

Uma Proposta para Equalização Baseada em Redes Neurais Recorrentes e Sistemas Imunológicos Artificiais

Leonardo Tomazeli Duarte, Romis Ribeiro de Faissol Attux, Rafael Ferrari, Leandro Nunes de Castro, Fernando José Von Zuben e João Marcos Travassos Romano

Resumo—Neste trabalho, é proposto um novo método inspirado em um modelo de rede imunológica artificial para treinamento de equalizadores baseados em redes neurais recorrentes. A abordagem tem por objetivo a superação prática das principais dificuldades existentes no treinamento desse tipo de estrutura, como a presença de mínimos locais e o risco de instabilidade. Os resultados obtidos atestam a eficiência da metodologia proposta.

Palavras-Chave—Equalização de Canais, Redes Neurais Recorrentes, Redes Imunológicas Artificiais, Computação Evolutiva.

Abstract—In this work, a novel approach to the training of equalizers based on a recurrent neural network model is proposed. The rationale of this new approach, which is founded on an artificial immune network model, is to overcome in practice the main drawbacks related to the training of this kind of structure, such as the convergence to local minima and the risk of instability. The obtained results show the efficacy of the proposed methodology.

Keywords—Channel Equalization, Recurrent Neural Networks, Artificial Immune Network, Evolutionary Computing.

I. INTRODUÇÃO

Um dos principais empecilhos ao adequado funcionamento de sistemas de comunicação digital de alta velocidade é a existência de interferência inter-simbólica (IIS). Por apresentar boas soluções frente a este problema, a teoria de equalização de canais vem sendo, há muitos anos, um tema de pesquisa de grande relevância.

Na década passada, a introdução de equalizadores baseados em redes neurais artificiais [1][2][3] tornou possível a equalização de certos canais intratáveis a partir de equalizadores lineares. Em um primeiro momento, foram utilizadas ferramentas clássicas, baseadas no emprego do vetor gradiente [2][3], para realização do treinamento desses equalizadores. Tal opção pode ser problemática, pois a tarefa de treinar uma rede neural implica, via de regra, em um problema de otimização com caráter multimodal.

Leonardo Tomazeli Duarte, Romis Ribeiro de Faissol Attux, Rafael Ferrari, Fernando José Von Zuben e João Marcos Travassos Romano, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, Brasil; Leandro Nunes de Castro, Universidade Católica de Santos, Santos, Brasil, E-mails: lduarte@decom.fee.unicamp.br, romisri@decom.fee.unicamp.br, rferrari@decom.fee.unicamp.br, lnunes@unisantos.edu.br, vonzuben@dca.fee.unicamp.br, romano@decom.decom.fee.unicamp.br. Os autores gostariam de agradecer à Fapesp e ao CNPq pelo apoio recebido.

A crescente difusão do estudo desses dispositivos não-lineares popularizou a formulação da tarefa de equalização como um problema de classificação de padrões. Sob esta nova óptica, foi possível entender a razão da ineficiência de equalizadores sem realimentação em cenários onde o canal apresenta zeros sobre -1 e $+1$, o que, em termos práticos, leva à existência de estados coincidentes. Constatou-se também que, nessa situação, é imperativo o uso de equalizadores recorrentes para que tenha lugar uma transmissão satisfatória [4].

Nesse contexto, uma possibilidade é a utilização de equalizadores baseados em redes neurais recorrentes, pois, além de apresentarem condições para superar o problema mencionado, esses dispositivos são capazes de operar diante de canais com caráter não-linear. Entretanto, no treinamento desse tipo de estrutura, é significativo, além do caráter multimodal mencionado, o risco de instabilidade trazido pela presença da realimentação. Logo, caso se deseje aproveitar todo o potencial de uma rede neural recorrente, tornar-se-á necessário buscar novos paradigmas de treinamento capazes de superar as dificuldades mencionadas, em implementações práticas.

Nesse sentido, no presente trabalho é proposto um novo método de treinamento baseado em uma técnica evolutiva, inspirada no funcionamento do sistema imunológico artificial [5], e denominada opt-aiNet (*Artificial Immune Network for Optimization*). O principal ponto que motiva nossa proposta é que a opt-aiNet se sobressai, dentre outros métodos da computação evolutiva, por sua capacidade de realizar busca em superfícies onde existem um grande número de mínimos locais. Ademais, em outros trabalhos [6][7], a eficácia da opt-aiNet pôde ser verificada junto a problemas semelhantes de processamento de sinais.

A organização deste trabalho será feita da seguinte maneira. Na seção II, será apresentada uma breve descrição do problema de equalização, bem como as motivações para o uso de redes neurais recorrentes neste problema. Na seção III, exporemos a nossa proposta e também os fundamentos da opt-aiNet. Em seguida, na seção IV, serão discutidos os resultados das simulações realizadas com o fim de avaliar a presente proposta. Por fim, na seção V, uma conclusão encerra o trabalho.

II. A UTILIZAÇÃO DE REDES NEURAIS RECORRENTES NO PROBLEMA DE EQUALIZAÇÃO

A. Equalização de Canais

A idéia essencial de um sistema de comunicação é garantir que a informação enviada por um transmissor possa ser obtida

de maneira tão fiel ao original quanto possível por um receptor. Na Figura 1, é apresentado um modelo simplificado de um sistema de comunicação. O canal representa o meio físico por onde a informação se propaga, sendo responsável pela introdução de distúrbios no sinal transmitido, os quais, por sua vez, fazem com que o sinal recebido difira do original. Logo, qualquer tentativa de recuperar diretamente os dados a partir da observação da saída do canal sem que seja feito um processamento adequado, pode conduzir a transmissões com altas taxas de erro.

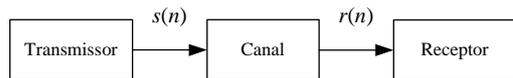


Fig. 1. Modelo Simplificado de um Sistema de Comunicação

Uma possível estratégia para evitar a degradação da transmissão causada por estes distúrbios é a introdução, no receptor, de um filtro que, em termos gerais, deve contrabalançar a ação do canal. Esta estratégia, exibida na Figura 2, é conhecida como equalização, e, analogamente, o filtro inserido no receptor é denominado equalizador.

De modo geral, o projeto de um equalizador de canal abrange três pontos principais. O primeiro deles nos remete à definição da estrutura do equalizador. O segundo ponto diz respeito à determinação de um critério de otimização que norteie a busca por um conjunto de parâmetros do equalizador. Por fim, é necessário selecionar uma técnica de otimização que realize a busca pelos valores ótimos desses parâmetros. É importante frisar que esta divisão possui um caráter eminentemente didático, pois, como veremos, é possível que haja uma estreita relação entre esses passos.

Quanto ao critério de otimização, este deve representar de uma maneira adequada o propósito da equalização, ou seja, o critério deve ser capaz de discriminar as soluções que resultem em uma transmissão satisfatória. É possível classificar esses critérios de acordo com a existência, ou não, de um sinal piloto, o qual, na formulação da função custo, é comumente uma réplica do sinal transmitido. No primeiro caso, a busca pelos parâmetros é dita supervisionada, enquanto no último é dita não-supervisionada ou cega.

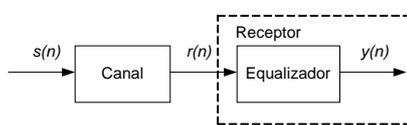


Fig. 2. O Esquema de Equalização

No paradigma supervisionado, merece destaque o critério de Wiener, cuja função custo é uma medida de erro quadrático médio a ser minimizada (MEQM)

$$J_W = E[(s(n-d) - y(n))^2], \quad (1)$$

onde $s(n)$ é o sinal transmitido, $y(n)$ é a saída do equalizador e d é o atraso de equalização. Sendo a saída $y(n)$ dependente dos parâmetros do equalizador, é possível concluir que J_W também é uma função desses parâmetros.

Um outro aspecto importante do projeto de um equalizador é a escolha de sua estrutura. Nesta etapa, em vez de considerar o problema de equalização sob a óptica da MEQM, é interessante enxergá-lo como um problema de classificação, o que é possível devido ao fato de que, em sistemas digitais, as amostras transmitidas sempre pertencem a um alfabeto finito.

O tratamento da equalização como um problema de classificação traz algumas vantagens que são particularmente úteis no estudo de equalizadores não-lineares. Por exemplo, esta abordagem permite verificar por que mesmo em alguns cenários com canais lineares é imperativo o uso de equalizadores não-lineares. Um outro ponto relevante é que essa abordagem abre espaço para a utilização de ferramentas originárias da área de inteligência computacional [8] capazes de realizar tarefas de classificação (e.g. redes neurais).

Todavia, quando a estrutura do equalizador é baseada em uma rede neural (que é uma estrutura não-linear), a função custo (1) possui caráter multimodal, ou seja, apresenta mínimos locais que podem comprometer o desempenho de métodos de otimização baseados no gradiente e mesmo em derivadas de ordem superior. Logo, se por um lado as redes neurais são eficazes numa ampla gama de canais, por outro esses dispositivos tornam o processo de busca pelos parâmetros um tanto mais complicado. Neste sentido, é de grande importância a busca por métodos de otimização que permitam o aproveitamento de todo o poderio de tais estruturas.

De fato, essa busca é um dos fatores que motivam nossa proposta. Uma outra questão tratada neste trabalho refere-se à necessidade de utilizar estruturas não-lineares com realimentação, na equalização de alguns canais. O emprego deste tipo de estrutura dificulta ainda mais o processo de busca, pois com a presença da realimentação problemas referentes à estabilidade passam a existir. Na próxima subseção, trataremos com mais detalhes da aplicação de redes neurais recorrentes, bem como dos casos em que esta aplicação é necessária e das dificuldades existentes no treinamento deste tipo de estrutura.

B. Aplicação de Redes Neurais Recorrentes ao Problema de Equalização

Sendo possível abordar o problema de equalização como uma tarefa de classificação, consideremos a seguinte situação. Em certos canais, o problema de classificação resultante pode apresentar uma peculiaridade capaz de comprometer o desempenho do equalizador. Essa situação ocorre quando dois ou mais padrões distintos a serem classificados ocupam o mesmo lugar no espaço, o que implica na impossibilidade de separação destes dois padrões.

Geralmente, essa situação ocorre em canais que apresentam zeros sobre os pontos -1 e $+1$ [9]. A principal forma de superar esse problema é fazer com que os equalizadores utilizem como entradas, além do sinal de saída do canal, suas saídas nos instantes anteriores. Esta nova informação permite ao equalizador realizar a tarefa de classificação em um novo espaço, onde é possível classificar de maneira adequada os padrões distintos. Logo, para resolver esse problema é preciso migrar para o campo dos equalizadores recorrentes.

Uma possibilidade é utilizar o bem conhecido DFE (*Decision Feedback Equalizer*), um filtro *quase-linear* cujo modo de operação é baseado em uma unidade de processamento linear e na realimentação das decisões passadas. Entretanto, em canais com caráter não-linear acentuado, o DFE pode apresentar uma severa degradação de desempenho [3]. Assim sendo, caso se deseje um equalizador que seja o mais genérico possível, torna-se necessário adotar estruturas que, além de poderem superar o problema de padrões coincidentes na classificação, sejam capazes de operar em um cenário não-linear. Uma possibilidade natural é a utilização de uma rede neural recorrente (RNR).

Um modelo típico de rede neural recorrente apresenta um conjunto de k neurônios totalmente conectados entre si e com as m entradas existentes. A peculiaridade deste dispositivo frente às redes neurais sem realimentação é que, nesse caso, o vetor de entradas contém, além das entradas externas, as saídas de todos os neurônios obtidas no instante anterior. Destarte, a dinâmica deste modelo de RNR é dada por

$$\mathbf{t}(n+1) = W \cdot \mathbf{u}(n), \quad (2)$$

$$\mathbf{o}(n+1) = f(\mathbf{t}(n+1)), \quad (3)$$

onde $\mathbf{o}(n+1)$ é um vetor cujos elementos correspondem às saídas de cada neurônio no instante $n+1$, o vetor $\mathbf{u}(n)$ é resultado da concatenação do vetor $\mathbf{o}(n)$ com um vetor de entradas externas $\mathbf{x}(n)$, e W é uma matriz $k \times (k+m)$ cujos elementos correspondem aos pesos sinápticos da rede. Adotamos em nosso trabalho a função tangente hiperbólica como função de ativação $f(\cdot)$. Em aplicações em que é desejada a presença de apenas uma saída, como é o presente caso, basta atribuir como saída global do sistema a saída de um neurônio qualquer.

No contexto de equalização, em [10] é apresentada uma estrutura de RNR que considera, além da realimentação das saídas dos neurônios, a realimentação das decisões passadas do equalizador, de uma maneira análoga ao que ocorre no DFE. Nesse trabalho constatou-se através de simulações preliminares que esta modificação pode acarretar em um ganho de desempenho. Diante disso, adotamos esse tipo de estrutura em nosso trabalho.

No tocante às vantagens da utilização de RNR em equalização, é importante ressaltar, além da capacidade de tal estrutura lidar com canais com zeros sobre a circunferência de raio unitário e com canais cuja solução só é alcançada através de dispositivos não-lineares, a parcimônia em termos do número de neurônios das soluções obtidas por essa abordagem frente a outros paradigmas de equalização baseados em modelos de redes neurais que não possuem realimentação, o que acarreta em um menor esforço computacional realizado durante a transmissão.

Todavia, se por um lado os benefícios presentes em equalizadores baseados em RNR são proporcionados pela complexidade de sua estrutura, por outro esta complexidade torna a etapa de ajuste dos pesos sinápticos uma tarefa árdua. O cerne de nosso trabalho está exatamente nesta questão, ou seja, na de propor um método de treinamento que consiga realizar adequadamente esta difícil tarefa. Na próxima seção,

apresentaremos os principais problemas a serem superados, bem como os fundamentos de nossa proposta.

III. PARADIGMA DE TREINAMENTO DE REDES NEURAIAS RECORRENTES

Conforme temos visto ao longo deste trabalho, redes neurais recorrentes são dispositivos com enorme capacidade de aproximação e, além disso, classificadores privilegiados pela disponibilidade de informações acerca das saídas (ou decisões) passadas. Tais características fazem dessas redes opções naturais quando é preciso equalizar sistemas reconhecidamente complexos ou canais sobre os quais há pouca informação disponível.

Tais virtudes, no entanto, serão meras idealizações a menos que a rede seja projetada segundo um método capaz de lidar adequadamente com três aspectos essenciais:

1) A significativa complexidade de qualquer função custo que tenha como domínio aquele engendrado pelos parâmetros da estrutura. Mesmo sob a égide do paradigma de Wiener, deparar-nos-emos, por exemplo, com mínimos locais ruins que, se escolhidos pela técnica de otimização, poderão levar a um desempenho bastante insatisfatório.

2) A presença de um laço de realimentação é uma fonte perene de instabilidade potencial que, se tornada concreta, pode comprometer decisivamente o processo de busca.

3) O cálculo do gradiente de uma função custo com respeito aos parâmetros de um filtro é uma tarefa assaz complexa quando se lida com uma estrutura recorrente e, além disso, não-linear. Por esse motivo, métodos de otimização baseados no cálculo das derivadas da função custo dependem amiúde de aproximações.

Destarte, para que fosse obtido um paradigma de treinamento verdadeiramente robusto, seria necessário que ele tivesse três características principais:

1') Grande capacidade de busca global, ou seja, de evitar mínimos locais ruins.

2') Robustez à existência de eventuais soluções instáveis.

3') Dependência exclusiva dos valores da função custo em si, sem a necessidade de informações de suas derivadas.

Dentre as técnicas dotadas de características que vão ao encontro dessa tríade, optamos neste trabalho por uma rede imunológica artificial, denominada opt-aiNet [5][11], por três motivos principais:

a) Trata-se de uma ferramenta de otimização dotada de mecanismos eficientes de busca local e global.

b) O algoritmo de busca em que se baseia a opt-aiNet contém mecanismos de controle dos recursos computacionais envolvidos.

c) A técnica vem sendo usada com sucesso em problemas similares da área de processamento de sinais [6][7].

Tratemos, pois, de analisar mais detalhadamente a ferramenta escolhida.

A. O Algoritmo Opt-aiNet

A rede imunológica artificial opt-aiNet [5][11] é uma técnica de busca cujo modus operandi tem por inspiração o funcionamento do sistema imunológico das espécies

superiores. O processo se baseia em duas teorias: o princípio da seleção clonal e a teoria da rede imunológica.

De acordo com o princípio da seleção clonal, quando determinadas células de defesa encontram agentes causadores de doenças (patógenos), elas iniciam um processo de replicação cuja intensidade é proporcional à sua capacidade de reconhecer o corpo estranho. Assim, quanto mais preciso for o reconhecimento, maior será a replicação. Por outro lado, no processo de geração de novas células ocorrem mutações de caráter inversamente proporcional à afinidade (*fitness*) ao nível de ajuste entre defensor e invasor. A apreciação conjunta desses dois fenômenos indica que um célula pouco adaptada a um dado patógeno tenderá a sofrer uma mutação mais pronunciada, enquanto uma célula mais eficiente tenderá a se modificar menos. Esse mecanismo pode ser entendido como um engenhoso método de busca capaz de aliar varreduras mais amplas a sutis refinamentos.

Já a teoria da rede imunológica nos oferece uma visão bastante distinta, pois nela é contemplada a possibilidade de células do sistema se reconhecerem mutuamente e, a partir disso, engendrarem modificações mesmo na ausência de antígenos.

A opt-aiNet surge a partir da aplicação do arcabouço conceitual subjacente a essas duas teorias à solução de problemas de otimização [5]. Na Figura 3, apresentamos uma descrição completa das etapas que constituem o algoritmo.

O objetivo da técnica exposta é otimizar uma função que expresse o grau de afinidade entre a célula defensora e o patógeno, uma medida que, na área de computação evolutiva, é muitas vezes chamada de *fitness*. Os argumentos dessa função são as possíveis soluções do problema, parâmetros reais que emulam, por assim dizer, o caráter estrutural das células do sistema. Em termos simples, os passos 2.1 a 2.5 podem ser entendidos como um processo de busca baseado num operador de mutação proporcional à qualidade (*fitness*) da solução. A eventual conclusão desse processo depende, por sua vez, de uma avaliação descrita no passo 2.6. O passo 2.7 é a base do caráter de rede imunológica, pois se baseia exclusivamente nas características da população de soluções. Do ponto de vista técnico, esse passo é um interessante mecanismo de controle do tamanho da população, pois tende a eliminar aglomerações redundantes de indivíduos em determinadas regiões do espaço de busca. Por fim, o passo 2.8 permite que sejam introduzidos novos indivíduos, os quais, por sua vez, potencialmente contribuirão com novas e enriquecedoras configurações.

Tendo definido o algoritmo, estamos prontos a analisar sua aplicação ao ajuste dos parâmetros de um equalizador neural recorrente. É disso que nos ocuparemos agora, e começaremos por uma descrição mais detalhada dos modelos adotados e das diversas opções pertencentes aos terrenos da estrutura de filtragem e do algoritmo de busca.

IV. RESULTADOS

A. Considerações Iniciais

Nas simulações apresentadas neste trabalho, consideramos que o sinal transmitido pertence a um alfabeto binário $\{-1,$

- 1 . Inicialização: A população inicial é gerada aleatoriamente.
- 2 . Até que o critério de parada escolhido seja obedecido, faça:
 - 2.1 . Cálculo do *fitness*: determine, para cada indivíduo, o *fitness*, que é uma medida direta do custo associado à solução.
 - 2.2 . Replicação: produza um número N_c de cópias (clones) de cada indivíduo da população.
 - 2.3 . Mutação: imponha um processo de mutação a $N_c - 1$ das cópias produzidas. A mutação segue a seguinte regra:

$$c' = c + \alpha N(0, 1)$$

$$\alpha = (1/\beta) \exp(-f^*)$$

$N(0, 1)$ é a variável normal padrão, a é um parâmetro livre que controla o nível da mutação, c é um clone genérico, c' é o indivíduo após a mutação e f^* é o *fitness*, normalizado para permanecer em um intervalo $[0, 1]$.
 - 2.4 . Cálculo do *fitness*: Calcule o *fitness* de todos os clones de todos os indivíduos.
 - 2.5 . Seleção: Selecione o melhor indivíduo de cada grupo formado pelo indivíduo original e seus $N_c - 1$ clones modificados pelas mutações.
 - 2.6 . Convergência Local: Se o *fitness* médio da população não variar significativamente, retorne ao passo 2.1. Caso contrário, continue.
 - 2.7 . Interações na Rede: Determine a afinidade (grau de similaridade) entre todos os pares de indivíduos da população, através de uma medida de distância euclidiana. Suprima todos os indivíduos exceto aqueles que, dentro de um certo par com afinidade menor que um valor σ_s , tenham maior *fitness*. Determine ainda o número de indivíduos da rede, denominados células de memória, que permanecerão.
 - 2.8 . Introdução de Diversidade: Introduza um certo número de indivíduos gerados aleatoriamente.
- 3 . Fim do laço

Fig. 3. Descrição do algoritmo opt-aiNet.

+1} e que suas amostras são independentes e identicamente distribuídas (i.i.d.). É importante também tecer algumas considerações acerca da implementação da opt-aiNet. A primeira delas é que, na descrição do algoritmo mostrada na Fig 3, um indivíduo corresponde a um vetor real cujos elementos representam os parâmetros do equalizador. Portanto, no caso do equalizador RNR, a dimensão desse vetor deve ser igual ao número total de elementos (pesos sinápticos) da matriz W que, no caso, é $k \cdot (k + m)$.

Um outro ponto é que a opt-aiNet é uma ferramenta que busca pelos múltiplos máximos de uma função custo. Entretanto, a base de nossa abordagem é utilizar essa técnica para minimizar o critério de Wiener apresentado na Eq. 1. Por conseguinte, é conveniente definir o *fitness* como

$$J_{FIT} = \frac{1}{J_W + 1}, \quad (4)$$

onde J_W é uma estimativa da Eq. 1 obtida via média temporal. Por fim, dado que estamos trabalhando com o ajuste de parâmetros de um sistema dinâmico, é preciso descartar eventuais transitórios no cálculo dessa estimativa.

Para verificar o desempenho de nossa proposta, consideramos dois cenários diferentes. No primeiro deles, o

canal apresenta zeros sobre -1 ou +1. Já no segundo, o canal é não-linear. Voltemos, pois, nossa atenção aos resultados obtidos.

B. Canal Linear com Zeros sobre a Circunferência Unitária

Neste primeiro cenário, é considerado o seguinte canal

$$r(n) = s(n) + 2s(n - 1) + s(n - 2) + \nu(n), \quad (5)$$

onde $r(n)$ e $s(n)$ correspondem, respectivamente, aos sinais recebido e transmitido e $\nu(n)$ representa um ruído aditivo branco com distribuição gaussiana de média nula (AWGN).

A estrutura da RNR utilizada como equalizador é dotada de 3 neurônios ($k = 3$) e 3 entradas ($m = 3$), sendo que duas correspondem às amostras atrasadas da saída do canal e uma à decisão obtida no instante anterior. O atraso de equalização usado é $d = 0$. A Tabela I apresenta os parâmetros da opt-aiNet utilizados neste cenário. Em todas as simulações realizadas neste trabalho, tanto a dimensão da RNR quanto os parâmetros da opt-aiNet foram obtidos a partir de ensaios preliminares.

TABELA I
PARÂMETROS DA OPT-AINET - PRIMEIRO CENÁRIO

Parâmetros	Valores
População inicial	5
Clones por indivíduo (N_C)	5
σ_s	10
β	30

Para cada treinamento do equalizador RNR foram utilizados 3000 símbolos transmitidos e, para a estimativa temporal do fitness, utilizou-se uma janela de 250 amostras. Na Figura 4, é apresentado o desempenho do equalizador RNR em termos da taxa de erro de bit (BER). A curva de BER obtida para o equalizador RNR representa uma média de 10 simulações. Ainda nesta figura, é apresentado o desempenho do equalizador Bayesiano [12] (com duas entradas e atraso de equalização zero), que corresponde à solução ótima de memória finita no sentido da minimização da probabilidade de erro da abordagem amostra-a-amostra.

A comparação entre as performances desses dois equalizadores nos permite verificar a importância da recorrência no equalizador no cenário em questão. Em contraste com o equalizador RNR, que sempre apresenta bom desempenho, observa-se que, a partir de um certo valor de SNR, a taxa de erro do equalizador Bayesiano, que é uma estrutura *feedforward*, tende a permanecer constante. Conforme já mencionado, isto ocorre devido à existência de dois estados distintos coincidentes no espaço de classificação. Assim sendo, mesmo sem ruído, há uma chance constante de erro quando esse equalizador recebe como entrada um dos estados coincidentes, pois é impossível discriminar entre ambos. Os estados do canal e a fronteira de decisão do equalizador Bayesiano são mostrados na Figura 5. Note os estados coincidentes em (0,0).

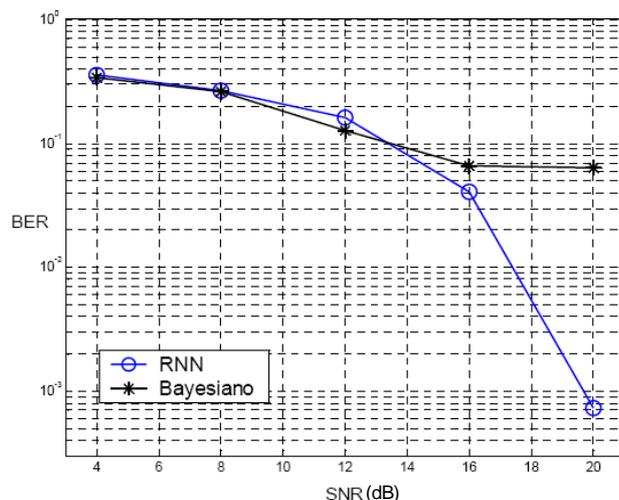


Fig. 4. Desempenho do equalizador RNR.

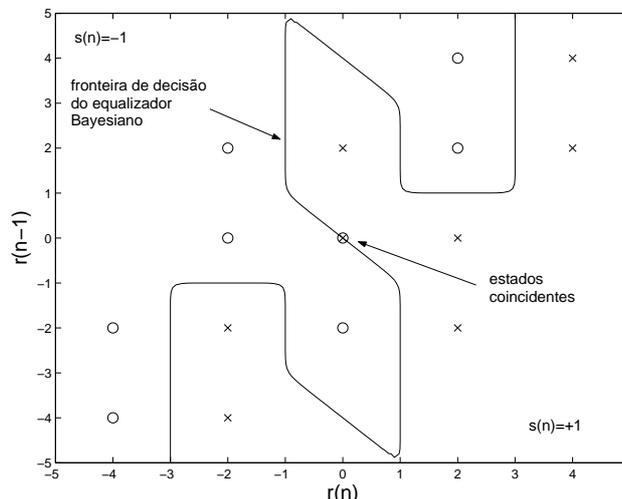


Fig. 5. Estados do canal linear e fronteira de decisão do equalizador Bayesiano com duas entradas e $d = 0$ (SNR=15dB).

C. Canal Não-Linear

No outro cenário escolhido para a avaliação da presente proposta, foi considerado o seguinte canal não-linear

$$r(n) = x(n) + 0,3x(n)^2 + \nu(n), \quad (6)$$

onde $x(n)$ representa o efeito da interferência inter-simbólica, que, no caso, é dado por

$$x(n) = 0,5s(n) + s(n - 1). \quad (7)$$

Neste cenário, fizemos uso de um equalizador RNR com 4 neurônios e 3 entradas, sendo que 2 correspondem às amostras atrasadas da saída do canal e uma à decisão obtida no instante anterior. Os parâmetros da opt-aiNet foram ajustados de acordo com a Tabela II.

A eficácia do treinamento do equalizador pode ser verificada na Figura 6. Nesta figura, é apresentada a evolução do fitness do melhor indivíduo de cada iteração, considerando uma

TABELA II
PARÂMETROS DA OPT-AINET - SEGUNDO CENÁRIO

Parâmetros	Valores
População inicial	5
Clones por indivíduo (N_C)	5
σ_s	2,5
β	60

transmissão com SNR = 20 dB. Tendo em vista a expressão (4), a convergência do *fitness* para um valor próximo de 1 significa que, durante a etapa de treinamento, o erro quadrático atingiu um valor próximo a zero.

Ainda na Figura 6, é apresentada a evolução do *fitness* médio da população. Observa-se que existe uma considerável diferença entre a evolução de ambos, ou seja, durante toda a evolução, a população apresenta um alto índice de diversidade que, por sua vez, é uma condição determinante para uma busca bem-sucedida em superfícies repletas de mínimos locais, como é o presente caso. De fato, esta é uma das grandes vantagens da opt-aiNet em relação às técnicas evolutivas tradicionais, como por exemplo, os algoritmos genéticos, aliada à definição automática do tamanho da população ao longo do processo de busca.

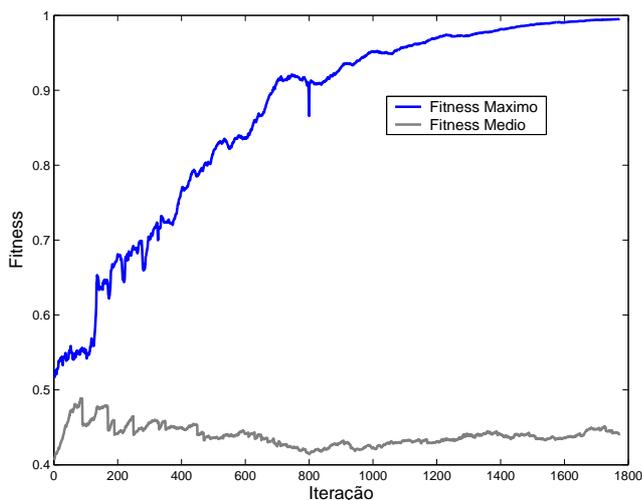


Fig. 6. Evolução do *fitness*.

V. CONCLUSÕES

Neste trabalho, foi proposto um novo paradigma de treinamento para equalizadores baseados em redes neurais recorrentes. A base de tal proposta é uma técnica evolutiva de busca cuja inspiração é o funcionamento do sistema imunológico das espécies superiores.

Dois cenários foram considerados para verificar o desempenho da presente proposta. Em ambos, a opt-aiNet produziu resultados que atestam sua capacidade de evitar a convergência para mínimos locais, que, por sua vez, é exatamente a principal desvantagem das técnicas de treinamento baseadas no gradiente.

Uma limitação inerente ao treinamento via opt-aiNet é a sua considerável complexidade computacional frente às

técnicas clássicas. Entretanto, o rápido e constante avanço dos processadores digitais de sinal abrem boas perspectivas para a viabilidade da presente proposta. Além do mais, é importante ressaltar que o problema em questão ainda não possui um tratamento adequado a partir de técnicas com menor complexidade computacional do que a utilizada neste trabalho. Finalmente, frisamos que a contribuição exposta, embora ligada ao contexto de equalização, pode ser diretamente estendida a outras aplicações de ajuste de parâmetros em filtragem.

REFERÊNCIAS

- [1] B. Mulgrew, "Applying Radial Basis Functions" *IEEE Signal Processing Magazine*, Março 1996.
- [2] G.J. Gibson, S. Siu, and C.F.N. Cowan, "The Application of Nonlinear Structures to the Reconstruction of Binary Signals" *IEEE trans. on Signal Processing*, v. 39, no. 8 p. 1877-1884, Agosto 1991.
- [3] G. Kechriotis, E. Zervas and E.S. Manolakos, "Using Recurrent Neural Networks for Adaptive Communication Channel Equalization" *IEEE transactions on Neural Networks*, v. 5, no. 2 p. 267-278, Março 1994.
- [4] M. T. M. Silva, M. Gerken, M. D. Miranda, "Estruturas não-lineares aplicadas à recuperação de sinais binários", *Simpósio Brasileiro de Telecomunicações*, Gramado, 2000.
- [5] L. N. de Castro and J. I. Timmis, *Artificial Immune Systems: A New Computational Intelligence Approach*. Springer-Verlag, London, 2002.
- [6] R. R. de F. Attux, M. B. Loiola, R. Suyama, L. N. de Castro, F. J. Von Zuben, J. M. T. Romano "Blind Search for Optimal Wiener Equalizers Using an Artificial Immune Network Model" *EURASIP Journal of Applied Signal Processing, Special Issue on Genetic and Evolutionary Computation for Signal Processing and Image Analysis.*, 2003.
- [7] R. R. de F. Attux, L. N. de Castro, F. J. Von Zuben, J. M. T. Romano "A Paradigm for Blind IIR Equalization using the Constant Modulus Criterion and an Artificial Immune Network" *Proceedings of IEEE Neural Networks for Signal Processing*, p. 839-848, Paris, França, 2003.
- [8] J. M. Zurada, R. J. Marks II and C. J. Robinson, *Computational Intelligence Imitating Life*. IEEE Press, 1994.
- [9] J. R. Montalvão Filho, B. Dorizzi, J. C. M. Mota, "Some Theoretical Limits of Efficiency of Linear and Nonlinear Equalizers," *Revista da Sociedade Brasileira de Telecomunicações*, Vol. 14, p. 85-92, 1998.
- [10] W. Mo, L. Li, H. Jiang, "A Decision Feedback Recurrent Neural Networks Equalizer for Digital Communication" *APCC/OECC'99 Fifth Asia-Pacific Conference on Communications and Fourth Optoelectronics and Communications Conference*, v. 1, p. 102-105, Outubro 1999.
- [11] L. N. de Castro, J. Timmis, "An Artificial Immune Network for Multimodal Function Optimization," *Proc. of the IEEE Congress of Evolutionary Computation*, Vol. 1, p. 699-704, Honolulu, Hawaii, 2002.
- [12] S. Chen, B. Mulgrew, P. M. Grant, "A Clustering Technique for Digital Communications Channel Equalization using Radial Basis Function Networks", *IEEE Transactions on Neural Networks*, v. 4(4), p. 570-579, 1993.