

Estratégias Evolutivas para o Problema de Desconvolução Sísmica

Monacér E. da Silva, Vinícius A. Oliveira, Kenji Nose-Filho, Levy Boccato, João M. T. Romano

Resumo— O problema de desconvolução sísmica, baseado na hipótese de esparsidade do perfil de refletividade, requer a otimização de uma função custo não-linear e multimodal. Neste trabalho, investigamos o uso de diferentes algoritmos evolutivos para realizar a busca dos parâmetros do filtro de desconvolução que minimizam a função pseudo-Huber normalizada, os quais possuem mecanismos para escapar de ótimos locais e explorar de forma mais ampla o espaço de soluções candidatas. Os resultados obtidos com dados sintéticos mostram o progresso de desempenho dos filtros de desconvolução projetados com estes algoritmos, quando comparados a um método do tipo gradiente estocástico.

Palavras-Chave— Desconvolução sísmica, Desconvolução esparsa, Algoritmos evolutivos.

Abstract— The problem of seismic deconvolution, based on the sparse hypothesis of the reflection profile, requires the optimization of a non-linear and multimodal function. In this work, we investigate the use of different evolutionary algorithms to perform the search of deconvolution filter parameters that minimize a normalized pseudo-Huber function, which have mechanisms to escape from optimal locations and explore more broadly the space of candidate solutions. The results obtained with the synthetic data show the performance progress of the deconvolution filters designed with these algorithms when compared to a stochastic gradient type method.

Keywords— Seismic deconvolution, Sparse deconvolution, Evolutionary algorithms.

I. INTRODUÇÃO

O problema de desconvolução busca recuperar uma informação primária que foi distorcida por um determinado fator que pode ser, desde um ruído, até o efeito ocasionado pelo meio de geração, transmissão e/ou recepção. Em muitos casos, esta recuperação é realizada sem a disponibilidade de um sinal que guie o processo de otimização, necessitando assim de métodos não-supervisionados de processamento de sinais, como é o caso dos problemas de equalização de canais de comunicação [1], desconvolução sísmica [2], desconvolução de imagens [3], processamento de sinais de voz, entre outros.

No contexto de processamento de sinais geofísicos, particularmente no problema de desconvolução sísmica, uma hipótese bastante explorada pelos métodos de desconvolução é a de que a resposta ao impulso do modelo de camadas do solo, conhecida como perfil de refletividade, possui uma característica

esparsa. Estes métodos são bastante conhecidos na literatura especializada como desconvolução de mínima entropia [4], [5], [6]. A desconvolução de mínima entropia busca estimar um filtro de desconvolução através da otimização de critérios que quantificam o nível de esparsidade dos sinais envolvidos. No entanto, estas métricas são, em geral, métricas normalizadas, que dão origem a problemas de otimização cujas funções custo apresentam superfícies dotadas de múltiplos ótimos locais [8].

Neste contexto, os algoritmos de busca baseados no gradiente, comumente utilizados para a obtenção dos coeficientes de um filtro de desconvolução [7], são bastante dependentes da inicialização, normalmente ficando presos em soluções sub-ótimas. Para estas situações, o uso de algoritmos evolutivos torna-se uma opção bastante atraente. Em termos simples, esta classe de métodos tem como inspiração o processo evolutivo natural e realiza a busca pelo ótimo através da aplicação de operadores de modificação e seleção sobre uma população de soluções candidatas, visando a descoberta de soluções cada vez melhor adaptadas, sendo a adaptação medida por uma função matemática que revela a qualidade da solução para um dado problema [11], [12].

Os algoritmos evolutivos não garantem a obtenção da solução ótima, tampouco convergência para alguma solução, mas, apesar disto, são dotados de mecanismos que promovem busca local e global simultaneamente, conferindo maior robustez e eficácia. Além disso, estes métodos apresentam ampla aplicabilidade, uma vez que utilizam apenas a informação de ordem zero da função a ser otimizada (i.e., o valor da função em qualquer ponto de seu domínio), não impondo restrições quanto ao fato da função ser diferenciável ou contínua. Apesar de possuírem complexidade elevada em relação às estratégias tradicionais, dada a característica *offline* da nossa aplicação, seu uso efetivo não tem necessidade de atender requisitos de processamento em tempo real.

Este trabalho, portanto, propõe a aplicação de algoritmos evolutivos ao problema de desconvolução sísmica, particularmente para realizar o ajuste dos parâmetros do filtro de desconvolução no sentido de mínima entropia. O critério a ser otimizado é definido pela função pseudo-Huber normalizada [7]. Para o processo de otimização, escolhemos três métodos evolutivos [12]: um algoritmo genético (AG), uma estratégia evolutiva do tipo $(\mu + \lambda)$ (EE) e um algoritmo de evolução diferencial (ED).

O presente trabalho está dividido da seguinte forma: na Seção II é apresentado o problema de desconvolução sísmica; na Seção III é apresentado o critério de desconvolução de mínima entropia que será utilizado neste trabalho. Já na Seção IV são apresentados os algoritmos evolutivos utilizados neste

M. E. da Silva, V. A. Oliveira, L. Boccato e J. M. T. Romano, Faculdade de Engenharia Elétrica e de Computação (FEEC) da Universidade Estadual de Campinas (UNICAMP). E-mails: monacer.ericson@gmail.com, viniciusalvesoli@gmail.com, lboccato@dca.fee.unicamp.br, romano@decom.fee.unicamp.br. K. Nose-Filho, Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas da Universidade Federal do ABC (UFABC). E-mail: kenji.nose@ufabc.edu.br. Este trabalho foi parcialmente financiado pela CAPES e CNPq.

trabalho e, também, o algoritmo baseado no gradiente, conhecido como F-SMDB (*Fast algorithm for Sparse Multichannel Blind Deconvolution*) [7], que servirá como referência para a comparação de desempenho feita na Seção V, sendo detalhado na seção IV. Por fim, são apresentadas algumas conclusões e perspectivas dos resultados obtidos.

II. FORMULAÇÃO DO PROBLEMA

A desconvolução sísmica tem por objetivo buscar um mapeamento estimado do subsolo. Para realizar tal análise, geram-se ondas acústicas que se propagam pelas camadas do subsolo. Em um modelamento simples, supondo camadas homogêneas, onde houver interface entre as diferentes camadas, surgirá uma alteração de impedância acústica e a energia da onda será em parte absorvida, em parte refletida e outra parte refratada para as camadas inferiores. A parte refletida, seja da primeira camada ou de camadas mais profundas, será captada por sensores estrategicamente posicionados na superfície da Terra ou do Mar. A partir dos sinais captados, deseja-se inferir qual o tipo de estrutura subterrânea presente naquele local, através de um processamento adequado destes sinais.

Adotando-se um modelo linear, podemos tratar a leitura do sensor como a convolução do pulso sísmico com um canal representado pelos traços sísmicos - raios que representam os coeficientes de reflexão entre as seções geológicas - mais um ruído. Sendo a convolução um operador comutativo, é indiferente considerar o pulso acústico como sinal de entrada e os coeficientes de reflexões como resposta ao impulso ou vice-versa. Sendo assim, considera-se a refletividade do solo - que desejamos estimar - como a entrada de um sistema (canal) cuja resposta ao impulso é dada pelo pulso sísmico ou *wavelet*.

Abstendo-nos de um maior detalhamento referente ao aspecto multicanal das técnicas envolvidas em [7], vamos representar o problema sob a ótica de filtragem simples, a qual serve de base para os procedimentos mais avançados. Seja $s[n]$ o traço sísmico, $h[n]$ a wavelet modelada como uma resposta ao impulso de duração finita e $\nu[n]$ um termo de ruído, podemos escrever que o sinal efetivamente coletado pelo sensor, denominado traço sísmico [5], é dado por:

$$x[n] = h[n] * s[n] + \nu[n] = \sum_k h[k]s[n-k] + \nu[n], \quad (1)$$

onde $*$ denota o operador de convolução.

A desconvolução consiste em encontrar um filtro FIR com resposta ao impulso $w[n]$, que, convoluído com o traço sísmico $x[n]$, nos permite obter em sua saída um sinal $y[n]$ que seja uma estimativa $\hat{s}[n]$ da refletividade:

$$y[n] = \hat{s}[n] = x[n] * w[n] = \sum_k x[k]w[n-k]. \quad (2)$$

Para o caso de inversão perfeita, deseja-se obter na saída do filtro de desconvolução o sinal [1]:

$$y[n] = \pm \alpha s[n-d], \quad (3)$$

sendo α uma constante complexa de magnitude unitária e d o atraso inserido pela resposta casada entre o canal e o filtro de desconvolução.

III. DESCONVOLUÇÃO DE MÍNIMA ENTROPIA

A desconvolução de mínima entropia é baseada na hipótese de que a combinação linear de sinais esparsos resulta em um sinal menos esperso. Deste modo, a desconvolução pode ser realizada através de um filtro capaz de gerar em sua saída um sinal com característica mais esparsa, surgindo assim a necessidade de estabelecer medidas que sejam capazes de quantificar o grau de esparsidade do sinal. Entre as métricas possíveis de avaliação do grau de esparsidade de um sinal, tem-se um particular interesse pela função pseudo-huber [9].

A. Função Pseudo-Huber

A função pseudo-Huber, utilizada em problemas de estimação robusta, surge como uma alternativa à norma ℓ_1 [10], sendo empregada para quantificar o nível de esparsidade de um determinado sinal. Sua definição detalhada pode ser encontrada em [7] e sua formulação é dada por:

$$\bar{J}_\epsilon(y_i) = \sum_i (\sqrt{y_i^2 + \epsilon^2} - \epsilon). \quad (4)$$

onde $y_i[n]$ é o sinal de saída do filtro com vetor de coeficientes \mathbf{w} . O índice i corresponde ao sinal associado a cada um dos sensores localizados na superfície da Terra. Esta função pode ser vista como uma norma híbrida, que atua linearmente para valores elevados do sinal e quadraticamente para valores pequenos, cuja ponderação dependerá do parâmetro ϵ .

A função pseudo-Huber não é invariável à escala e, portanto, não pode ser diretamente empregada como um critério não-supervisionado. Felizmente, uma modificação pode ser introduzida de modo a satisfazer a condição de invariância: a normalização do sinal desconvoluído $y[n]$ pelo seu desvio padrão σ_y , como proposto em [7]. Assim, a função pseudo-Huber normalizada passa a ser dada por:

$$J_\epsilon(\mathbf{w}) = \sum_i (\sqrt{\frac{y_i^2}{\sigma_y^2} + \epsilon^2} - \epsilon) \quad (5)$$

Em um contexto multicanal, o filtro de desconvolução é dado como a solução do seguinte problema de otimização:

$$\hat{\mathbf{w}} = \min_{\mathbf{w}} J_\epsilon(\mathbf{w}) = \sum_i (\sqrt{\frac{y_i^2}{\sigma_y^2} + \epsilon^2} - \epsilon),$$

Sujeito a $\mathbf{w}^T \mathbf{w} = 1$. (6)

A restrição de norma unitária do vetor de coeficientes é inserida para evitar a solução trivial ($\mathbf{w} = \mathbf{0}$).

IV. ALGORITMOS DE OTIMIZAÇÃO

A. Algoritmo baseado no gradiente (F-SMDB)

O algoritmo F-SMDB baseia-se na seguinte fórmula de adaptação:

$$\mathbf{w}(m+1) = \mathbf{w}(m) - \mu \frac{\nabla J(\mathbf{w}(m))}{\|\nabla J(\mathbf{w}(m))\|}$$

$$\mathbf{w}(m+1) = \frac{\mathbf{w}(m+1)}{\|\mathbf{w}(m+1)\|} \quad (7)$$

Os coeficientes do vetor gradiente são obtidos através das derivadas parciais de $J_{\in}(\mathbf{w})$ com relação aos coeficientes w_k . Seja z_i igual a:

$$z_i = \frac{y_i^2}{\sigma_{y_i}^2} + \epsilon^2. \quad (8)$$

Os coeficientes do vetor gradiente de $J_{\in}(\mathbf{w})$ podem ser definidos como:

$$\frac{\partial J_{\in}(\mathbf{w})}{\partial w_k} = \sum_i z_i^{-1/2} (y_i x_{i-k} - \frac{y_i^2}{N\sigma_y^2} \sum_i y_i x_{i-k}). \quad (9)$$

Dada a não-convexidade da função custo, a inicialização do algoritmo terá um efeito determinante sobre seu desempenho. Por isso, sugere-se inicializar o filtro com um impulso de amplitude unitária e posição de acordo com a fase do canal [8]. Por exemplo, para canais de fase mínima, sugere-se inicializar o filtro com um impulso de amplitude unitária logo no início do filtro; para canais de fase mista, no meio do filtro; e, para canais de fase máxima, no final do filtro.

B. Algoritmos Evolutivos

Algoritmos evolutivos são meta-heurísticas populacionais que despontam como ferramentas úteis para realizar a busca por soluções ótimas em um espaço de soluções candidatas, fazendo uso de princípios e mecanismos inspirados no processo evolutivo natural. Neste trabalho, foram selecionados três abordagens evolutivas diferentes para estudo no problema de desconvolução sísmica: algoritmo genético (AG), estratégia evolutiva (EE) e evolução diferencial (ED). Estes métodos, embora tenham origens e explorem ideias distintas, partilham de uma estrutura comum: dada uma população inicial de indivíduos, que representam soluções potenciais para o problema tratado, a cada geração são aplicados operadores de mutação e reprodução (*crossover*), os quais geram novas soluções candidatas que herdaram características dos indivíduos originalmente presentes na população, e, posteriormente, faz-se a seleção dos indivíduos que devem permanecer na população para a próxima geração.

O grau de adaptação ao meio associado a cada indivíduo, denominado *fitness*, indica a qualidade da solução com respeito ao problema abordado e serve como critério base para o processo de seleção, de maneira que as soluções com melhor *fitness* tendem a ser privilegiadas e possuem maior chance de sobrevivência. Sendo assim, os operadores de mutação e reprodução em um algoritmo evolutivo promovem a exploração do espaço de busca, tanto a descoberta de novas regiões potencialmente promissoras, quanto o refinamento das soluções rumo ao ótimo global. Por sua vez, a seleção atua no sentido de direcionar a busca para as regiões mais promissoras, mantendo na população as soluções que se mostram as mais adequadas.

Tendo estes conceitos em mente, a seguir descrevemos brevemente as características específicas de cada algoritmo evolutivo implementado neste trabalho, sabendo que, no âmbito do problema de desconvolução sísmica, cada indivíduo representa uma configuração diferente para o vetor de coeficientes do filtro de desconvolução (\mathbf{w}), enquanto a medida de *fitness* será dada pela função pseudo-Huber normalizada.

1) *Algoritmos Genéticos*: Dada uma população \mathcal{P}_i de N indivíduos na geração i , primeiramente os 20% melhores indivíduos são selecionados para a próxima geração. A fim de manter o tamanho fixo da população, a parcela restante (80%) é preenchida com indivíduos gerados via recombinação entre aqueles que estavam presentes em \mathcal{P}_i , com o auxílio do operador de crossover aritmético. Os descendentes gerados também passam por um processo de mutação, sendo esta do tipo gaussiana, com variância 0,005. A escolha dos indivíduos que participam da etapa de *crossover* é aleatória, de acordo com o operador de torneio sem reposição, com 5 indivíduos por torneio, enquanto o operador de mutação é aplicado sempre sobre 9% de todos os genes da população aleatoriamente escolhidos, i.e., de todos os coeficientes de filtros candidatos presentes na população. O algoritmo repete essa sequência de operações até que um número máximo de gerações é atingido.

2) *Estratégias Evolutivas*: Uma marca distintiva das estratégias evolutivas é a presença de parâmetros que controlam características dos operadores evolutivos, como, por exemplo, a taxa de mutação, no próprio vetor de atributos de um indivíduo da população. Esta ideia, conhecida como auto-adaptação, faz com que estes parâmetros de controle também estejam sujeitos ao processo de otimização, sendo, portanto, adaptados a cada geração por meio de recombinação e mutação.

Para a estratégia evolutiva ($\mu+\lambda$) implementada neste trabalho, cada indivíduo possui não apenas os atributos do problema em sua representação (no caso, os coeficientes do filtro de desconvolução), mas também um vetor σ e θ . O vetor $\sigma \in \mathbb{R}^l$ contém os desvios padrão das mutações associadas a cada coeficiente, enquanto o vetor $\theta \in (0, 2\pi]^{l_\theta}$ descreve as rotações de coordenadas necessárias para transformar um vetor de mutações descorrelacionadas em outro com correlações nas mutações aplicadas sobre cada atributo. l corresponde à dimensão de \mathbf{x} e de σ , e $l_\theta \in \{0, l(l-1)/2\}$.

Sendo assim, o algoritmo parte de uma população composta por μ pais e, por meio de recombinação, gera λ filhos a cada iteração. Os filhos gerados experimentam um processo de mutação especializado, levando em consideração o perfil de mutação – desvios e correlações – dado em seu vetor de atributos. Após a mutação, os μ indivíduos com melhor custo associado ao problema em questão, considerando o conjunto completo de $(\mu + \lambda)$ indivíduos, passam para a próxima geração.

3) *Evolução Diferencial*: No método de evolução diferencial, novos vetores de parâmetros são gerados via mutação através da adição do vetor diferença entre dois indivíduos a um terceiro indivíduo. Em termos matemáticos, para cada indivíduo (*target vector*), denotado por $\mathbf{x}_{i,G}$, $i = 1, \dots, N$, onde N é o tamanho da população e G o índice da geração atual, um novo vetor será gerado segundo a expressão:

$$\mathbf{v}_{i,G} = \mathbf{x}_{r_1} + F(\mathbf{x}_{r_3} - \mathbf{x}_{r_2}), \quad (10)$$

onde $i, r_1, r_2, r_3 \in \{1, 2, \dots, P\}$, são índices mutuamente distintos e F é uma constante real que denota o passo a ser dado na direção do vetor diferença.

Após esta operação, é feita a recombinação entre $\mathbf{x}_{i,G}$, i.e., os indivíduos originalmente presentes na população no

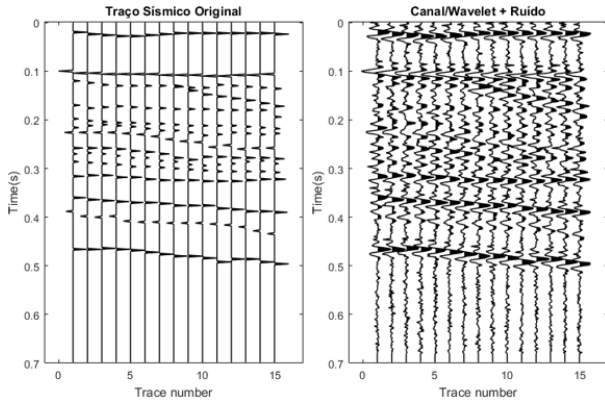


Fig. 1. Refletividade original e traço sísmico com relação sinal ruído igual a 9dB.

início da geração G , e os respectivos vetores mutados $\mathbf{v}_{i,G}$, produzindo, assim, os chamados *trial vectors*, representados por $\mathbf{u}_{i,G+1}$. A estratégia de recombinação utilizada é muito semelhante ao famoso esquema de *crossover* uniforme: cada elemento de $\mathbf{u}_{i,G+1}$ é uma cópia do elemento correspondente de um dos pais, i.e., de $\mathbf{x}_{i,G}$ ou de $\mathbf{v}_{i,G}$; a escolha de qual pai transfere o atributo para $\mathbf{u}_{i,G+1}$ é probabilística, sendo esta probabilidade um parâmetro do algoritmo, denotado por CR . Ou seja,

$$u_{ji,G+1} = \begin{cases} v_{ji,G+1}, & \text{se } r_j \leq CR \text{ ou } j = l_i \\ x_{ji,G}, & \text{se } r_j > CR \text{ ou } j \neq l_i \end{cases} \quad (11)$$

onde $j=1,\dots,D$, $r_j \sim U(0,1)$, $CR \in [0,1]$ é uma constante definida pelo usuário e l_i é um índice aleatoriamente escolhido $\in \{1,\dots,D\}$.

Por fim, a seleção é feita com base na comparação de *fitness* entre o *target vector* $\mathbf{x}_{i,G}$ e o *trial vector* associado, $\mathbf{u}_{i,G+1}$: aquele que possuir o melhor valor de *fitness* será mantido na população.

- Se $f(\mathbf{u}_{i,G+1}) < f(\mathbf{x}_{i,G})$, então $\mathbf{x}_{i,G+1} = \mathbf{u}_{i,G+1}$.
- Caso contrário, $\mathbf{x}_{i,G+1} = \mathbf{x}_{i,G}$.

V. RESULTADOS

Nesta seção, serão apresentados os resultados obtidos com os algoritmos evolutivos para o perfil de refletividade sintético ilustrado pela imagem da esquerda da Fig. 1, para diferentes relações sinal ruído. A imagem da direita da Fig. 1 ilustra o traço sísmico proveniente da convolução do perfil de refletividade sintético com a wavelet de fase mista ilustrada pela Fig. 2, mais um ruído aditivo Gaussiano (AWGN) com relação sinal ruído (SNR) igual a 9 dB.

Os resultados obtidos pelos algoritmos evolutivos são comparados com os obtidos com o F-SMBD para três inicializações diferentes: com um impulso no primeiro coeficiente do filtro (F-SMBD1), com um impulso no coeficiente central do filtro (F-SMBD2) e com um impulso no último coeficiente do filtro (F-SMBD3). Em todos os casos, foi utilizado um passo de adaptação igual a 0,02 e um total de 1000 iterações para o algoritmo F-SMBD. Como um critério de avaliação do desempenho de cada algoritmo, é apresentado o valor da função custo obtido para cada algoritmo e, também, o

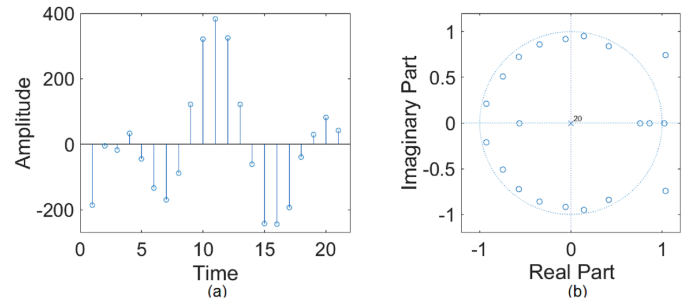


Fig. 2. (a) Resposta ao impulso da wavelet e (b) seu respectivo diagrama de pólos e zeros do canal;

coeficiente de correlação de Pearson da refletividade estimada com a refletividade original, considerando uma média de 20 realizações independentes do processo de busca, e diferentes valores de SNR: 9, 12, 15, 18, 21 e 24 dB. Além disso, também foram considerados dois valores para o limiar da norma híbrida: $\epsilon = 1.0$ e, para uma versão menos suave, $\epsilon = 0,1$. Para reduzir a dimensionalidade do problema (número de parâmetros a serem estimados) e, também, reduzir o espaço de busca dos algoritmos evolutivos, os coeficientes do filtro de desconvolução foram transformados em coordenadas polares. Esta transformação reduz o número de coeficientes do filtro a serem estimados e, também, restringe o espaço de busca ao intervalo $[0;2\pi]$ para o último coeficiente e $[0;\pi]$ para os demais. A população inicial, para cada algoritmo evolutivo, foi gerada a partir de uma variável aleatória com distribuição uniforme entre 0 a 2π . Os respectivos parâmetros para os algoritmos evolutivos são indicados abaixo:

1) Algoritmo Genético (AG):

- **População:** 200 indivíduos;
- **Recombinação:** aritmética, com escolha dos pais por torneio e sem reposição (grupo de 5 indivíduos);
- **Mutação:** gaussiana ($N \sim (0, 0.005)$) e troca recíproca, cada uma atuando em 9% dos atributos para todos os indivíduos da população;
- **Seleção:** os 20% melhores indivíduos passam para a próxima geração.

2) Estratégia Evolutiva (EE):

- **População:** $\mu = 10$ e $\lambda = 70$.
- **Recombinação:** local, com escolha aleatória de dois pais dentre μ , para geração de dois indivíduos, até completar 70 filhos;
- **Mutação:** correlacionada, com atuação para 100% dos indivíduos; inicialização dos desvios padrões para cada indivíduo utilizando distribuição uniforme $U(0,1)$; inicialização dos ângulos com distribuição uniforme $U(0,2\pi)$. Empregamos os valores padronizados sugeridos em [13];

3) Evolução Diferencial (ED):

- **População:** 100 indivíduos;
- **Mutação:** $F=0.75$;
- **Recombinação:** $CR=0.25$;

A Fig. 3 apresenta o valor médio da função custo, fornecida pela equação 5, obtidos no final das 1000 iterações para os

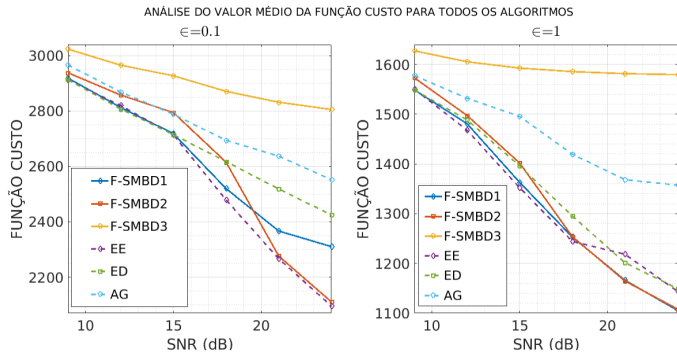


Fig. 3. Valor médio dos mínimos da função custo obtidos nas 20 simulações de Monte Carlo para cada algoritmo, diferentes normas híbridas e SNRs.

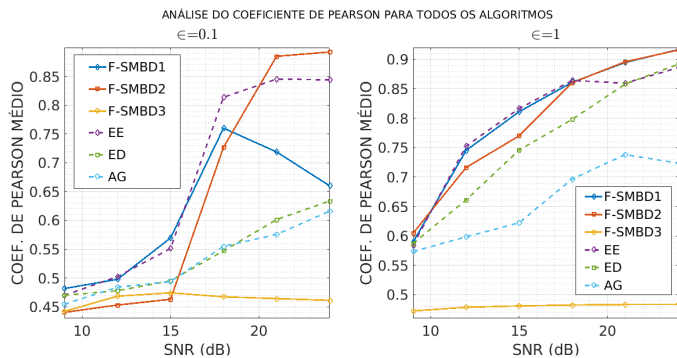


Fig. 4. Valor médio dos coef. de correlação de Pearson obtidos nas 20 simulações de Monte Carlo para cada algoritmo, diferentes normas híbridas e SNRs.

diferentes algoritmos: F-SMBD1, F-SMBD2, F-SMBD3, AG, EE e ED, para diferentes SNRs e para os limiares 1.0 e 0.1. Já a Fig. 4 apresenta os coeficientes de correlação de Pearson [7] das refletividades estimadas para cada um desses casos.

Através destas figuras é possível observar que, na média, os algoritmos F-SMBD1, F-SMBD2 e EE, para o limiar de norma híbrida igual a 0.1, e os algoritmos F-SMBD1, F-SMBD2, EE e ED, para o limiar de norma híbrida igual a 1.0, foram capazes de convergir para bons mínimos locais, uma vez que eles atingem os menores valores de função custo e, também, os melhores valores de correlação. Já os resultados obtidos pelo algoritmo F-SMBD3 foram os piores apresentados, o que comprova a forte dependência que o algoritmo F-SMBD possui com a inicialização. Apesar dos resultados obtidos com os algoritmos ED e AG, para $\epsilon=0.1$, e o algoritmo AG, para $\epsilon=1$, serem piores que os obtidos pelos algoritmos F-SMBD1 e F-SMBD2, ainda assim são melhores do que os obtidos pelo F-SMBD3. Isto indica uma maior robustez por parte dos algoritmos evolutivos quando comparados com o algoritmo baseado no gradiente. Cabendo ressaltar ainda a variedade de ajustes possíveis sobre os parâmetros das estratégias evolutivas.

VI. CONCLUSÕES

Este trabalho propôs a aplicação de algoritmos evolutivos para estimar os coeficientes de um filtro de desconvolução de mínima entropia, de modo a evitar o problema da inicialização dos algoritmos baseados no gradiente que podem ficar restritos

à regiões de mínimos locais. O critério de otimização foi definido pela função pseudo-Huber normalizada. Para o processo de otimização, foram escolhidos três métodos evolutivos: um algoritmo genético, uma estratégia evolutiva do tipo $(\mu + \lambda)$ (EE) e um algoritmo de evolução diferencial. Os algoritmos foram então comparados com um algoritmo baseado no gradiente, o F-SMBD.

Os resultados com dados sintéticos foram capazes de mostrar que o desempenho dos filtros de desconvolução obtidos com os algoritmos evolutivos são melhores do que aqueles obtidos pelo algoritmo baseado no gradiente quando inicializado inadequadamente. Vale ressaltar que o refinamento das soluções pelo algoritmo do gradiente tende a ser maior do que a estratégia utilizada pelos algoritmos evolutivos e, desta forma, é de se esperar que o algoritmo do gradiente obtenha melhores resultados quando inicializado numa região apropriada.

Desta forma, apesar do fato de que nem todos os resultados obtidos através dos algoritmos evolutivos são melhores do que os resultados obtidos pelo F-SMBD quando inicializado adequadamente, surge a possibilidade das soluções obtidas pelos algoritmos evolutivos, atualmente em estudo, serem refinadas através de métodos ou estratégias de busca local como, por exemplo, o próprio F-SMBD.

REFERÊNCIAS

- [1] Romano, J. M. T., Attux, R., Cavalcante, C. C., e Suyama, R. (2016). *Unsupervised signal processing: channel equalization and source separation*. CRC Press.
- [2] Yilmaz, Ö. (2001). *Seismic data analysis: Processing, inversion, and interpretation of seismic data*. Society of exploration geophysicists.
- [3] Kundur, D., e Hatzinakos, D. (1996). Blind image deconvolution. *IEEE signal processing magazine*, 13(3), 43-64.
- [4] Claerbout, J. F. (1978). Minimum information deconvolution. *Stanford Exploration Project, Report*, 15, 109-22.
- [5] Wiggins, R. A. (1978). Minimum entropy deconvolution. *Geoprospection*, 16(1-2), 21-35.
- [6] Ulrych, T. J., e Walker, C. (1982). Analytic minimum entropy deconvolution. *Geophysics*, 47(9), 1295-1302.
- [7] Nose-Filho, K., Takahata, A. K., Lopes, R., e Romano, J. M. (2015). A fast algorithm for sparse multichannel blind deconvolution. *Geophysics*, 81(1), V7-V16.
- [8] Nose-Filho, K. (2015). *Desconvolução e separação cega de sinais esparsos e aplicações em sísmica de reflexão*. Tese (Doutorado). Universidade de Campinas, SP, 2015.
- [9] Repetti, A., Pham, M. Q., Duval, L., Chouzenoux, E., e Pesquet, J. C. (2015). Euclid in a Taxicab: Sparse Blind Deconvolution with Smoothed ℓ_1/ℓ_2 Regularization. *IEEE Signal Processing Letters*, 22(5), 539-543.
- [10] Hartley, R., & Zisserman, A. (2003). *Multiple view geometry in computer vision*. Cambridge university press.
- [11] Fogel, D. B. (2006). *Evolutionary computation: toward a new philosophy of machine intelligence* (Vol. 1). John Wiley & Sons.
- [12] Simon, D. (2013). *Evolutionary optimization algorithms*. John Wiley & Sons.
- [13] Bäck, T., Fogel, D. B., & Michalewicz, Z. (2000). *Evolutionary Computation 2-Advanced Algorithms and Operations*. Taylor Francis, 1.