

UMA VERSÃO EVOLUTIVA DO ALGORITMO DE GODARD

F. A. C. M. Cardoso, D. S. Arantes, J. M. Romano e J. B. Destro Filho
(cardoso; dalton; romano; destro)@decom.fee.unicamp.br

Departamento de Comunicações
Faculdade de Engenharia Elétrica e Computação
Universidade Estadual de Campinas - UNICAMP
Caixa Postal 6101, 13083-970, Campinas, SP

RESUMO

Neste trabalho a equalização autodidata é tratada como um problema de otimização de parâmetros com base no funcional proposto por Godard. Tal otimização é realizada num processamento por bloco de dados a partir de um Algoritmo Genético (AG) em conjunto com o tradicional algoritmo da descida na direção do vetor gradiente. O resultado é um algoritmo híbrido capaz de lidar com problemas relativos a mínimos locais e que se mostrou eficiente na equalização cega de sistemas QAM.

1. INTRODUÇÃO

Entre os algoritmos de equalização cega disponíveis na literatura, os de Godard [2] são provavelmente os mais conhecidos e estudados. Sabe-se que a minimização global de seu funcional é consistente com o objetivo de se minimizar a interferência intersimbólica (ISI) na saída de um equalizador. Sabe-se também que a convergência para um ponto de mínimo local pode representar uma solução não satisfatória para o problema de equalização, pois a ISI pode se manter em níveis inaceitáveis. Assim, algoritmos que se baseiam no gradiente teriam desempenho bastante limitado, pois são incapazes de distinguir entre mínimos locais e global. Isto nos serve como motivação para estudar o uso de Algoritmos Genéticos no problema de equalização autodidata.

Algoritmos Genéticos (AGs) [6], [7] e [3] são estratégias de busca que imitam o processo de evolução das espécies por meio da seleção natural e das leis da genética. O algoritmo inicia com uma amostragem muito restrita do espaço de parâmetros que irá constituir uma *população*. Cada amostra, ou seja, cada possível solução para o problema de busca é representada no algoritmo por uma ou mais seqüências de símbolos s gerados a partir de um alfabeto A . Estas seqüências são denominadas de *cromossomos* e cada versão codificada de uma amostra é denominada de *indivíduo*. Na sua forma mais simples o algoritmo representa uma amostra por um único cromossomo que é gerado a partir de um alfabeto binário $A = \{0, 1\}$. Neste caso, um cromossomo é simplesmente uma representação binária dos parâmetros quantizados. Para forçar a evolução desta população, define-se um conjunto de operações não lineares denominadas de *cruzamento*, *mutação* e *seleção natural*. Cruzamento é a troca de porções cromossômicas (bits) entre dois cromossomos. Mutação é a inversão aleatória de bits a uma taxa pré especificada. Seleção natural é a eliminação probabilística de indivíduos com base no funcional que se deseja minimizar (ou maximizar). Observe que a operação cruzamento aumenta o tamanho da população, enquanto que a operação de seleção restaura o tamanho inicial. A analogia com o processo biológico su-

gere que tal procedimento de busca conduzirá a soluções eficientes para problemas não lineares complexos.

Os Algoritmos Genéticos têm sido empregados com sucesso em diversas áreas do conhecimento (por exemplo, [8], [13], [5], [11] e [12]). A despeito de sua eficácia num processo de otimização global, sua aplicação em processamento de sinais tem sido relativamente limitada em função principalmente da baixa velocidade de convergência ([4] e [5]).

Assim, a solução proposta neste trabalho é a de um algoritmo híbrido, AG-Gradiente, que incorpora o algoritmo de descida de gradiente como mais uma operação do AG. O princípio geral é unir as características de um eficiente algoritmo de busca global com aquele que oferece simplicidade e rapidez na busca local. O objetivo é assim aumentar a velocidade de convergência do AG preservando sua eficiência. Mostra-se ainda que este algoritmo híbrido é robusto e não necessita de qualquer tipo de inicialização especial. Devido ao processamento por bloco de dados, este algoritmo requer poucas amostras de sinal para convergir. Por outro lado, a complexidade computacional é maior que a dos algoritmos tradicionais.

A técnica proposta é aplicada ao problema de equalização autodidata em transmissão digital utilizando o funcional de Godard, que é sabidamente multimodal. Sabe-se ainda que, ao se empregar este tipo de critério, erros de fase na recuperação da portadora tornam-se um problema adicional em sistemas cuja constelação é bidimensional, por exemplo, em sistemas QAM. A estratégia adotada consiste então em realizar conjuntamente a equalização e a recuperação da fase da portadora num processamento por bloco de dados.

Quanto à organização deste artigo, apresenta-se na Seção 2 uma formalização para o problema de otimização dentro do contexto evolutivo dos AGs. Uma descrição dos vários elementos do AG é apresentada na Seção 3. O algoritmo genético propriamente dito é apresentado na Seção 4. A modificação realizada no AG para incluir o método do gradiente é descrita na Seção 5. O método de estimação e correção do erro de fase da portadora é apresentado na Seção 6. A metodologia adotada na simulação do sistema é apresentada na Seção 7 e os resultados obtidos são apresentados e discutidos na Seção 8. Finalmente, as conclusões são apresentadas na Seção 9.

2. FORMALIZAÇÃO DO PROBLEMA

Considera-se neste trabalho a classe de canais cuja função de transferência é dada por

$$H(z) = \sum_{n=0}^{N-1} h(n) z^{-n}, \quad h(n) \in \mathbb{C},$$

onde $h(n)$ representa a resposta ao impulso de um canal complexo que inclui implicitamente qualquer tipo de erro de fase na recuperação da portadora. Este modelo de canal simula ainda o efeito de interferência mútua entre parte real e imaginária e interferência entre símbolos do sinal transmitido.

Suponha que o equalizador de ordem L ideal para este canal seja dado por

$$\check{H}(z) = \sum_{n=0}^{L-1} \check{h}(n) z^{-n}, \quad \check{h}(n) \in \mathbb{C}. \quad (1)$$

Isto significa que a interferência inter-simbólica residual neste caso é a mínima possível. Define-se ainda, conforme mostrado na Figura 1, $y(n)$ como amostras do sinal recebido em banda base e $u(n)$ como sendo o sinal equalizado. Isto significa que

$$u(n) = \sum_{k=0}^{L-1} c(k) y(n-k), \quad u(n), c(n) \text{ e } y(n) \in \mathbb{C},$$

onde $c(n)$ corresponde a uma estimativa do filtro procurado $\check{h}(n)$.

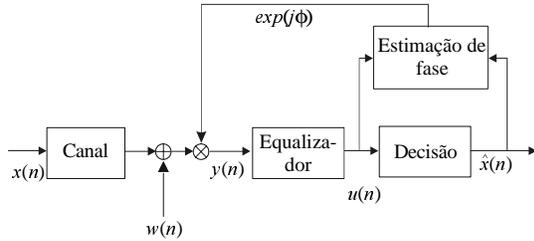


FIGURA 1: Equalização de canal num sistema de comunicação de dados com recuperação de fase da portadora.

Na aplicação de um AG na otimização do filtro $c(n)$, cada coeficiente c_i é codificado como uma “string” de números binários, conhecidos como *genes*. Os genes são então cascateados para formar uma “string” mais longa C , chamada *cromossomo*. Cada possível combinação dos parâmetros (coeficientes) estimados é, deste modo, representado por um cromossomo. A estratégia de otimização é aplicar o AG para procurar pelo melhor cromossomo C , de modo que um funcional seja minimizado. O funcional de Godard, aqui utilizado, é dado por

$$J(c(n)) = E \left[(|u(n)|^p - R_p)^2 \right], \quad (2)$$

onde R_p é uma constante definida por

$$R_p = \frac{E[|x|^{2p}]}{E[|x|^p]}.$$

A função risco (Equação 2) é estimada adaptando-se os coeficientes do equalizador em um bloco de dados. Neste caso, o filtro $c(n)$ é utilizado na equalização de todo o bloco para o qual ele foi calculado. Supondo que o bloco de dados tenha um comprimento d , uma estimativa do risco pode ser calculada por

$$\hat{J}_j^i = \frac{1}{d-1} \sum_{k=1}^d \left(|u_j^i(k)|^p - R_p \right)^2, \quad (3)$$

sendo $u_j^i(n)$ o sinal obtido pela filtragem do bloco de dados pelo filtro $c_j^i(n)$ associado ao j -ésimo cromossomo dos pesos estimados para a i -ésima geração.

Assim, numa população constituída por M cromossomos (indivíduos) dos pesos estimados, o algoritmo examina a população em cada geração i , na procura por um erro de estimação mínimo,

$$\hat{J}_{\min}^i = \min \left(\hat{J}_j^i \right), \quad \text{todo } j \in [1 \cdots N], \quad (4)$$

sobre o espaço total de coeficientes e força \hat{J}_{\min}^i a convergir para o mínimo global nas gerações sucessivas.

3. CARACTERÍSTICAS DO AG

Esta Seção descreve os vários elementos do AG, incluindo o mecanismo de codificação, o método de inicialização, a regra de seleção dos cromossomos pais, detalhes no procedimento de cruzamento, a introdução da mutação como um modo de evitar mínimos locais, bem como a estratégia de extinção e imigração criada por Yao [3].

1) **Codificação:** Cada parâmetro estimado é codificado em genes, como uma “string” de dígitos binários representados por um inteiro sem sinal. Optamos por utilizar um inteiro sem sinal de, no máximo, 64 bits para representar cada gene. Na verdade, são utilizados apenas $B_k \leq 64$ bits mais significativos, sendo que B_k é o comprimento, em bits, do k -ésimo gene. Desta forma, um cromossomo nada mais é do que um vetor de inteiros sem sinal. Supondo que os parâmetros se encontram no intervalo $[-\eta_k, \eta_k]$, isto é,

$$|w_k| \leq \eta_k \text{ para } k = 1, 2, \dots, h, \quad (5)$$

então, o comprimento B_k do k -ésimo gene pode ser calculado a partir de η_k e da precisão desejada, δ_k , como

$$B_k = \left\lceil \log_2 \left(\frac{2\eta_k}{\delta_k} \right) \right\rceil,$$

de modo que o comprimento efetivo total de bits, utilizados em um cromossomo, é dado por $\sum_{k=1}^h B_k$.

2) **Inicialização.** Os valores iniciais dos parâmetros estimados são aleatoriamente atribuídos. Portanto, no início do processo de estimação, Nh inteiros sem sinal, de 64 bits, são gerados para formar N vetores (cromossomos) com h genes, sendo que cada gene utilizará apenas B_k bits, dos 64 bits possíveis.

3) **Seleção.** A seleção de cromossomos pais é baseada na noção de “adequabilidade,” que governa a extensão em que um indivíduo pode influenciar gerações futuras. No AG, D cromossomos são selecionados, para cruzamento, com base na sua adequabilidade em relação à adequabilidade total de todos os cromossomos na geração. Neste trabalho, a adequabilidade para o j -ésimo cromossomo na i -ésima geração é definida como $e_{\max}^i - e_{ji}$, sendo que e_{\max}^i é o erro de estimação máximo na i -ésima geração. Além disso, esta medida é escalonada a partir de coeficientes α e β para atenuar os problemas relativos à pressão seletiva (Goldberg [6]). Assim, a probabilidade do j -ésimo cromossomo ser selecionado para cruzamento na próxima geração é dada por

$$P_j^i = \frac{\alpha (e_{\max}^i - e_{ji}) + \beta}{\sum_{k=1}^i [\alpha (e_{\max}^i - e_{ki}) + \beta]} \quad (6)$$

Visto que o critério de seleção é probabilístico, cromossomos representando conjuntos de parâmetros que estão próximos a valores ótimos podem ser descartados, resultando em uma convergência lenta. Sabendo-se que a melhora do erro de estimação requer que os melhores cromossomos estejam presentes na população, o AG é modificado para garantir que estes cromossomos sejam preservados em toda geração. Assim, adotando-se uma estratégia elitista, em uma população de N indivíduos, D são selecionados para cruzamento e os ρD ($\rho < 1$) melhores cromossomos entre esses N indivíduos são mantidos na geração seguinte.

Após a seleção dos D cromossomos pais, aplica-se o operador cruzamento para gerar $2D$ filhos. Como são repassados os ρD melhores indivíduos de uma geração para a outra, então, após o cruzamento, haverão $2D + \rho D$ indivíduos. Como este número deverá corresponder ao tamanho original N da população, então

$$N = 2D + \rho D,$$

ou seja,

$$\rho = \frac{N - 2D}{D}.$$

Visto então que os ρD melhores são preservados para a próxima geração, o erro de estimação mínimo na geração atual será sempre menor ou igual ao erro de estimação mínimo na geração anterior.

4) **Cruzamento.** Entre os D possíveis pais, $(N - \rho D) / 2$ possíveis pares de cromossomos são gerados. Cada um desses pares irá gerar dois outros cromossomos via o procedimento de recombinação, que imita o cruzamento biológico. Primeiro, um ponto de corte é aleatoriamente atribuído ao longo dos cromossomos:

Pai1	xxxxxxxxxxxxxxxx
Pai2	yyyyyyyyyyyyyy ↑ ponto de corte

Segundo, gera-se dois cromossomos filhos, sendo que o Filho 1 contém a parte inicial de Pai 1 e a final de Pai 2, enquanto que o Filho 2 contém a parte inicial de Pai 2 e a final de Pai 1:

Filho1	xxxxxyyyyyyyyyy
Filho2	yyyyyxxxxxxxxxxx

Supondo que o esquema xxxxx***** corresponda a um baixo erro de estimação, onde * representa um valor qualquer, então o Filho 1 poderia corresponder a um erro de estimação mais baixo do que qualquer outro cromossomo pai. É este procedimento (biologicamente inspirado) de cruzamento, bem como a eliminação dos cromossomos não “adequados,” que diferenciam os AGs de algoritmos cujo estilo de busca é puramente aleatório.

Neste trabalho, a recombinação de material genético é realizada por parâmetro (gene) e não por cromossomo, porque o número de possíveis filhos é maior no primeiro do que no segundo caso, aumentando-se, assim, o tamanho da região de busca realizada pela recombinação.

5) **Mutação.** Geralmente, ao longo de um período de várias gerações, a população tende a se tornar mais e mais estagnada quando um gene (parâmetro) começa a dominar. A mutação é frequentemente introduzida para evitar convergência prematura para uma

solução não ótima. A mutação altera aleatoriamente um determinado bit de um gene, de 0 para 1 ou de 1 para 0, com probabilidade P_m . O objetivo da mutação é introduzir perturbações ocasionais nos parâmetros estimados, para garantir que todos os pontos favoráveis no espaço de busca possam ser alcançados.

6) **Extinção e Imigração.** Pode-se mostrar que o número de cromossomos em uma população, associados com um erro de estimação pequeno, cresce exponencialmente. Portanto, depois de algumas gerações os D cromossomos pais escolhidos para cruzamento são muito semelhantes entre si. É óbvio que se dois pais são muito parecidos, seus filhos também serão, e nenhuma nova informação é obtida. A estimação tende deste modo a estagnar, restando apenas a mutação como mecanismo para gerar melhores cromossomos. Visto que P_m é geralmente pequena ($\leq 0,001$), a probabilidade de redução adicional do erro de estimação é muito pequena, especialmente para cromossomos longos. Yao [3] propôs uma técnica drástica, chamada extinção e imigração, para vencer esta dificuldade. Extinção elimina todos os cromossomos na geração atual, exceto o cromossomo correspondente ao erro de estimação mínimo. Assim, $N - 1$ cromossomos são então aleatoriamente gerados para substituir os cromossomos eliminados (uma imigração em massa) e $D = (N - 1) / 2$ cromossomos, entre estes imigrantes, são então selecionados como pais. A estes, juntamente com os cromossomos sobreviventes, é permitido cruzar para formar a próxima geração. Por conveniência, dizemos então que outra era se inicia. A operação Extinção e Imigração em conjunto com a mutação, é análoga à taxa de mutação variante com o tempo, na qual a probabilidade de mutação de bit resultante seria próxima de $1/2$ no início de cada era (pois novos indivíduos são gerados aleatoriamente), reduzindo-se em seguida para P_m (por exemplo, $0,001$) nas gerações restantes dentro da era.

A operação Extinção e Imigração deve ocorrer quando nenhum decréscimo adicional no erro de estimação mínimo for detectado em, digamos, L_e gerações.

4. ESTABELECENDO O ALGORITMO

Há vários parâmetros reguladores no algoritmo que devem ser atribuídos antes de executar o AG. Estes parâmetros são os seguintes:

N : número de cromossomos em cada geração.

D : número de cromossomos escolhidos como pais para cruzamento.

L_t : número de gerações toleradas caso nenhum progresso no erro de estimação mínimo seja observado antes do AG terminar.

L_e : número de gerações toleradas caso nenhuma melhora seja observada no erro de estimação mínimo antes que o operador extinção e imigração seja aplicado. Note que $L_e \ll L_t$.

P_m : probabilidade de mutação.

ρ : fração de pais sobreviventes na geração seguinte.

ξ : precisão desejada da estimação (em bits).

O Algoritmo Genético (AG) é resumido como segue:

1. Fixe os parâmetros reguladores como descrito acima. Codifique os pesos sinápticos a serem estimados em cromossomos. Faça $i = 0$, $k = 0$, e $m = 0$.
2. Inicialize N cromossomos, faça $i = i + 1$, $k = 0$, e $m = 0$.
3. Decodifique os cromossomos e calcule o erro de estimação e_{ij} para cada j -ésimo cromossomo na i -ésima geração. Faça $e_{\min}^i = \min_j (e_j^i)$.

4. Passe os ρD melhores pais para a próxima geração.
5. Selecione D pais e gere $(N - \rho D)$ filhos. Invoque a mutação com o procedimento de recombinação.
6. Se $e_{\min}^i = e_{\min}^{i-1}$, então

$$k = k + 1 \text{ e } m = m + 1;$$
 caso contrário, faça $k = 0$ e $m = 0$.
7. Se D pais são todos idênticos, aplique a operação de extinção e imigração retornando ao passo (1) e salve somente o cromossomo correspondente a e_{\min}^i . Faça $k = 0$.
8. Se $k = L_e$, então volte ao passo (7).
9. Se $m = L_t$ (ou $e_{\min}^i < \xi$), então termine o algoritmo; caso contrário, vá ao passo (2).

Note que se a variância do ruído de quantização é conhecida a priori e igual a ξ , então o AG é terminado se o erro de estimação é menor que ξ . Entretanto, se nenhuma informação estatística da medida do ruído é conhecida a priori, o AG é terminado quando nenhuma melhora no erro de estimação for detectada para L_t gerações.

5. ESQUEMA HÍBRIDO AG-GRADIENTE

O espaço de busca de um AG pode ser contínuo ou discreto, côncavo ou convexo e, além disso, a função objetivo pode ter muitos picos e vales. Mais ainda, a função objetivo definida neste espaço pode ser derivável ou não. Daí a robustez dos AGs. Entretanto, quando a função objetivo é contínua, derivável e tem apenas um ponto estacionário, os métodos baseados no gradiente convergem bem mais rapidamente e com um custo computacional menor do que os AGs. Isto revela que, apesar do AG ter a capacidade de escapar de ótimos locais, dentro de uma determinada região, dominada por um ponto estacionário, a eficiência dos métodos baseados no gradiente é maior. Surge então a idéia de integrar um algoritmo eficiente de busca global com outro algoritmo eficiente de busca local, utilizando assim o AG conjuntamente com o método do gradiente.

Existem inúmeras formas distintas de unir os dois métodos para compor um algoritmo híbrido. Neste trabalho a descida de gradiente é incorporada ao AG a partir da definição de um novo operador, chamado *mutaçãoG* que, ao ser aplicado à população, altera o melhor indivíduo com base no gradiente. O algoritmo híbrido AG-Gradiente é mostrado na Figura 2.

6. ESTIMAÇÃO DO ERRO DE FASE DA PORTADORA

Após a equalização de um bloco de sinal, o resultado na saída do equalizador será a constelação “procurada”, porém rotacionada por um ângulo ϕ , que pode ser representada por um ganho complexo do canal. Assim, para um dado bloco de sinal, se definirmos $\bar{\mathbf{u}}_{q_i}$ como um vetor médio de amostras de um sinal q -QAM detectadas como o símbolo complexo \mathbf{q}_i , uma estimativa inicial θ do ângulo ϕ será o ângulo médio entre os vetores $\bar{\mathbf{u}}_{q_i}$ e \mathbf{q}_i para todo i , ou seja,

$$\theta = \frac{1}{q} \sum_{i=1}^q \theta_i.$$

O sentido horário ou anti-horário de correção da fase será analisado de acordo com o seguinte critério:

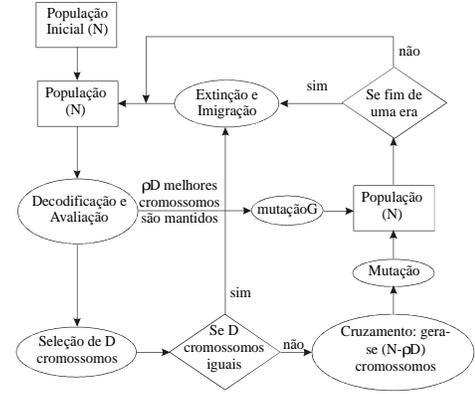


FIGURA 2: Esquema Híbrido AG-Gradiente.

- Se $\text{real}(\mathbf{q}_i) > 0$ e
 - Se $\text{imag}(\mathbf{q}_i) > \text{imag}(\bar{\mathbf{u}}_{q_i}) \Rightarrow \theta_i > 0$
 - Se $\text{imag}(\mathbf{q}_i) < \text{imag}(\bar{\mathbf{u}}_{q_i}) \Rightarrow \theta_i < 0$
- Se $\text{real}(\mathbf{q}_i) < 0$ e
 - Se $\text{imag}(\mathbf{q}_i) > \text{imag}(\bar{\mathbf{u}}_{q_i}) \Rightarrow \theta_i < 0$
 - Se $\text{imag}(\mathbf{q}_i) < \text{imag}(\bar{\mathbf{u}}_{q_i}) \Rightarrow \theta_i > 0$

O processo de tomada de decisão terá então que ser repetido com a correção de fase da portadora até que $|\theta| < \text{tol}$, onde tol é uma tolerância a ser fixada, por exemplo, $\text{tol} = 10^{-3}$. Salienta-se que a correção de fase da portadora nesta fase corresponde apenas a girar a constelação na entrada da tomada de decisão. Durante este processo, estima-se o ganho complexo $e^{j\phi}$ do equalizador, a ser utilizado na equalização do próximo bloco de dados, a partir da expressão

$$\phi(n) \leftarrow \phi(n-1) + \theta(n),$$

para $n = 1, 2, \dots$ com $\phi(0) = 0$.

7. METODOLOGIA

Para testar o algoritmo, os dados de entrada utilizados correspondem ao equivalente em banda base de um sinal QAM, isto é, $\{x(n) = x_R(n) + jx_I(n)\}$, onde $\{x_R(n)\}$ e $\{x_I(n)\}$ são duas seqüências PAM independentes assumindo os valores $\pm 1, \pm 3, \dots, \pm(M-1)$ com igual probabilidade. Dois filtros FIR de fase não mínima são utilizados para modelar o canal de comunicação. Estes filtros são caracterizados pela resposta em frequência e pelo diagrama de pólos e zeros mostrados na Figura 3. O ruído branco é modelado por $\{w(n) = w_R(n) + jw_I(n)\}$, onde $\{w_R(n)\}$ e $\{w_I(n)\}$ são seqüências Gaussianas independentes e idênticamente distribuídas. O equalizador é linear e com $L = 31$ coeficientes quantizados em genes de 32 bits. O intervalo de valores para os coeficientes varia de -8 a 8 . O desempenho do algoritmo é medido a partir dos seguintes critérios:

- O erro quadrático médio (EQM);
- A taxa de erro de símbolo (TES) estimada num bloco com d amostras;
- A constelação do sinal equalizado (CSE);

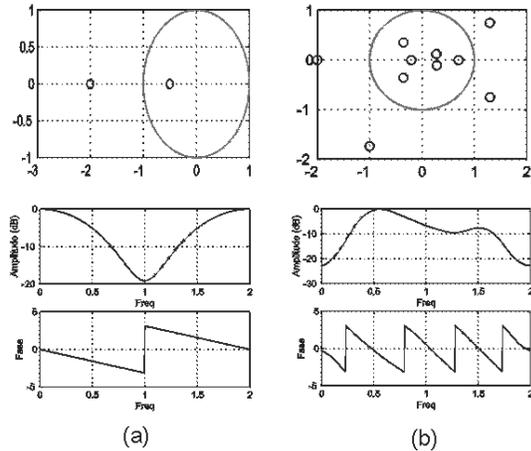


FIGURA 3: Filtros FIR utilizados para modelar canais de comunicação: (a) Canal 1; (b) Canal 2.

- A resposta ao impulso do sistema conjunto canal e equalizador.

Neste trabalho foram realizados três experimentos. O primeiro visa justificar a utilização de AGs na equalização de sistemas QAM a partir do funcional de Godard. Neste experimento mostra-se que, a partir de uma mesma condição inicial, o algoritmo híbrido converge para um ponto de equalização, enquanto o algoritmo da descida gradiente fixa-se num ponto de mínimo local que não equaliza o canal. A partir de resultados intermediários obtidos durante o processo de convergência, mostra-se no segundo experimento a habilidade do sistema implementado em detectar e corrigir erros na fase da portadora. Finalmente, no último experimento mostra-se a habilidade do sistema implementado na equalização de sistemas QAM.

8. RESULTADOS DE SIMULAÇÃO

No experimento 1 mostram-se curvas típicas do funcional de Godard ao longo das iterações dos algoritmos Gradiente e Híbrido. Para ambos os algoritmos a mesma condição inicial foi utilizada. Isto significa que para o algoritmo Híbrido, o melhor indivíduo da primeira iteração corresponde à condição inicial do Gradiente. Os resultados da Figura 4 mostram claramente que o algoritmo Híbrido (Figura 4(b)) conseguiu “driblar” o mínimo local no qual o Gradiente (Figura 4(a)) ficou preso. De fato, para este experimento o algoritmo Híbrido convergiu restaurando a constelação original com uma probabilidade de erro inferior a 3%.

O resultado do Experimento 2 é mostrado na Figura 6. Em cada passo da Figura 6(a) mostra-se o comportamento do ângulo θ como descrito na Seção 6. Para este experimento utilizou-se um bloco de sinal 64-QAM com 7000 amostras transmitidas sobre o Canal 2. A relação sinal-ruído é de 35dB. Mostra-se na Figura 6(b) a constelação inicial na entrada do dispositivo de decisão. A probabilidade de erro para esta constelação é de 26.81%. Observe pela Figura 6(c) que a fase da portadora pode ser recuperada em apenas cinco passos do algoritmo de estimação de fase. Neste caso, o ganho complexo estimado para a equalização do bloco seguinte é $e^{j\phi} = e^{j0.117}$, que corresponde à soma dos ângulos θ_i para $i = 1, \dots, 5$. De fato, a probabilidade de erro no final deste pro-

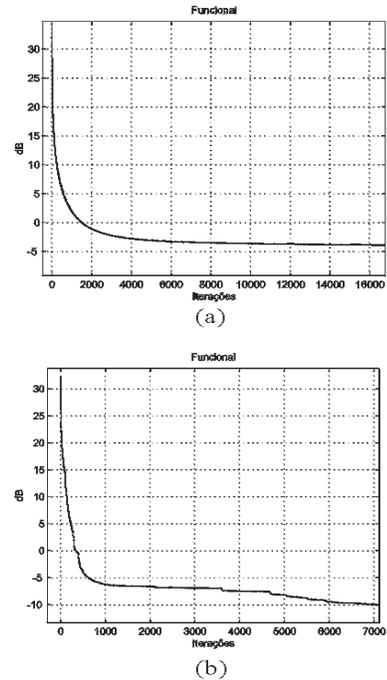


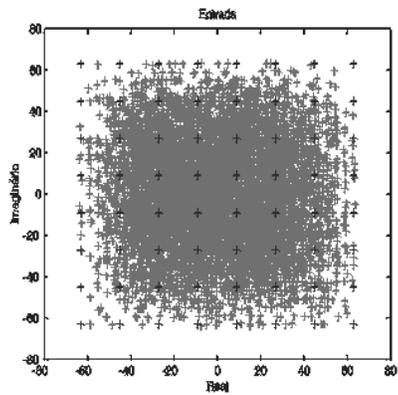
FIGURA 4: Curvas típicas de minimização do funcional de Godard ao longo das iterações dos algoritmos Descida Gradiente (a) e Híbrido (b).

cesso de estimação da fase da portadora caiu para 3,2%, mostrando que o erro de fase foi corrigido com sucesso.

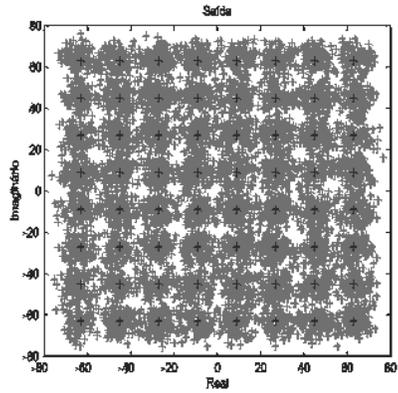
Como no Experimento 2, o Experimento 3 utiliza blocos de sinal 64-QAM com 7000 amostras. Os Canais 1 e 2 são utilizados para testar a convergência do algoritmo. Os resultados são mostrados na Figura 5. A primeira coluna (a1, b1 e c1) mostra os resultados obtidos a partir da transmissão do sinal pelo Canal 1 e a segunda coluna (a2, b2 e c2) os resultados obtidos para o Canal 2. Nesta Figura, (a1) e (a2) correspondem às constelações na entrada do equalizador, enquanto (b1) e (b2) correspondem às constelações na saída. Finalmente, (c1) e (c2) são as respostas impulsivas do sistema global (canal + equalizador). Os valores obtidos para a probabilidade de erro para os Canais 1 e 2 foram 6% e 3,12% respectivamente. Apesar de não ter sido realizada uma repetição exaustiva deste experimento, o algoritmo convergiu em todas as tentativas realizadas, indicando que o algoritmo aqui proposto é robusto e eficiente.

Como descrito anteriormente, a otimização do funcional de Godard é feita por bloco. Uma vantagem desta estratégia é que o algoritmo requer muito menos amostras para convergir do que os algoritmos baseados no LMS. Isto não significa que o tempo gasto numa otimização por blocos seja menor que o tempo gasto por um algoritmo que tenha por base o gradiente estocástico. De fato, uma iteração do algoritmo híbrido toma mais tempo do processador do que uma iteração dos algoritmos tipo LMS. Ainda assim, o fato da otimização realizada por blocos utilizar menos amostras é uma vantagem, principalmente nos casos em que são poucas as amostras a serem equalizadas.

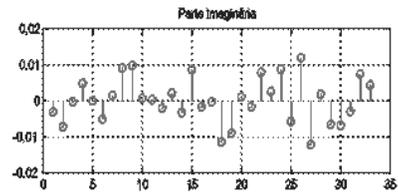
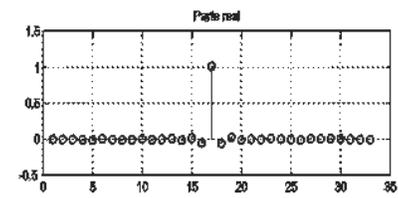
Canal 1
 SNR=35dB
 d=7000 amostras



(a1)

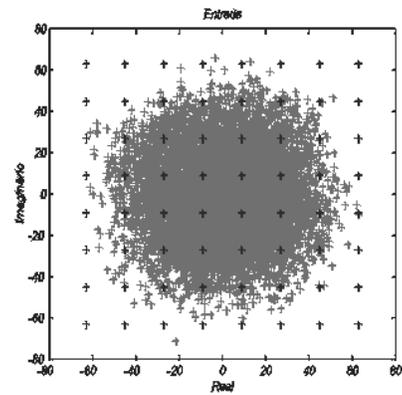


(b1)

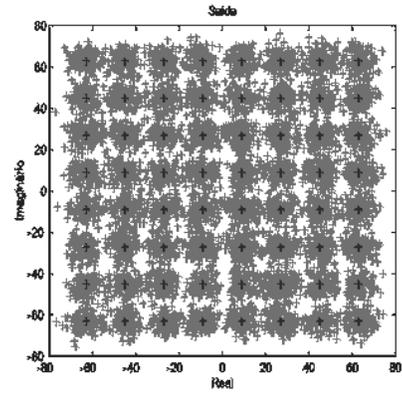


(c1)

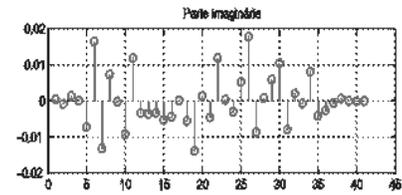
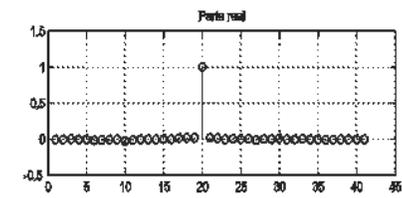
Canal 2
 SNR=35dB
 d=7000 amostras



(a2)



(b2)



(c2)

FIGURA 5: Resultados do Experimento 3. (a1, b1, c1) e (a2, b2, c2) são resultados obtidos pela transmissão do sinal pelos Canais 1 e 2, respectivamente. (a1 e a2) são as constelações na entrada do equalizador. (b1 e b2) são as constelações na saída do equalizador. Finalmente, (c1 e c2) são as respostas ao impulso do sistema global (canal + equalizador).

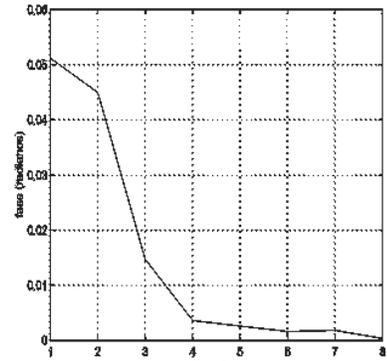
9. CONCLUSÕES

Em todos os casos testados o algoritmo híbrido AG-gradiente foi eficiente na equalização de sistemas QAM. Comparado com resultados obtidos pelos algoritmos tradicionais de equalização autodata, o método aqui proposto requereu um número pequeno de amostras para convergir.

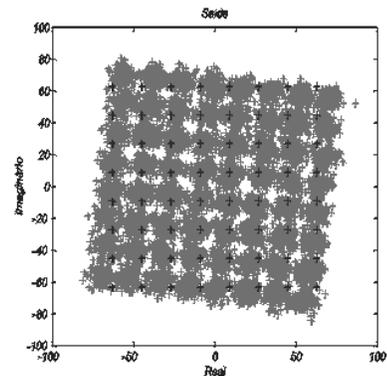
O Algoritmo provou ainda ser capaz de lidar com problemas relativos a mínimos locais, mostrando ser robusto com relação à inicialização. Além disso, o algoritmo mostrou ser capaz de detectar e corrigir erros de fase da portadora.

10. BIBLIOGRAFIA

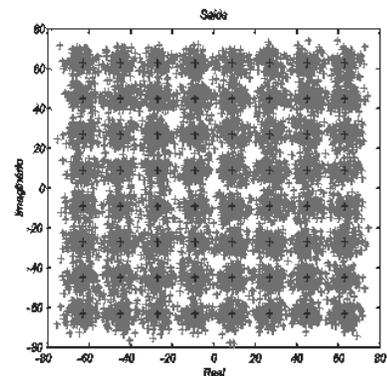
- [1] Simon Haykin (Editor), *Blind Deconvolution*, Prentice-Hall, New Jersey, 1994.
- [2] Godard, D. N., *Self-Recovering Equalization and Carrier Tracking in Two-Dimensional Data Communication Systems*, IEEE Trans. on Communications, vol COM-28, pp. 1867-1875, 1980.
- [3] Leehter Yao e William A. Sethares. *Nonlinear Parameter Estimation via the Genetic Algorithm*. IEEE Trans. on Signal Processing, vol 42, no. 4, pp. 927-935, abril, 1994.
- [4] S.C. NG, S.H. Leung, C.Y. Chung, A. Luk e W.H. Lau. *The Genetic Search Approach: a new Learning Algorithm for Adaptativ IIR Filtering*. IEEE Signal Processing Magazine, pp. 38-46, novembro, 1996.
- [5] K.S. Tang, K.F. Man, S. Kwong e Q. HE. *Genetic Algorithms and their Applications*. IEEE Signal Processing Magazine, pp. 22-37, novembro, 1996.
- [6] D. E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*. New York: Addison-Wesley, 1989.
- [7] Julio Tanomaru. *Motivação, Fundamentos e Aplicações de Algoritmos Genéticos*. II Congresso Brasileiro de Redes Neurais. Curitiba, novembro de 1995.
- [8] Fabbryccio A. C. M. Cardoso e Dalton S. Arantes, *Genetic Decoding of Linear Block Codes*, 1999 Congress on Evolutionary Computation, vol. 3, pp. 2302-2309, Washington D.C.
- [9] Y. S. Han, C. R. P. Hartmann and C. C. Chen, "Efficient Priority-First Search Maximum-Likelihood Soft-Decision Decoding of Linear Block Codes", IEEE Trans. on Information Theory, Vol. 39, N. 5, September, 1993.
- [10] G. C. Clark and J. B. Cain, "Error-Correction Coding for Digital Communications", Plenum Press, New York, 1981.
- [11] J. N. Amaral, "Genetic Algorithms and Evolutionary Neural Computation", invited lecture in Sian Ka'an International Conference: The First Joint Mexico-US International Workshop on Neural Networks and Neurocontrol, September, 1995.
- [12] J. N. Amaral, K. Tumer and J. Ghosh, "Designing Genetic Algorithms for the State Assignment Problem", IEEE Transactions on Systems, Man and Cybernetics, pp.687-694, Vol. 25, No. 4, April 1995.
- [13] J. L. Blanton Jr. and R. L. Wainwright, "Multiple Vehicle Routing with Time and Capacity Constraints using Genetic Algorithms," Proc. Fifth Int. Conf. Genetic Algorithms, pp. 452-459, 1993.



(a)



(b) Passo 0



(c) Passo 5

FIGURA 6: Resultados obtidos pelo Experimento 2: (a) passos intermediários do algoritmo de correção da fase da portadora; (b) constelação inicial na entrada do dispositivo de decisão; (c) constelação no final do processo de correção do erro de fase da portadora.