação da inteligência artificial em antenas inteligentes (Mansour, 2016).

As RNA's (Redes Neurais Artificiais) têm a capacidade de aumentar a eficiência e otimizar o uso de antenas inteligentes em sistemas de comunicação sem fio, devido aos crescentes requisitos em sistemas de comunicação por implicarem em mais foco na implementação da inteligência artificial em antenas inteligentes. Isto foi observado, já que as redes neurais têm proporcionado um rápido desenvolvimento nas últimas três décadas (Mansour, 2016).

Dessa forma, apresenta-se a comparação e avaliação de desempenho dos algoritmos citados levando-se em consideração a complexidade, estabilidade, velocidade de convergência, resposta de amplitude e rastreamento do sinal desejado.

Os resultados obtidos são muito interessantes e refletem a transmissão do sinal numa determinada direção na qual o mesmo é devidamente aproveitado retirando-se as interferências garantindo, assim, um padrão de rastreabilidade dos dispositivos envolvidos no sistema e alcançando-se um valor determinado do MSE (erro quadrático médio) do sinal transmitido ou recebido numa velocidade adequada para o padrão desejado. Observa-se que as técnicas de conformação de feixe adaptativo são usadas para aplicações comerciais, incluindo os sistemas de radar e sonar, por exemplo.

Implementou-se os algoritmos no ambiente MATLAB e os resultados são apresentados e discutidos.

Este artigo está organizado como segue: na Seção 2 apresenta-se o modelo do sinal e o método de conformação de feixe, na Seção 3, a formulação matemática dos algoritmos LMS, NLMS (Mínimo Quadrado Médio Normalizado), PNLMS (Mínimo Quadrado Médio Normalizado Proporcional) e RLS

são descritas. O método proposto é descrito na Seção 4. A utilização da rede neural para o arranjo de antenas inteligentes proposto é mostrada na seção 5. Na Seção 6 apresentamos os resultados da simulação. A conclusão e comentários finais são apresentados na seção 7.

2. MODELO DO SINAL E MÉTODO DE CONFORMAÇÃO DE FEIXE

Nesta Seção, apresenta-se o modelo do sinal proposto e o método de conformação de feixe em um arranjo de antenas.

2.1 Modelo do Sinal

Seja um sinal \mathbf{s}_n recebido em relação à frente de onda eletromagnética que incide sobre um arranjo linear uniforme (ULA) de M sensores em como:

$$\mathbf{s}_n = \mathbf{w}_n e^{j(i-1)\frac{2\pi d}{\lambda} \text{sen}\theta}, \quad i = 1, 2, 3, \dots, M, \quad (1)$$

Onde \mathbf{w}_n é o vetor de peso, d é o espaçamento entre os elementos da antena, λ é o comprimento de onda e θ é o valor do ângulo de chegada (AOA). O j é a parte imaginária da representação complexa tal que $j^2 = -1$. O vetor de entrada \mathbf{x} , descreve o modelo do sinal na ULA dado por (Litva, 1996):

$$\mathbf{x}_n = \mathbf{s}_n^{\text{des}} + \mathbf{s}_n^{\text{int}} + \mathbf{s}_n^{\text{noise}}, \quad i = 1, 2, 3, \dots, M - 1 \quad (2)$$

onde $\mathbf{s}_n^{\text{des}}$, $\mathbf{s}_n^{\text{int}}$, $\mathbf{s}_n^{\text{noise}}$ são os vetores dos sinais desejado, interferente e de ruído, respectivamente.

2.2 Método de Conformação de Feixe

O método de conformação de feixe (Godara, 1997) é baseado no modelo do arranjo descrito anteriormente, e pode ser visto como um banco de filtros no qual o sinal de cada sensor é alocado para um peso, lembrando que a conformação de feixe também é usada para modificar o diagrama de radiação no conjunto de arranjo de antenas. Um critério de otimização é escolhido para calcular os pesos dos filtros, tal como o filtro de saída maximiza apenas o sinal de direção no AOA especificado, minimizando também todas as outras direções do espectro angular (Stoica and Moses, 1997). Este princípio é muito simples e rápido de implementar, fornecendo uma estimativa espectral, ou seja, a partir de uma gravação finita de uma seqüência de dados estacionários, estimar como a potência total está distribuída no domínio da frequência (Dias, 2003) representada por (P_θ) (Castro, 2011) e dada por:

$$P_\theta = \mathbf{a}_\theta^H \hat{\mathbf{R}} \mathbf{a}_\theta, \quad (3)$$

onde $(.)^H$ denota transposição hermitiana (isto é, operação de transposição combinada com complexo conjugado) e $\hat{\mathbf{R}}$ é a matriz de correlação geralmente dada por:

$$\hat{\mathbf{R}} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n^H \mathbf{x}_n, \quad (4)$$

sendo N o número de amostras disponíveis no sinal. Aqui, é utilizado um arranjo de antenas para as técnicas de conformação de feixe onde explora-se as características espaciais dos sinais através das relações de fase e ângulo de chegada (AOA). Portanto, supõe-se que exista um ou mais sinais localizados em alguma região do espaço, e pode ter interferência em outras regiões. Nas técnicas de conformação

de feixe adaptativo, o foco principal é adaptar o feixe ajustando a magnitude e a fase de cada elemento da antena enquanto os padrões desejáveis de radiação são formados (Widrow and Mantey, 1967). As características de um conformador de feixe, tal como o número de sensores, relação sinal/ruído (SNR) e relação sinal interferência mais ruído (SINR), ajudam a caracterizar o filtro espacial ou a conformação de feixe.

3. ALGORITMOS DE CONFORMAÇÃO DE FEIXE

Nesta Seção, destaca-se os algoritmos de conformação de feixe do tipo não cegos, entre eles o RLS e LMS. Algoritmos de conformação de feixe são divididos em cegos e não cegos. Métodos não cegos são chamados assim, porque empregam uma sequência referencial em sua atualização recursiva (Sayed, 2008). Por outro lado, os algoritmos cegos não usam um sinal de referência. Aqui, quatro métodos não cegos são discutidos em ULA (Arranjo Linear Uniforme).

3.1 Algoritmo LMS Padrão

O algoritmo LMS é um dos primeiros algoritmos adaptativos e sua origem advém do método de “descida mais íngreme” (Haykin, 1996) e (Haykin, 2002). Este célebre Algoritmo desenvolvido até então por Widrow and Hoff em 1960 é um dos algoritmos de gradiente estocástico e por causa de sua robustez e baixa complexidade computacional pode ser utilizado em um grande espectro de aplicações. Dada a função custo $J[e_n]$, na qual e_n representa o erro (diferença entre o sinal desejado e a saída do filtro), tem-se essa função $J[e_n]$ do algoritmo LMS proveniente do MSE (erro quadrático médio) dada por:

$$J[e_n] = E[e_n^2] = E|d_n - \mathbf{w}_n^H \mathbf{x}_n|^2, \quad (5)$$

onde E denota esperança, d_n é o sinal desejado, \mathbf{x}_n é o vetor de entrada, \mathbf{w}_n é o vetor de peso e o H denota a transposição hermitiana desse vetor peso. Portanto, pode-se escrever a equação de atualização da seguinte forma:

$$\mathbf{w}_{n+1} = \mathbf{w}_n - \mu \frac{\partial J[e_n]}{\partial \mathbf{w}_n^*}, \quad (6)$$

onde $\frac{\partial J[e_n]}{\partial \mathbf{w}_n^*}$ é o vetor gradiente de uma função de erro instantânea e μ é o tamanho do passo e o “*” representa o complexo conjugado. Para a função de custo MSE da equação (5), o vetor gradiente é dado por:

$$\frac{\partial E[e_n^2]}{\partial \mathbf{w}_n^*} = E \left[\frac{\partial e_n^2}{\partial \mathbf{w}_n^*} \right] = -2E[e_n^* \mathbf{x}_n]. \quad (7)$$

Usando a equação (7) em (6), obtém-se:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \mu 2E[e_n^* \mathbf{x}_n], \quad (8)$$

aqui, o operador esperança é substituído pela estimativa instantânea, portanto:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + 2\mu \mathbf{x}_n e_n^*. \quad (9)$$

A Equação (9) é denominada de algoritmo LMS padrão.

3.2 Algoritmo NLMS

O algoritmo LMS normalizado também chamado de algoritmo de projeção modificado é uma ótima alternativa para o LMS. O algoritmo NLMS possui a mesma estrutura do LMS. A diferença para o LMS é a função de custo adotada. O processo de otimização é baseado na diferença quadrática de dois parâmetros de estimativa consecutivos, ou seja, a função custo J_n é dada por:

$$J_n = \frac{1}{2} \|\mathbf{w}_n - \mathbf{w}_{n-1}\|^2, \quad (10)$$

Uma vez que o vetor de peso \mathbf{w}_n é obtido em cada iteração, a saída da matriz y_n pode ser calculada por:

$$y_n = \mathbf{w}_n^H \mathbf{x}_n, \quad (11)$$

Portanto, usando o método multiplicador de Lagrange, obtém-se:

$$L = \frac{1}{2} (\mathbf{w}_n - \mathbf{w}_{n-1})^T (\mathbf{w}_n - \mathbf{w}_{n-1}) + \alpha (d_n^* - \mathbf{w}_n^H \mathbf{x}_n), \quad (12)$$

onde L é o Lagrangeano e $e_n^* = d_n^* - \mathbf{w}_n^H \mathbf{x}_n$. A solução desta Lagrangeana (Choi and Shim, 2000) resulta em:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \frac{\mu}{\|\mathbf{x}_n^T \mathbf{x}_n\| + \varepsilon} \mathbf{x}_n e_n^*, \quad (13)$$

Para superar o problema de amplificação de ruído de gradiente é aplicado o ajuste ao vetor de peso em cada iteração normalizado em relação à norma euclidiana de \mathbf{x}_n . Portanto, a Equação (13) é chamada de algoritmo LMS normalizado, sendo μ a taxa de aprendizado para sua estabilidade e ε é a constante escalar que impede a divisão por zero durante a inicialização quando $\mathbf{x}_n = 0$.

3.3 Algoritmo PNLMS

Os algoritmos adaptativos proporcionais são utilizados em aplicações como identificação de sistemas, processamento de sinais e previsão (Haykin and Widrow, 2003). Os algoritmos adaptativos tais como LMS e NLMS geralmente aplicam o mesmo ganho a todos os parâmetros. Para melhorar o desempenho destes algoritmos, em particular a velocidade de convergência, foi desenvolvido nos Laboratórios Bell, em 2000, uma abordagem baseada no NLMS, que distribuiu diferentes ganhos individuais para os parâmetros de estimação a partir de algum critério. Tal abordagem foi chamada de NLMS Proporcional. O PNLMS é definido pelas equações (14) a (18) (Haykin and Widrow, 2003), (Duttweiler, 2000) e (de Souza, 2010). A equação de atualização é dada por:

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \frac{\mu \mathbf{G}_n}{\mathbf{x}_n^T \mathbf{G}_n \mathbf{x}_n + \varepsilon} \mathbf{x}_n e_n^*, \quad (14)$$

onde μ é a taxa de aprendizado, ε é o termo de regulação que impede a divisão por zero e $e_n^* = d_n^* - \mathbf{w}_n^H \mathbf{x}_n$ é a estimativa do erro. Observe que a Equação (14) tem um termo proporcional dado pela matriz de distribuição de ganhos \mathbf{G}_n e o termo normalizado $\mathbf{x}_n^T \mathbf{G}_n \mathbf{x}_n + \varepsilon$, a proporção desses termos é que determina o ganho de atualização de cada parâmetro. A matriz de distribuição de ganhos \mathbf{G}_n dada por:

$$\mathbf{G}_n = \text{diag}[g_n^1 g_n^2 \dots g_n^M], \quad (15)$$

que determina o ganho de cada parâmetro individual estimado. Os elementos da matriz são dados pelo ganho individual:

$$g_n^i = \frac{q_n^i}{\frac{1}{M} \sum_{i=1}^M q_n^i}, \quad (16)$$

Função de proporcionalidade:

$$q_n^i = \max\{f_n, |w_n^i|\}, \quad (17)$$

Fator de ativação:

$$f_n = \rho \max(\delta, \|\mathbf{w}_n\|_\infty) \quad (18)$$

$$\mathbf{r}_n = \alpha^{(N-1)-n} \sum_{n=0}^{N-1} \mathbf{x}_n d_n, \quad (22)$$

Onde α é o fator de ponderação exponencial e seu valor está entre 0 e 1 ($0 \leq \alpha \leq 1$). Finalmente, as declarações matemáticas para os pesos são derivadas como:

$$\begin{aligned} \mathbf{w}_{n+1} &= \mathbf{w}_n - \mathbf{g}_n \mathbf{x}_n^H \mathbf{w}_n + \mathbf{g}_n d_n \\ &= \mathbf{w}_n + \mathbf{g}_n [d_n - \mathbf{x}_n^H \mathbf{w}_n], \end{aligned} \quad (23)$$

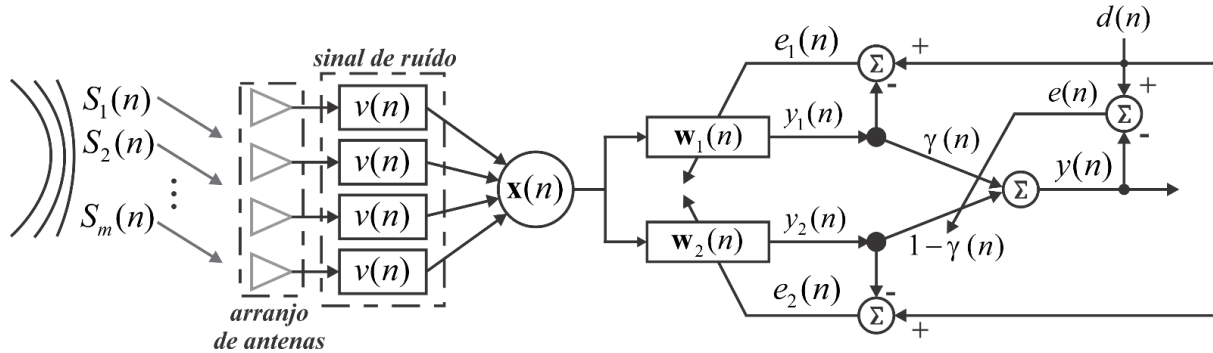


Figura 1: Estrutura inteligente de uma combinação afim usando dois filtros LMS e RLS.

onde δ e ρ são pequenos parâmetros positivos que desempenham o papel de regularização. O parâmetro de inicialização δ é utilizado no início do processo de adaptação ($n = 0$), isto é, quando todos os pesos são nulos ($\mathbf{w}_0 = \mathbf{0}$); o parâmetro ρ evita a estagnação de um dado peso que tenha magnitude muito menor do que a magnitude do maior peso.

3.4 Algoritmo RLS

Algoritmos de mínimos quadrados (LS) visam a minimização da soma dos quadrados da diferença entre o sinal desejado e a saída do filtro do modelo (Haykin, 2002). Quando novas amostras dos sinais de entrada são recebidas a cada iteração, a solução para o problema de mínimos quadrados pode ser calculada de forma recursiva, resultando em algoritmos de mínimos quadrados recursivos (RLS) (Diniz, 2008). Sejam a matriz auto correlação \mathbf{R}_n^{xx} e o vetor de correlação cruzada \mathbf{r}_n dados por:

$$\mathbf{R}_n^{xx} = \sum_{n=0}^{N-1} \mathbf{x}_n \mathbf{x}_n^H, \quad (19)$$

$$\mathbf{r}_n = \sum_{n=0}^{N-1} \mathbf{x}_n d_n. \quad (20)$$

Pode-se anular o efeito das primeiras amostras de dados e destacar os dados de sinal mais recentes, pois o sinal pode variar com o tempo. Este método desejado pode ser alcançado modificando as equações anteriores, tornando-se:

$$\mathbf{R}_n^{xx} = \alpha^{(N-1)-n} \sum_{n=0}^{N-1} \mathbf{x}_n \mathbf{x}_n^H, \quad (21)$$

com \mathbf{g}_n sendo a matriz de ganho. O valor do erro anterior é avaliado diretamente no algoritmo RLS. Nas condições em que os parâmetros são alterados, o uso do algoritmo RLS oferece o melhor desempenho em relação aos da classe LMS.

4. COMBINAÇÃO AFIM DE DOIS FILTROS ADAPTATIVOS APLICADOS A UM BEAMFORMER RLS-LMS

A combinação afim dos vetores $\mathbf{x}_1, \dots, \mathbf{x}_L$ é referida como um ponto na forma $c_1 \mathbf{x}_1 + \dots + c_L \mathbf{x}_L$, onde $c_1 + \dots + c_L = 1$ (Boyd, 2004). Se $c_i \in [0, 1]$ para todo $i = 1, \dots, L$, então a combinação anteriormente mencionada é denominada convexa.

A estrutura inteligente da combinação afim do referido esquema é mostrada na Figura 1. A soma ponderada dos sinais (desejado e interferente) mais o sinal de ruído é dado por (2). Os pesos serão calculados pela saída combinada dos filtros conectados ao parâmetro de mistura. Nesta Seção, considere-se a combinação afim de filtros adaptativos aplicado a um beamformer RLS-LMS, onde a saída no instante n , dada por y_n é alcançada por uma combinação linear, onde a saída geral do filtro y_n e o vetor de peso geral \mathbf{w}_n é dada por (Arenas-Garcia et al., 2016):

$$y_n = \gamma_n y_n^1 + [1 - \gamma_n] y_n^2, \quad (24)$$

$$\mathbf{w}_n = \gamma_n \mathbf{w}_n^1 + [1 - \gamma_n] \mathbf{w}_n^2, \quad (25)$$

com $y_n^k = \mathbf{u}_n^T \mathbf{w}_n^k$, $k = 1, 2$, sendo as saídas dos dois filtros adaptativos caracterizados pelos pesos \mathbf{w}_n^k e pelo parâmetro de mistura γ_n . Neste esquema, propõe-se a atualização do parâmetro de mistura dado por (Cândido et al., 2010):

$$\gamma_{n+1} = \gamma_n + \frac{\mu_\gamma}{\varepsilon + \rho_n} e_n [y_n^1 - y_n^2], \quad (26)$$

Onde $\varepsilon > 0$, sendo um valor pequeno para evitar divisão por zero e:

$$\rho(n) = \eta\rho(n-1) + (1-\eta)[y_1(n) - y_2(n)]^2. \quad (27)$$

Logo, $\rho(n)$ é a estimação da potência do sinal de interesse das saídas dos dois filtros, com η sendo o fator de esquecimento e $0 \leq \eta < 1$. O erro do esquema geral $e(n)$ será calculado por:

$$e_n = d_n - y_n, \quad (28)$$

Ressalta-se que as equações (11) e (24) utilizam a mesma nomenclatura y_n apenas para simbolizar a saída dos respectivos filtros à eles associados, cujo resultados exprimem os valores resultantes das equações que os envolvem.

A equação (26), que é chamada de parâmetro de mistura ($\rho\eta - LMS$) neste trabalho, foi obtido em (Cândido et al., 2010) usando o método de gradiente estocástico. Aqui, obtém-se um desempenho próximo do ótimo não realizável apresentando a mesma ou superior velocidade de convergência e comportamento em regime. Nota-se, ainda, nesta equação que para atingir qualquer valor de γ_n não é necessário recorrer à uma função de ativação sigmoidal, como no caso da combinação convexa.

5. UTILIZAÇÃO DA REDE NEURAL PARA O ARRANJO DE ANTENAS INTELIGENTES PROPOSTO

Nesta seção mostra-se a aplicação de uma Rede Neural Artificial Feed Forward a uma combinação RLS-LMS de filtros adaptativos. A aplicação dessa rede neural proporciona a capacidade de aumentar a eficiência e otimizar o uso das antenas inteligentes.

Propõe-se um modelo utilizando-se RNA para um beamforming adaptativo de antena inteligente levando em consideração duas etapas: treinamento de rede no vetor de fase alvo e rede de treinamento no vetor de saída desejado (Sallomi and Albanee, 2016). A entrada da rede neural na primeira etapa do treinamento é o vetor de fase dos sinais recebidos. Os sinais desejados recebidos pela antena M do arranjo se sobrepõem aos sinais indesejados e de ruído, conforme fornecido na Equação (1). O vetor de direção desejado que incide sobre o conjunto de antenas para o sinal desejado na direção θ_m é dado por:

$$A_d = [1 \quad e^{-jk_m\theta_m} \quad e^{-j2k_m\theta_m} \quad \dots \quad e^{-j(M-1)k_m\theta_m}] \quad (29)$$

O vetor de direção do sinal de ondas planas K (sinais desejados e de interferência) pela antena M do arranjo e é dado por:

$$A_r = \sum_{m=1}^k e^{-j(i-1)k_m\theta_m} \quad (30)$$

$$i = 1, 2, \dots, M$$

O mesmo raciocínio que vale para A_d vale para A_r em relação à componente de fase e ângulo do peso recebido. O vetor de fase desejado ou ótimo que acompanha o peso desejado é dado por:

$$\theta_d = \tan^{-1} \frac{\text{imag}(A_d)}{\text{real}(A_d)} \quad (31)$$

E o vetor de fase recebido que acompanha o peso recebido é dado por:

$$\theta_r = \tan^{-1} \frac{\text{imag}(A_r)}{\text{real}(A_r)} \quad (32)$$

A entrada da rede neural para o treinamento da primeira etapa é o peso recebido ao qual está associado o θ_r e o alvo que deve ser satisfeito por meio desse treinamento é o peso desejado ou ótimo ao qual está associado θ_d .

A segunda etapa do treinamento da rede na saída desejada deve ser verificada pelo arranjo de antenas. Nesta etapa de treinamento a entrada da rede neural é representada por X_u onde :

$$X_u = |X_i(k)| \quad (33)$$

E a referência ou vetor de saída desejado é D . Onde D é o vetor bipolar:

$D = [-1 \quad 1 \quad -1 \quad -1 \quad 1 \quad \dots \dots]$, com n número de amostra.

Na seção 6 para esta Rede Neural Artificial Feed Forward (FFNN) se utiliza a regularização Bayesiana no treinamento. Para melhor contextualização do objetivo da robustez da solução apresentada explica-se aqui, nesta seção 5, a diferença entre a FFNN e a Rede Neural Feed Forward Backpropagation ou de retropropagação (FNNBP).

Em uma Rede Feed Forward (FFNN), cada camada se conecta à próxima camada, porém não há caminho de volta. Todas as conexões, portanto, têm a mesma direção, partindo da camada de entrada rumo a camada de saída. Por isso que para o treinamento dessa rede FFNN utiliza-se um algoritmo backpropagation FNNBP por tratar-se de um treinamento supervisionado. Daí a diferença entre ambas as redes. Dessa forma, com o erro calculado, o algoritmo corrige os pesos em todas as camadas, partindo da saída até a entrada.

O modelo proposto de FFNN (Feed Forward Neuronal Network) é mostrado na Figura 2 e consiste em quatro camadas sendo uma camada de entrada, uma de saída e duas ocultas. A camada de entrada possui N nós, onde N é o número de nós de cada camada. Para a primeira etapa do treinamento da rede na fase desejada N é igual ao número do elemento da antena (M), para o caso deste experimento $M=24$, pois são 24 antenas ou 24 elementos sensores, uma vez que o número da amostra no vetor de fase recebido é igual a M , enquanto na segunda etapa do treinamento da rede no vetor de saída desejado (bipolar) N é igual ao número da amostra no vetor desejado (n). A função de ativação na camada oculta é a função sigmóide e na camada de saída é a função linear. A escolha dessas funções de ativação deveu-se a que essas funções deram melhor desempenho do que outras no treinamento da rede neural. As camadas ocultas consistem em

48 (quarenta e oito) nós cada e a camada de saída tem 1 (um) nó.

Após esta etapa de treinamento da rede neural artificial, nota-se que o vetor peso ideal pode ser escrito em função da fase e dos vetores de saída desejados. Dessa forma, o vetor de peso ideal $w(k)$ pode ser dado como (Sallomi and Albanee, 2016):

$$w(k) = Y(k)^* x_s^\dagger \quad (34)$$

Onde $Y(k)$ é a saída da rede neural da segunda etapa do treinamento.

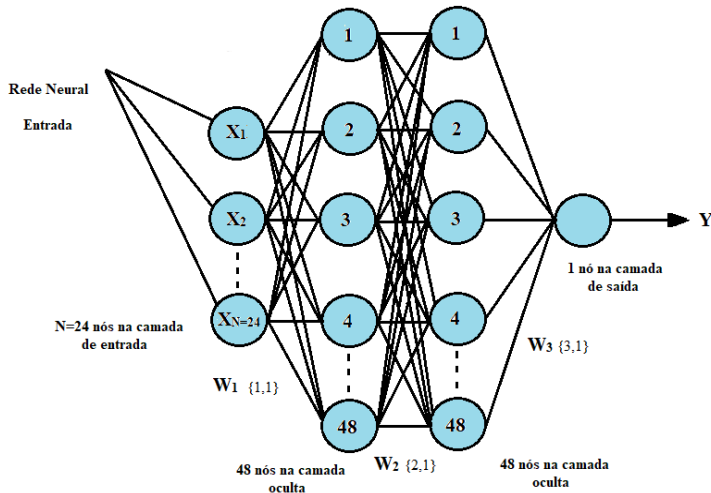


Figura 2 Modelo Proposto da Rede Neural de Feed Forward (FFNN)

Para o vetor de saída x_s relativo à saída da primeira etapa de treinamento (treinamento de fase) da rede neural temos:

$$x_s = e^{-j(i-1)k\theta_s} \quad (35)$$

Onde θ_s é o vetor de fase de saída da rede neural da primeira etapa do treinamento que acompanha seu respectivo peso.

Na equação (34) † se refere a matriz pseudo inversa de Moore-Penrose para encontrar a inversa da matriz não quadrada (x_s) e é dada por (Albert, 1972):

$$x_s^\dagger = (x_s^T x_s)^{-1} x_s^T \quad (36)$$

O diagrama de radiação do arranjo de antenas pode ser obtido (desenhado) a partir da equação do fator de arranjo (AF) que neste caso é função do peso ideal e do ângulo de fase representado por $\alpha(k)$:

$$AF = |w(k)e^{-j(i-1)\alpha(k)}| \quad (37)$$

$$i = 1, 2, \dots, M$$

O ângulo $\alpha(k)$ é o ângulo de busca entre $[-90^\circ, 90^\circ]$ com 1º como tamanho do passo de -90 a 90.

A Figura 3 representa o diagrama de blocos e os detalhes da aplicação da rede neural Feed Forward que seleciona os pesos ótimos para serem aplicados nos filtros.

Um arranjo linear uniformemente espaçado com 24 antenas e a distância $d = 0,25\lambda$ entre elas é escolhida de 500 amostras. Todos os elementos são dados com valores de amplitude fixos.

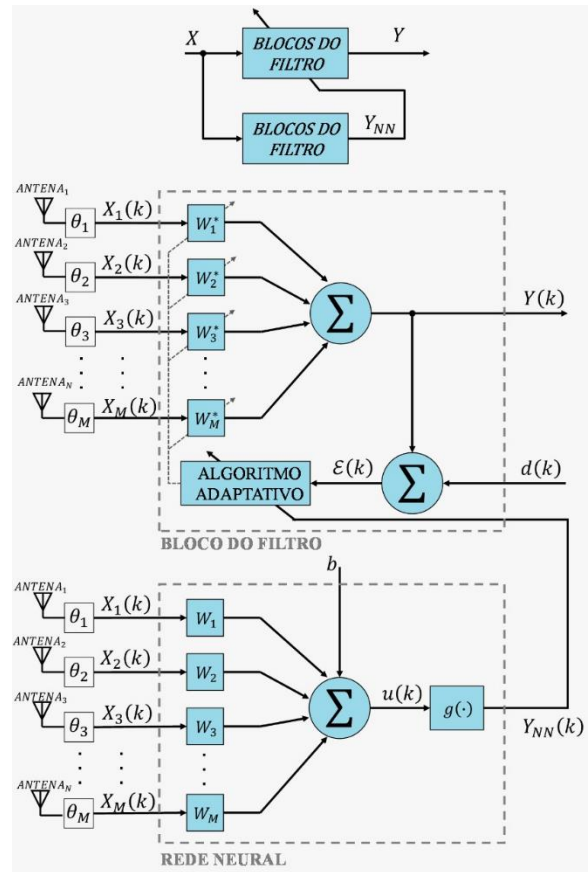


Figura 3: Diagrama de Blocos e Detalhe do Experimento

6. RESULTADOS DA SIMULAÇÃO

Os resultados da simulação do uso do algoritmo de retropropagação da rede neural feed forward (FNNBP) para realizar a formação de feixes adaptativos são implementados para o algoritmo de retropropagação de regularização bayesiana. Foi assumido $M = 24$ (antenas), espaçamento de elemento $d = \lambda/2$, $\theta = 30^\circ$, e o número da amostra $n = 2.100$. As simulações são para o filtro adaptativo utilizando beamforming em antenas inteligentes para a combinação RLS-LMS com a rede neural.

6.1 Treinamento da Rede Neural (FNNBP)

Em geral, o treinamento da RNA visa a redução do somatório dos erros quadráticos. No treinamento da Regularização Bayesiana proposta atua-se na função de custo na qual o somatório dos erros quadráticos da rede são parâmetros de regularização da função objetivo. De acordo com o comportamento desses parâmetros o treinamento terá maior ênfase na minimização do erro para os dados do treinamento e ou o treinamento irá enfatizar a redução dos valores dos pesos da rede, produzindo uma resposta de rede mais suave (Medeiros, 2004).

O desempenho do treinamento de Retropropagação de Regularização Bayesiana com uma direção de chegada é

desenvolvido em uma FNNBP com duas camadas ocultas com 48 neurônios cada, conforme mostrado na Figura 4.





Figura 4: Rede Neural Artificial Feed Forward Utilizada.

O resultado da simulação do diagrama de radiação com os gráficos retangular, polar e de ganho é mostrado na Figura 5. Esse gráfico é plotado para o filtro adaptativo utilizando beamforming em antenas inteligentes para a combinação RLS-LMS com a aplicação da rede neural. Os resultados são implementados com as entradas de informações para o sistema de antena inteligente ($M = 24$, $d = \lambda / 2$, $\theta = 30^\circ$, $n = 500$).


Os gráficos da Figura 5 mostram que o padrão de radiação atinge o sinal desejado localizado a aproximadamente 30° . Isso é observado nos diagramas de irradiação retangular, polar e de ganho.

Os gráficos das Figuras 5 e 6 mostram um excelente desempenho para o algoritmo de retropropagação de aprendizagem da Rede Neural Feed Forward (FNNBP) em relação ao do filtro adaptativo convencional utilizando os algoritmos RLS e os da família LMS. A função de treinamento mais rápida é a função de treinamento padrão para Rede Neural Feed Forward. Este método tende a ser menos eficiente para grandes redes (com milhares de pesos), pois requer mais memória e mais tempo de computação para esses casos.


A FFNN atua de maneira rápida na escolha dos pesos ótimos a serem utilizados no filtro, tendo em vista que os melhores pesos são escolhidos. A Rede Neural Feed Forward (FFNN) artificial é usada para calcular os pesos ideais que adaptam o



(a)



(b)



(c)

Figura 5: Diagrama de radiação usando FFNN treinado pelo algoritmo de Regularização Bayesiana com $M = 24$, $d = \lambda / 2$ (a) Gráfico Retangular; (b) Gráfico Polar e; (c) Gráfico de Ganho


padrão de radiação da antena, direcionando vários feixes estreitos para os usuários desejados e anulando a interferência ou usuários indesejados.

Os resultados mostram um ótimo desempenho do sistema de rede treinada pelo algoritmo de Regularização Bayesiana.

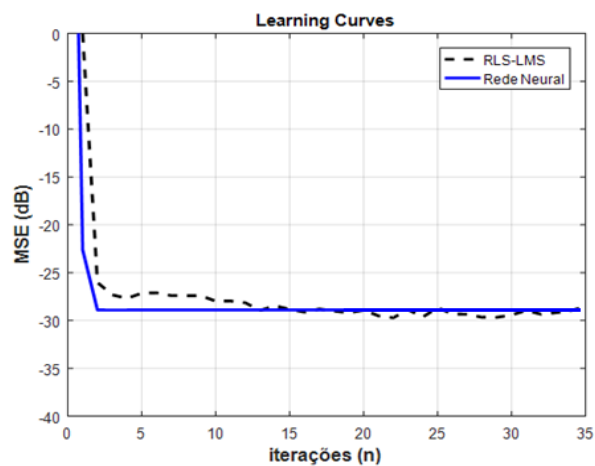
Para os gráficos da Figura 6 utilizou-se valores de sinais de 5 e 10 dB a fim de verificar o comportamento do MSE, ou seja, numa relação SINR em que se tem a aplicação da potência em relação aos efeitos do ruído mais interferência e quanto é o desvio do sinal a ser transmitido em relação ao esperado.

A Figura 6 representa o comportamento do MSE (erro quadrático médio) em relação ao número de iterações da amostra na qual observa-se a iteração para o SINR com 5 dB e 10 dB.

Agora a análise é com duas curvas: a da combinação RLS-LMS e a outra utilizando a Rede Neural Feed Forward. Durante o processo de treinamento o diagrama do MSE para ambos os arranjos diminui a cada iteração e converge após um valor acima de 2 iterações no ambiente de aprendizagem.



(a)



(b)

Figura 6: - MSE dos algoritmos RLS-LMS e Rede Neural:

(a) SINR=5 dB e (b) SINR=10 dB

Nota-se que o MSE tem um erro menor para 10 dB, pois converge para um valor da ordem de quase -30 dB. Ao passo que o MSE para a aplicação de 5 dB tem um erro maior, pois converge para um MSE da ordem de quase -25 dB. O algoritmo RLS-LMS utilizando a Rede Neural apresenta maior estabilidade, tanto para o caso da SINR com 5dB, quanto para o de 10 dB. Conforme já esclarecido, o comportamento universal da combinação afim é alcançado para o caso da SINR com 10dB.

Dessa forma, o comportamento de ambos os arranjos mostrados nas Figuras 5 e 6 rastream o sinal desejado com sucesso e o nulo apropriado na direção do sinal interferente.

Portanto, o esquema de combinação RLS-LMS com Rede Neural Feed Forward apresenta maior velocidade de convergência e boa capacidade de rastreamento no sistema do que a combinação RLS-LMS sem a RNA.

7. CONCLUSÃO

Neste artigo aplicou-se uma rede neural artificial feed forward (FFNN) a uma combinação afim de filtros adaptativos RLS-LMS para conformação de feixes utilizando antenas inteligentes. Calculou-se os pesos ideais que adaptam o padrão de radiação da antena, direcionando os feixes para os usuários desejados e anulando a interferência ou usuários indesejados. A simulação foi aplicada em um arranjo linear uniforme (ULA) com vinte e quatro elementos de antena. Os resultados mostram um ótimo desempenho do sistema da rede treinada pelo algoritmo de Regularização Bayesiana. Notou-se através dos resultados obtidos nas Figuras 5 e 6 que de acordo com o sinal transmitido ou recebido utilizando-se essa técnica obtém-se um sinal com aproveitamento máximo em 30°, assim como valor do ganho do sinal transmitido ou recebido. Observa-se também que a SINR tem seu valor de convergência em 10 dB para um MSE menor em relação à 5 dB. Essas características são muito importantes no padrão de rastreabilidade dos dispositivos utilizados em telefonia celular, radares, sistemas de aproximação de pouso de aeronaves, sistemas de telecomunicações e etc.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico do Maranhão (FAPEMA), da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS

- Arenas-Garcia, J., Azpicueta-Ruiz, L. A., Silva, M. T., Nascimento, V. H., & Sayed, A. H. (2016). Combinations of adaptive filters: performance and convergence properties. *IEEE Signal Processing Magazine*, 33(1), 120-140.
- Bershad, N. J., Bermudez, J. C. M., & Tournet, J. Y. (2008). An affine combination of two LMS adaptive filters—transient mean-square analysis. *IEEE Transactions on Signal Processing*, 56(5), 1853-1864.

- Boyd, S., & Vandenberghe, L. (2004). *Convex optimization*. Cambridge university press.
- Candido, R., Silva, M. T., & Nascimento, V. H. (2008, October). Affine combinations of adaptive filters. In 2008 42nd Asilomar Conference on Signals, Systems and Computers (pp. 236-240). IEEE.
- Candido, R., Silva, M. T., & Nascimento, V. H. (2010). Transient and steady-state analysis of the affine combination of two adaptive filters. *IEEE Transactions on Signal Processing*, 58(8), 4064-4078.
- Castro, Roberto Mouzinho de. Estudo de Algoritmos Adaptativos de Beamforming com detecção de Ângulo de Chegada. Rio de Janeiro: UFRJ/COPPE, 2011, página 8, 68 p.
- Choi, S., & Shim, D. (2000). A novel adaptive beamforming algorithm for a smart antenna system in a CDMA mobile communication environment. *IEEE Transactions on Vehicular Technology*, 49(5), 1793-1806.
- de Souza, F. D. C., Tobias, O. J., Seara, R., & Morgan, D. R. (2010). A PNLMS algorithm with individual activation factors. *IEEE Transactions on Signal Processing*, 58(4), 2036-2047.
- Dias, Maurício Henrique Costa. Estimaco das respostas do canal real de propagao rdio-mvel nos domnios espacial e temporal: anlise da supresso de rudo por decomposio wavelet como tcnica complementar de processamento. Rio de Janeiro: PUC, Departamento de Engenharia Eltrica, 2003, pgina 44.
- Duttweiler, D. L. (2000). Proportionate normalized least-mean-squares adaptation in echo cancelers. *IEEE Transactions on Speech and Audio Processing*, 8(5), 508-518.
- Godara, L. C. (1997). Application of antenna arrays to mobile communications. II. Beam-forming and direction-of-arrival considerations. *Proceedings of the IEEE*, 85(8), 1195-1245.
- Gross, F. (2005). Smart antennas for wireless communications with MATLAB. *McGraw Hills*.
- Haykin, Simon.(1996). Adaptive Filter Theory. 3th ed. Upper Saddle River, NJ, USA; Prentice Hall.
- Haykin, Simon.(2002). Adaptive Filter Theory. 4th ed. Upper Saddle River, NJ, USA; Prentice Hall.
- Litva, J., & Lo, T. K. (1996). Digital beamforming in wireless communications. Artech House, Inc..
- Medeiros, Talles Henrique de. Treinamento de Redes Neurais Artificiais com Otimizao Multi-objetivo e Regularizao Bayesiana: um estudo comparativo. Minas Gerais: UFMG, Programa de Ps Graduao, 2004, pgina 28.
- Sallomi, Adheed Hassan and Albanee, Sulaiman A. G. Smart Antenna Adaptive Beam Forming Base on Neural Network with Different Training Algorithms. *Journal of Engineering and Sustainable Development* Vol. 20, No. 03, May 2016 ISSN 2520-0917 www.jeasd.org.
- Ribeiro, Antonio et al. Um algoritmo RLS-LMS usando combinao afim de filtros adaptativos para conformao de feixe em antenas inteligentes. In: Anais do 14^o Simpsio Brasileiro de Automao Inteligente, 2019, Ouro Preto. Anais eletrnicos. Campinas, Galo, 2019. 10.17648/sbai-2019-111446.
- Srar, J. A., & Chung, K. S. (2009, January). Adaptive RLMS algorithm for antenna array beamforming. In TENCON 2009-2009 IEEE Region 10 Conference (pp. 1-6). IEEE.
- Stoica, P., & Moses, R. L. (1997). Introduction to spectral analysis. Upper Saddle River, NJ: Prentice hall.
- Widrow, B. & Haykin, Simon. (2003). Least-mean-square adaptive filters. New York: Wiley-Interscience.
- Widrow, B., Mantey, P. E., Griffiths, L. J., & Goode, B. B. (1967). Adaptive antenna systems. *Proceedings of the IEEE*, 55(12), 2143-2159.