

Estimação DOA aplicando Algoritmo Genético ao Espectro Diferencial

Lucas Rodrigues Ferreira e Rodrigo Pinto Lemos

Resumo— Estimação DOA (ângulo de incidência das frentes de onda, do inglês *Direction Of Arrival*) é um problema não-linear e multimodal. Em antenas inteligentes, a estimação DOA permite mitigar interferências e rastrear os usuários. Dada a importância de antenas inteligentes para sistemas modernos de comunicação móvel, têm-se buscado o aperfeiçoamento das técnicas de estimação DOA. Como algoritmo genético é uma técnica adaptativa de busca global com rápida convergência, o presente trabalho propõe um método de estimação DOA baseado em sua aplicação para realizar uma busca pelo espectro diferencial.

Palavras-Chave— Algoritmo genético, estimação DOA, Espectro diferencial, Processamento de sinal.

Abstract— DOA estimation (Direction Of Arrival) is a nonlinear and multimodal problem. In smart antennas, the DOA estimation allows mitigating interference and tracking users. Due to the importance of smart antennas for modern mobile communication systems, we have sought to improve the DOA estimation techniques. As a genetic algorithm is an adaptive global search technique with fast convergence, this paper proposes a new DOA estimation method based on its application to perform a differential spectrum search.

Keywords— Genetic algorithm, DOA estimation, Differential spectrum, Signal process.

I. INTRODUÇÃO

No problema de estimação DOA (*Direction Of Arrival*), comumente são empregadas técnicas baseadas no critério de máxima verossimilhança (ML – *Maximum Likelihood*), que minimiza uma função objetivo não-linear e multimodal [1], a exemplo o MODE e o MODEX. O MODE (*Method Of Direction Estimation*) [2] reparametriza o problema ML numa otimização quadrática; já o MODEX (*MODE with eXtra roots*) [2] emprega raízes extras cujas combinações geram estimativas de DOA, selecionando-se a melhor através de um procedimento de ML. Embora apresentem bom desempenho em altas SNRs, ambos perdem sua eficácia quando o ruído supera o sinal [2].

Na busca de um método mais robusto, foi desenvolvido o SEAD (*SEArch of direction by Differential spectrum*) [3], que utiliza a diferença entre os valores singulares principais da matriz de covariância espacial aumentada para gerar o espectro diferencial (ED), cujos picos permitem produzir estimativas iniciais para os DOA. O *Improved SEAD* [4] refina essas estimativas, minimizando a função objetivo de ML através de uma estratégia inspirada no *branch-and-bound*, o que resulta em um desempenho superior ao do MODEX em baixas SNR.

Em [5] foi proposto um aprimoramento do *Improved SEAD*, refinando-se o resultado obtido com um algoritmo de Nelder-Mead a partir do ED. Ele mostrou-se mais robusto em baixas SNRs, já que sua função objetivo é menos susceptível ao ruído. Entretanto seu desempenho em altas SNRs está limitado à resolução do espectro diferencial. O presente trabalho objetiva aumentar ainda mais a precisão da estimação DOA por meio da aplicação de algoritmos genéticos.

Este trabalho está dividido em outras três seções: a seção II descreve o modelo de sinal utilizado; na seção III, o método aqui proposto é apresentado e comentado; e, finalmente, as conclusões são expostas na seção IV.

II. MODELO DE SINAL

Sejam M ondas planas de faixa estreita incidindo em um arranjo linear uniforme de K sensores espaçados entre si de metade do comprimento de onda da portadora, onde o número de fontes $M < K$ é conhecido e os ângulos de incidência são medidos à partir da normal ao arranjo. O vetor das entradas nos K elementos de saída do arranjo, na presença de ruído aditivo gaussiano branco, é dado no instante n por [1]:

$$\mathbf{y}(n) = \mathbf{A}\mathbf{s}(n) + \mathbf{e}(n), \quad (1)$$

onde $\mathbf{A} = [\mathbf{a}(\omega_1) \dots \mathbf{a}(\omega_m)]$ é uma matriz $K \times M$ de Vandermonde composta por vetores diretores $K \times 1$ $\mathbf{a}(\omega_m) = [1 e^{-j\omega_m} \dots e^{-j(K-1)\omega_m}]^T$ para cada fonte m , sendo $\omega_m = \pi \sin(\theta_m)$ os ângulos elétricos relativos aos ângulos mecânicos θ_m , para $m = 1, 2, \dots, M$. Além disso, $\mathbf{s}(n)$ é um vetor $M \times 1$ de amplitudes complexas do sinal e $\mathbf{e}(n)$ é um vetor $K \times 1$ de ruído aditivo [3]. A matriz de covariância espacial é obtida a partir do vetor de saída $\mathbf{y}(n)$ como [3]:

$$\mathbf{R} = E\{\mathbf{y}(n)\mathbf{y}^H(n)\} = \mathbf{A}\mathbf{P}\mathbf{A}^H + \sigma^2\mathbf{I}, \quad (2)$$

onde \mathbf{I} é a matriz identidade $K \times K$, $E\{\cdot\}$ é o operador esperança estatística, $(\cdot)^H$ é o operador transposto conjugado (hermitiano), σ^2 é a potência de ruído e \mathbf{P} é a matriz $M \times M$ de correlação entre os sinais de um mesmo *snapshot*, cujos elementos $\mathbf{P}_{ij} = \rho_{ij}$ representam a correlação entre as fontes i e j [1].

III. MÉTODO PROPOSTO

O algoritmo de Nelder-Mead se baseia no método Simplex para encontrar o mínimo ou o máximo local de funções objetivo multidimensionais não-lineares com derivadas desconhecidas. Para N dimensões, esse algoritmo estuda o comportamento da função objetivo em $N+1$ pontos e substitui iterativamente um deles para otimizar a função [6].

Como o Nelder-Mead realiza uma busca local, o método em [5] necessita de um chute inicial suficientemente próximo, caso contrário a otimização será equivocada. Portanto, quando não se tem informações da região aproximada em que se encontram as fontes, esse método se torna ineficaz.

Já os algoritmos genéticos são utilizados para realizar uma busca global, pois são gerados pontos de teste aleatoriamente espalhados, que depois são selecionados e refinados. Por isso diz-se que algoritmo genético é uma técnica computacional probabilística baseada no princípio evolutivo de Darwin, no qual os indivíduos mais adequados ao meio sobrevivem e se reproduzem, contribuindo para a evolução da espécie [7].

Partindo de uma população inicial, são empregados operadores genéticos, tais quais seleção, crossover (recombinação) e mutação para promover a evolução da espécie [8]. O método proposto foi ajustado para uma população de 80 indivíduos, sendo cada indivíduo representado por um vetor de duas posições (uma para cada fonte de sinal), além de índice de mutação de 3% e de 6% para crossover.

A cada iteração, os indivíduos são classificados quanto a sua adequação, medida por meio do erro quadrático médio (EQM) em relação aos ângulos verdadeiros. Os 50% melhores são selecionados para a próxima iteração, enquanto que os indivíduos restantes são substituídos por meio da reprodução (combinação) dos selecionados, podendo ocorrer crossover ou mutação de acordo com as probabilidades ajustadas.

Quando um mesmo indivíduo é o mais apto (possui menor EQM) durante 10 gerações consecutivas, ele é selecionado e a busca é encerrada. Ao final, um refinamento local baseado no algoritmo de Nelder-Mead é aplicado conforme em [5], e então é calculado o EQM para medir a eficiência da estimação.

A Figura 1 mostra o desempenho do método proposto (GA), do SEAD e do método anterior [5] (MA), enquanto que a Figura 2 mostra para o tempo de execução. A simulação foi feita para duas fontes de sinal, uma na posição 10° e a outra em 15° . Utilizou-se uma resolução de 181 pontos para o espectro diferencial e a REQM foi medida para um conjunto de 1000 experimentos para cada valor de SNR.

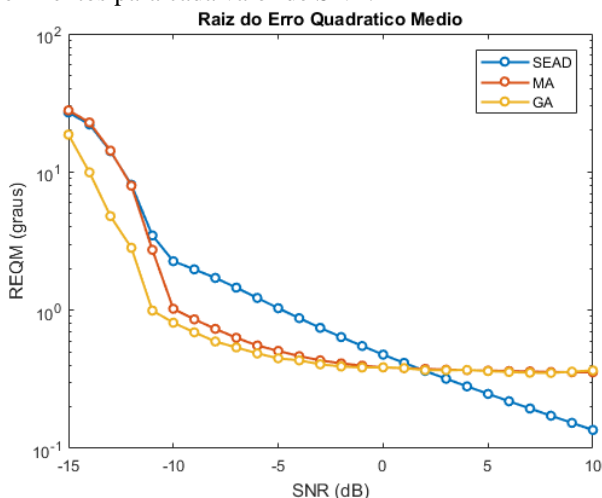


Fig. 1. REQM para o método aqui proposto (GA), o método SEAD e o método proposto anteriormente em [5] (MA).

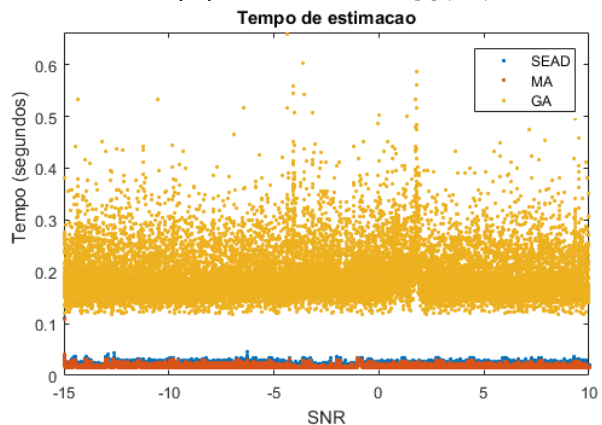


Fig. 2. Tempo de execução do método aqui proposto (GA), o método SEAD e o método proposto anteriormente em [5] (MA).

Da Figura 1, observa-se que o método proposto (GA) obteve um desempenho consideravelmente melhor ao SEAD em baixas SNRs, com erro de estimação na ordem de 10^0 abaixo em -15 dB e mantendo-se melhor até 1 dB. Aproximadamente nesta SNR, o método proposto se estabiliza com REQM entre $0,3^\circ$ e $0,4^\circ$, ao passo em que o SEAD mantém sua decrescente, fatalmente cruzando a curva GA em 2 dB.

Em relação ao método em [5], observa-se um desempenho consideravelmente melhor de -15 dB até -11 dB. Entre -10 dB e -1 dB, a curva GA manteve-se ainda um pouco abaixo. Em

0 dB, ambas as curvas se sobrepõem e assim se mantêm, já que a curva MA também se estabiliza entre $0,3^\circ$ e $0,4^\circ$ de REQM.

Essa estabilização da curva de desempenho presente no método aqui proposto, que utiliza algoritmo genético, pode ser explicada do mesmo modo como em [5]: como a busca está sendo feita comparando-se os espectros diferenciais, sua precisão fica limitada à resolução dos gráficos.

Quanto ao tempo de execução, a Figura 2 mostra que o método proposto necessitou de dezenas de vezes mais tempo para convergir do que os outros dois métodos analisados. Esse fato já era esperado, pois algoritmos genéticos possuem custo computacional superior aos métodos tradicionais de estimação DOA. O tempo de estimação do método proposto pode ser reduzido substituindo-se o algoritmo de Nelder-Mead por uma busca local de convergência mais rápida, como o método de Newton, ou aprimorando-se o algoritmo genético com a utilização de algoritmos genéticos compactos [9].

IV. CONCLUSÕES

A utilização de algoritmo genético para fazer uma busca global pelo espectro diferencial em baixas SNRs apresentou uma melhor acurácia, medida por uma REQM menor, do que nos outros dois métodos analisados. Para os casos em que a potência de sinal é maior do que a de ruído, o método SEAD mostrou-se melhor, já que ele não se estaciona em um patamar de REQM como os outros dois. Todavia, como mencionado em [5], o limiar de $0,4^\circ$ é suficientemente baixo para a maioria das aplicações. Por outro lado, o ganho de 1 dB na estimação em relação a [5] custou um esforço computacional muito maior, expresso pelo tempo de execução.

Por conseguinte, o objetivo de propor um método de estimação DOA com melhor desempenho em baixa SNR foi alcançado, indicando um caminho a ser melhor explorado. Deste modo, propõe-se para trabalhos futuros a aplicação de algoritmos genéticos compactos, que apresentam desempenho comparável, porém tempo de execução consideravelmente inferior [9].

REFERÊNCIAS

- [1] S. M. Kay. *Fundamentals of Statistical Signal Processing: Estimation Theory*. Prentice Hall, Englewood Cliffs, NJ, 1993.
- [2] A.B. Gershman e P. Stoica. "New MODE-based techniques for direction finding with an improved threshold performance". *Signal Processing*, v. 76, pp. 221-235, 1999.
- [3] Y. R. Ferreira e R. P. Lemos, "A new DOA estimation algorithm based on differential spectrum", *Proceedings of the 8th International Symposium on Signal Processing and Its Applications*, Sydney, Australia, pp. 303-307, 2005.
- [4] H. V. L. Silva, R. P. Lemos, Y. R. Ferreira e L. G. R. Guedes. "A branch-and-bound inspired technique to improve the computational efficiency of DOA estimation". *Signal Processing*, v. 93, pp. 947-56, 2013.
- [5] L. R. Ferreira e R. P. Lemos. "Estimação DOA usando SEAD e Nelder-Mead Simplex". *Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, São Pedro, Brasil, pp. 983-984, 2017 ;
- [6] J. A. Nelder e R. Mead. "A simplex method for function minimization". *The Computer Journal*, v. 7, pp. 308-313, 1965.
- [7] M. A. C. Pacheco. "Algoritmos genéticos : princípio e aplicações". Laboratório de inteligência computacional aplicada, PUC-RJ, versão 1, 1999
- [8] V. S. Monego; A. A. Schmidt; A. J. Kozakevicius. "Estratégias de otimização baseadas em algoritmos genéticos com operadores migração, epidemia e relaxamento local". *Proceeding series of the Brazilian society of applied computational mathematics*, vol. 5, n. 1, 2017 ;
- [9] D. Burgos; R. Lemos; H. Silva; J. Kunzler; E. Flôres. « Adaptive beamforming for moving targets using genetic algorithm. *Revista Ingeniería*, v. 21, pp. 214-24, 2016.