Quenaz Bezerra Soares

PROPOSTA DE ALGORITMOS EVOLUTIVOS PARA CONSTRUÇÃO DE DETECTORES OBJETIVOS DE RESPOSTA POR MEIO DA RECOMBINAÇÃO DE ELEMENTOS DE DETECTORES EXISTENTES

Viçosa, MG 2019 Quenaz Bezerra Soares

PROPOSTA DE ALGORITMOS EVOLUTIVOS PARA CONSTRUÇÃO DE DETECTORES OBJETIVOS DE RESPOSTA POR MEIO DA RECOMBINAÇÃO DE ELEMENTOS DE DETECTORES EXISTENTES

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 – Monografia e Seminário – e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Orientador: Leonardo Bonato Felix

Viçosa, MG 2019

QUENAZ BEZERRA SOARES

PROPOSTA DE ALGORITMOS EVOLUTIVOS PARA CONSTRUÇÃO DE DETECTORES OBJETIVOS DE RESPOSTA POR MEIO DA RECOMBINAÇÃO DE ELEMENTOS DE DETECTORES EXISTENTES

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 – Monografia e Seminário e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 22 de novembro de 2019.

COMISSÃO EXAMINADORA

Prof. Dr. Leonardo Bonato Felix - Orientador Universidade Federal de Viçosa

Prof. Dr. Rodolpho Vilela Alves Neves - Membro Universidade Federal de Viçosa

22

M.Sc. Tiago Zanotelli - Membro Instituto Federal do Espirito Santo

Dedico este trabalho à minha família e amigos.

Agradecimentos

Primeiramente agradeço a Deus, por ter me concedido saúde, força e disposição para terminar o curso de Engenharia Elétrica. Sem Ele, nada disso seria possível. Também sou grato ao Senhor por ter dado saúde aos meus familiares e tranquilizado o meu espírito nos momentos mais difíceis da minha trajetória acadêmica até então.

À minha família, em especial aos meus pais, Antonio e Neusa, e ao meu irmão, Gabriel. Os quais entenderam as minhas ausências, me incentivaram e deram todo o suporte durante esse período.

À minha namorada, Letícia, que esteve comigo por quase toda a graduação, me dando apoio e sendo companheira em todos os momentos.

A todos os moradores do 16nze, que proporcionaram um ambiente mais que amigável, familiar.

Aos meus companheiros da Engenharia Elétrica, com os quais compartilhei as dificuldades do curso e aprendi a necessidade do trabalho em grupo na construção do conhecimento.

Aos amigos do Núcleo Interdisciplinar de Análise de Sinais, pelo companheirismo, ajuda e conhecimentos compartilhados.

A todos professores que contribuíram na minha vida acadêmica, fornecendo conhecimento e conselhos que me fizeram ser quem eu sou hoje. Um agradecimento especial ao professor Leonardo Bonato, por todos estes anos de orientação, pelas experiencias que foram passadas durante os projetos e pelos conhecimentos compartilhados durante os Journal Clubs.

À FAPEMIG, à CAPES e ao CNPq pelo apoio financeiro concedido durante todas as Iniciações Científicas que realizei, a partir das quais adquiri conhecimento e experiência suficiente para produzir este trabalho.

Agradeço à Universidade Federal de Viçosa, por proporcionar um ambiente amigável para os estudos e por fornecer o suporte financeiro por meio da assistência estudantil, suporte este que tornou possível a minha permanência em Viçosa durante o curso.

"Transformar o simples em complicado é fácil, porém transformar o complicado em simples exige criatividade" (Arakawa, Hiromu; **Fullmetal Alchemist**; 2001)

"A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo" (Albert Einstein)

> "Pois o Senhor é quem dá sabedoria; de sua boca procedem o conhecimento e o discernimento" (Provérbios 2:6)

Resumo

Com os avanços nas técnicas derivadas da teoria de detecção de sinais, muitos detectores objetivos de resposta (ORD) foram propostos baseados em testes estatísticos e em características dos sinais de interesse. Tais detectores são capazes de estimar a existência ou ausência de resposta a um sinal de entrada na saída de um sistema e podem ser utilizados em diversas áreas, desde usos militares a aplicações médicas. A derivação teórica de novos ORDs usualmente aborda apenas relações e testes estatísticos intuitivos, deixando de fora uma grande parte do espaço de busca que consiste de detectores não intuitivos. Este trabalho visa abordar o espaço de busca como um todo, englobando soluções óbvias e não óbvias, em busca de criar novos e mais robustos detectores através da combinação de elementos presentes nos ORDs existentes por meio de algoritmos evolutivos, tirando proveito de suas características estocásticas intrínsecas. Um algoritmo evolutivo customizado foi proposto, no qual os princípios da programação genética foram emulados através de um algoritmo genético, por meio de árvores geradoras de funções linearizadas e com tamanho fixo, também foi utilizada uma técnica de programação genética tradicional. Os ORDs Magnitude Quadrática da Coerência (MSC), Medida de Componente Síncrona e Testes F Local e Global foram utilizados na recombinação, juntamente com seus componentes (somatório, denominador e numerador). Sinais simulados foram utilizados durante o algoritmo evolutivo e, posteriormente, foram utilizados sinais reais de eletroencefalografia para validar os novos ORDs em detecções de respostas auditivas de regime permanente. A taxa de detecção foi utilizada como métrica de avaliação das soluções geradas durante o algoritmo evolutivo, o limiar de detecção foi ajustado por meio de simulações de Monte Carlo para o nível de significância de 5%. Os melhores detectores encontrados foram comparados por meio do levantamento de suas curvas de probabilidade de detecção e através da taxa de detecção em dados de validação. O melhor detector quanto à curva de probabilidade de detecção apresentou um incremento de 24,68% na área abaixo da curva e o melhor detector encontrado na validação apresentou um incremento de 13,1% na taxa de detecção, incrementos estes relativos à MSC. Desse modo é possível concluir que a utilização de algoritmos evolutivos é capaz de gerar novos detectores não óbvios, com melhores performances que os detectores existentes.

Palavras-chaves: Detector Objetivo de Resposta; ORD; Algoritmo Evolutivo; Programação Genética.

Abstract

Many objective response detectors (ORDs) were proposed based on statistical tests and on characteristics of the signals of interest, due the advances in techniques derived from the theory of signal detection. Such detectors are able to estimate the existence or absence of response to an input signal at the output of a system and can be used in a variety of fields, from military to medical applications. The theoretical derivation of new ORDs usually only addresses intuitive relations and statistical tests, leaving apart a large amount of the search space consisting of non-intuitive detectors. This work aims to approach the search space as a whole, analyzing obvious and not obvious solutions, in search of creating new and more robust detectors by combining elements present in the existing ORDs by means of an evolutionary algorithm, taking advantage of its stochastic characteristics. A modified evolutionary algorithm was proposed, in which the principles of genetic programming were emulated through a genetic algorithm, using linearized and fixed-size generating trees, a traditional genetic programming technique was also used. The ORDs Magnitude-Squared Coherence (MSC), Component Synchrony Measure, and Local and Global F-tests were used in recombination along with their components (sums, denominator, and numerator). Simulated signals were used during the evolutionary algorithm and real eletroencefalography signals were used to validate the new ORDs in detections of Auditory Steady-State Response. The detection rate was used as a metric to evaluate the solutions generated during the evolutionary algorithm and the detection threshold was adjusted by means of Monte Carlo simulations to the level of significance of 5%. The best detectors found were compared by their curve of probability of detection and by the detection rate in real validation data. The best detector for the curve of probability of detection showed an increase of 24.68% in the area under the curve and the best detector found in validation showed a 13.1% increase in the detection rate, compared to MSC. In this way it is possible to conclude that the use of evolutionary algorithms is capable of generating new non-obvious detectors, with better performance than the existing detectors.

Key-words: Objective Response Detector; ORD; Evolutionary Algorithm; Genetic Programming.

Lista de ilustrações

Figura 1 –	Exemplo de um sinal de EEG apresentando quatro canais referenciados ao canal Cz.	14
Figura 2 –	Diagrama de blocos simplificado do conjunto de sistemas entre o estímulo e o sinal de EEG.	16
Figura 3 –	EEG no domínio da frequência de dois indivíduos durante uma ses- são de audiometria objetiva. Os limiares auditivos obtidos com uma audiometria comportamental são exibidos no topo. Figura retirada de (PICTON et al., 2008).	18
Figura 4 –	Exemplo de codificação de genes, cálculo de <i>fitness, crossover</i> e mutação de um AG para encontrar a solução real da função $f(x) = (0, 3x)^3 - 0.25x^2 - 17.069$	9 9
Figura 5 –	Bepresentação em árvore da função $max(3 + z - u)$	$\frac{22}{25}$
Figura 6 –	Crossover entre duas árvores gerando árvores de tamanhos e formas	20
Figura 7 $-$	Um exemplo de uma representação em árvore e sua $array$ de código genético. A expressão representada é $9, 8(-6(-8MSC * 0, 3CSM) +$	20
	0, 1GFT), contendo nós não utilizados nas posições 6 e 7	27
Figura 8 –	PD dos ORDs originais. Na legenda são apresentadas as respectivas áreas abaixo da curva PD.	32
Figura 9 –	fitness ao longo da primeira execução da configuração I	35
Figura 10 – Figura 11 –	fitness ao longo da segunda execução da configuração VII PD dos melhores detectores encontrados. A PD da MSC também é	36
Figura 12 –	mostrada em linha pontilhada para possibilitar a comparação Teste Tukey entre as curvas PD dos melhores detectores encontrados e da MSC, evidenciando a diferença estatística dos novos detectores em	37
Figura 13 –	relação à MSC e à falta de diferença estatística entre os novos detectores. Teste Tukey entre as curvas PD de todos os melhores detectores en- contrados na PG emulada, evidenciando que não foram encontradas	37
	diferenças estatísticas entre os sete melhores detectores. \ldots \ldots \ldots	39
Figura 14 –	Incremento na probabilidade de detecção do melhor detector comparado à MSC	40
Figura 15 –	Número de nós e profundidade da árvore e <i>fitness</i> ao longo da primeira execução da PG não emulada.	40
Figura 16 –	Número de nós e profundidade da árvore e <i>fitness</i> ao longo da nona execução da PG não emulada.	41

Figura 17 – PD do melhor detector encontrado na PG não emulada. A PD da MSC também é mostrada em linha pontilhada para possibilitar a comparação. 42

Lista de tabelas

Tabela 1 –	Codificação adotada no material genético. Números negativos represen-	
	tam operadores e números positivos representam funções. \ldots .	28
Tabela 2 –	Configurações de restrições de níveis utilizadas	31
Tabela 3 –	Incremento na área abaixo da curva PD dos detectores resultante de	
	cada configuração, quando comparados à MSC	38
Tabela 4 –	Equações para os melhores detectores encontrados em dados simulados.	42
Tabela 5 –	Melhores detectores encontrados para a validação com dados reais e	
	suas respectivas métricas (a taxa de detecção é referenciada por VP,	
	sendo apresentada para 30 e 60 janelas e seu valor médio). \ldots .	43

Lista de abreviaturas e siglas

AE	Algoritmo Evolutivo
AG	Algoritmo Genético
ASSR	Resposta Auditiva em Regime Permanente
CSM	Medida de Componente Síncrona
EEG	Eletroencefalograma
FP	Taxa de Falsos Positivos
MSC	Magnitude Quadrática da Coerência
ORD	Detector Objetivo de Resposta
PD	Probabilidade de Detecção
PE	Potencial Evocado
PG	Programação Genética
SNR	Relação Sinal-Ruído
TFG	Teste F Global

TFL Teste F Local

Sumário

1 1.1 1.2 1.3 1.4 1.5	INTRODUÇÃO Detectores Objetivos de Resposta Eletroencefalografia Respostas Auditivas em Regime Permanente Algoritmos Evolutivos Objetivos	13 13 13 14 15 15
2	MATERIAIS E MÉTODOS	16
2.1	ORD	16
2.1.1	ORDs baseadas na amplitude	17
2.1.2	ORDs baseadas na fase	19
2.1.3	ORD baseada na amplitude e fase	19
2.2	Algoritmos Evolutivos	20
2.2.1	Algoritmo genético	21
2.2.2	Programação genética	25
2.2.3	Programação genética emulada	26
2.2.4	Programação genética não emulada	29
2.3	Simulações	29
2.3.1	PG emulada	29
2.3.2	PG não emulada	30
2.4	Determinação do Melhor ORD	31
2.5	Validação	32
2.5.1	Banco de dados	33
2.5.2	Métricas de validação	33
3	RESULTADOS E DISCUSSÃO	35
3.1	Desempenho da PG Emulada	35
3.2	Desempenho da PG não Emulada	38
3.3	Função Otimizada	41
3.4	Validação	43
4	CONCLUSÕES	45
5	TRABALHOS FUTUROS	46
	REFERÊNCIAS	47

1 Introdução

1.1 Detectores Objetivos de Resposta

Detectores objetivos de resposta (ORD, do inglês *Objective Response Detector*) são testes estatísticos que permitem estimar se existe ou não resposta na saída do sistema decorrente de uma entrada conhecida. Tais técnicas tem origem na teoria de detecção de sinais, com finalidade bélica, e foram adaptadas para diversos contextos incluindo diagnósticos médicos (CREELMAN, 2015).

As aplicações médicas estão relacionados à detecção de respostas a estímulos externos. Em tais aplicações o sistema é o corpo humano e o sinal de saída frequentemente é composto pelos potenciais elétricos produzidos pelo sistema nervoso e mensurados no escalpo. Os estímulos mais comuns são padrões visuais intermitentes, tons ou cliques sonoros, e estímulos somatossensoriais (pulsos de corrente) (MELGES; SÁ; INFANTOSI, 2012). Estímulos somatossensoriais podem ser utilizados para monitorar cirurgias vasculares (KEYHANI et al., 2009) e da coluna (CRUCCU et al., 2008), estímulos visuais podem ser utilizados para implementar interfaces cérebro-computador (técnicas que permitem que indivíduos com funções motoras debilitadas controlem dispositivos sem a utilização de tais funções motoras, por meio da atividade cerebral) (TANNUS; TIERRA-CRIOLLO; MELGES, 2013) e estímulos auditivos permitem o monitoramento da profundidade de aplicações de anestesia (CAGY, 2003). A detecção de respostas evocadas por meio de estímulos auditivos também podem ser utilizadas para implementar sistemas e protocolos de audiometria objetiva, nos quais são estimados os limiares auditivos de um indivíduo sem subjetividade do avaliador nem interferência do indivíduo avaliado (ELOI; ANTUNES; FELIX, 2018; LUTS et al., 2004; DOBIE; WILSON, 1993). Esta aplicação da detecção de estímulos auditivos aplicados à audiometria será abordada neste trabalho, pois a validação das técnicas será realizada em tal condição. Nestas aplicações mencionadas, o desenvolvimento de ORDs mais sensíveis permitem diagnósticos mais apurados.

1.2 Eletroencefalografia

Ao receber e transmitir estímulos, através da polarização e despolarização elétrica da membrana dos neurônios (LOPES, 2008), o cérebro produz potenciais elétricos que podem ser medidos através do escalpo através da técnica de eletroencefalografia (BRON-ZINO, 2006). Esta técnica consiste em posicionar eletrodos no escalpo de um indivíduo, frequentemente no padrão conhecido como 10-20 ou alguma variante, e realizar medições da diferença de potencial elétrico com relação a um eletrodo de referência (ou em relação

a um eletrodo terra) (SUBHA et al., 2010), o resultado final é um registro temporal desses potenciais, o qual é chamado de eletroencefalograma (EEG) (MANTRI et al., 2013). Um exemplo de sinal de EEG de quatro canais é exibido na Figura 1.



Figura 1 – Exemplo de um sinal de EEG apresentando quatro canais referenciados ao canal Cz.

1.3 Respostas Auditivas em Regime Permanente

Quando um estímulo externo é apresentado a um indivíduo é esperado que ocorram respostas elétricas advindas do sistema nervoso, essas respostas são chamadas de Potenciais Evocados (PE). Se este estímulo possuir algum padrão repetitivo, é esperado que o PE apresente o mesmo padrão de repetição (FELIX et al., 2014).

As respostas auditivas em regime permanente (ASSR, do inglês Auditory Steady-State Response) ocorrem quando estímulos sonoros são apresentados ao indivíduo com uma taxa de repetição alta o suficiente para que os PE de cada estímulos se sobreponham. Desse modo, após um transitório inicial, a sobreposição de respostas apresentará um padrão em regime permanente com maior energia na frequência de apresentação do estímulo (ELOI; ANTUNES; FELIX, 2018). Ao utilizar algum padrão de estímulo capaz de evocar uma ASSR, como um tom modulado em amplitude (AM) (DOLPHIN; MOUNTAIN, 1992), em conjunto com uma técnica ORD aplicada a dados de potenciais elétricos adquiridos no escalpo, é possível realizar alguns diagnósticos médicos, como por exemplo, a audiometria.

1.4 Algoritmos Evolutivos

Algoritmos evolutivos (AE) compreendem um conjunto de técnicas de otimização meta-heurísticas baseadas em populações, as quais têm como inspiração a evolução biológica. AEs utilizam mecanismos análogos aos biológicos, como reprodução, mutação, recombinação e seleção (AMASIFEN; ROMERO; MANTOVANI, 2005).

Atualmente, diversas aplicações do mundo real possuem uma complexidade cada vez maior, sendo possível citar áreas como aerodinâmica (RAM; LAL; AHMED, 2018), gerenciamento de operações (LEE, 2018), processamento de imagens (HERNANDEZ-BELTRAN et al., 2019), mineração de dados (DHIFLI; KARABADJI; ELATI, 2018), robótica, bioinformática, aprendizado de máquina e muitas outras que possuem problemas complexos e difíceis de serem resolvidos (VIKHAR, 2017).

Uma das possíveis abordagens para resolver estes problemas é utilizar algum dos tipos de AEs que, de modo semelhante à evolução biológica, seja capaz de encontrar soluções ótimas ou quasi-ótimas a partir de fatores aleatórios e uma pressão evolutiva para soluções melhores adaptadas para uma determinada situação. Este mesmo raciocínio pode ser aplicado para otimizar ORDs para uma determinada função-objetivo, como por exemplo, para uma maior sensibilidade.

1.5 Objetivos

Este trabalho tem como objetivo desenvolver, de forma automática, novos e mais robustos ORDs, através da recombinação de ORDs já existentes, utilizando de algoritmos evolutivos.

Dado o objetivo geral, têm-se como objetivos específicos:

- Implementar um AE capaz de criar combinações das funções dos ORDs utilizados, de forma que iterativamente sejas obtidas populações de ORDs com melhores taxas de detecção;
- Analisar os resultados obtidos com o AE, buscando por melhores ORDs;
- Validar os novos ORDs em dados de EEG reais, durante estimulações auditivas em regime permanente.

2 Materiais e Métodos

A metodologia abordada neste trabalho é sintetizada em:

- Definir os elementos de ORDs existentes que serão as bases da recombinação. Tópico abordado na seção 2.1.
- Utilizar de algoritmos evolutivos para realizar a recombinação destes elementos. Tópico abordado na seção 2.2.
- Avaliar os ORDs obtidos com os algoritmos evolutivos em dados simulados (seção 2.4) e reais (seção 2.5).

Para a avaliação da função objetivo dos algoritmos evolutivos, bem como o desempenho em dados simulados, foram utilizadas simulações de Monte Carlo conforme é descrito na seção 2.3.

2.1 ORD

Assumindo a detecção de uma ASSR, a resposta presente no EEG que será detectada por um ORD advém de uma estimulação auditiva. O conjunto que compreende o sistema auditivo, sistema nervoso e sistema eletrônico de aquisição do EEG pode ser representado por um sistema conforme o diagrama de blocos da Figura 2. Neste diagrama de blocos o estímulo é denotado por X(s), $N_1(s)$ representa os ruídos sonoros externos, $G_1(s)$ é o sistema auditivo, $N_2(s)$ representa os ruídos decorrentes das diversas atividades bioelétricas do corpo, $G_2(s)$ é o sistema nervoso, $N_3(s)$ representa todos os ruídos do sistema de aquisição e Y(s) é o EEG coletado.



Figura 2 – Diagrama de blocos simplificado do conjunto de sistemas entre o estímulo e o sinal de EEG.

Logo, o EEG pode ser representado pela equação 2.1. Os sistemas auditivo e nervoso não são completamente lineares, porém, para a modelagem apresentada neste trabalho, as não linearidades serão representadas por ruídos, os quais podem ser aglutinados com os demais ruídos e suas respostas após passarem por $G_1(s)$ e $G_2(s)$. Realizando essa simplificação e combinando as partes lineares de $G_1(s)$ e $G_2(s)$ em G(s), obtemos a equação 2.2.

$$Y(s) = ((X(s) + N_1(s)) \times G_1(s) + N_2(s)) \times G_2(s) + N_3(s)$$
(2.1)

$$Y(s) = X(s) \times G(s) + N(s)$$
(2.2)

A equação 2.2 explicita o fato de que o sinal obtido com um EEG durante uma estimulação auditiva é composta por uma componente linearmente dependente do estímulo de entrada e um ruído. Neste trabalho o ruído de fundo do EEG será considerado gaussiano, estacionário e ergódico.

Uma aplicação prática de ORDs em diagnósticos é a audiometria objetiva, a qual tem como finalidade a identificação dos limiares auditivos através de medições eletrofisiológicas sem interferência do indivíduo a ser diagnosticado (PICTON et al., 2008).

A ASSR pode ser facilmente identificada e distinguida do ruído de fundo quando sua relação sinal-ruído (SNR) é alta, porém, quando a SNR é baixa, não é possível distinguir visualmente o ruído da ASSR. Na Figura 3 é possível observar estas duas condições, para o EEG da direita em 80 dB é possível distinguir claramente a quatro primeiras ASSRs, já para o EEG da esquerda em 60 dB não é possível distinguir todas as quatro primeiras ASSRs, sendo que, de acordo com a audiometria comportamental, o indivíduo estaria escutando o estímulo.

Para o caso da detecção do limiar auditivo, situação em que a SNR é considerada baixa, é necessário utilizar alguma técnica objetiva para definir se houve ou não uma ASSR. Com este intuito, diversos ORDs foram propostos, sendo que tais detectores também podem ser utilizados em outras aplicações, não se restringindo apenas à detecção de ASSRs. Neste trabalho serão abordadas apenas técnicas baseadas em sinais no domínio da frequência.

Para criar um novo ORD mais robusto através de recombinação de outros é necessário escolher ORDs que utilizem diferentes características dos sinais. Neste trabalho foram utilizados detectores baseados apenas na amplitude do sinal, apenas na fase e baseados na amplitude e fase.

2.1.1 ORDs baseadas na amplitude

O teste F global (TFG) compara o valor da amplitude do sinal no qual será testada a presença de uma resposta com o valor da amplitude de um sinal que não teve nenhum estímulo de entrada e, portanto, não possui resposta. Este ORD baseia-se no aumento de energia no bin do estímulo quando existe uma resposta ao sinal de entrada.

O teste F local (TFL) utiliza apenas o sinal no qual será testada a presença de uma resposta e compara o bin de estimulação com os bins laterais. Este ORD baseia-se no



Figura 3 – EEG no domínio da frequência de dois indivíduos durante uma sessão de audiometria objetiva. Os limiares auditivos obtidos com uma audiometria comportamental são exibidos no topo. Figura retirada de (PICTON et al., 2008).

incremento de energia no bin de estímulo enquanto os demais bins não sofrem alteração e são considerados apenas ruídos.

Tais detectores são definidos, respectivamente, pelas equações 2.3 (SHUMWAY, 1988) e 2.4 (DOBIE; WILSON, 1993).

$$TFG(f) = \frac{\sum_{i=1}^{M} |Y_i(f)|^2}{\sum_{i=1}^{M} |Y_i(f)|^2 + \sum_{i=1}^{M} |X_i(f)|^2}$$
(2.3)

$$TFL(f) = \frac{|\overline{Y}(f)|^2}{\sum_{j=-L/2}^{L/2} |\overline{Y}(f_j)|^2}$$
(2.4)

Onde $Y_i(f)$ é a transformada de Fourier da i-ésima janela do sinal a ser testado, Mé o número de janelas utilizadas, $X_i(f)$ é a transformada de Fourier da i-ésima janela do sinal quando nenhuma entrada é aplicada, L é o número de bins laterais da transformada de Fourier utilizados, $\overline{Y}(*)$ é a transformada de Fourier de M janelas concatenadas do sinal a ser testado e f_j é o j-ésimo bin lateral à frequência a ser testada (ou seja, próximo a frequência do estímulo mas sem presença de resposta). Além destes dois ORDs, seus numeradores e denominadores, bem como uma versão normalizada do TFL, também foram utilizados para a recombinação.

2.1.2 ORDs baseadas na fase

A medida de componente síncrona (CSM, do inglês *Component Synchrony Measure*) baseia-se na manutenção da fase do bin de interesse no sinal a ser testado devido à entrada aplicada. A igualdade trigonométrica $\cos^2 \phi + \sin^2 \phi = 1$ é adaptada e utilizada para mensurar a manutenção da fase, conforme a equação 2.5 (FRIDMAN et al., 1984).

$$CSM(f) = \left[\frac{1}{M}\sum_{i=1}^{M}\cos\phi_i(f)\right]^2 + \left[\frac{1}{M}\sum_{i=1}^{M}\sin\phi_i(f)\right]^2$$
(2.5)

Onde $\phi_i(f)$ é a fase da transformada de Fourier da i-ésima janela do sinal a ser testado e M é o número de janelas utilizada.

Os somatórios dos cossenos e dos senos e uma versão hiperbólica da CSM também foram utilizados de forma individual para a recombinação.

2.1.3 ORD baseada na amplitude e fase

A magnitude quadrática da coerência (MSC, do inglês *Magnitude-Squared Coherence*) entre dois sinais é utilizado como um teste que indica o quanto dois sinais são correlacionados (linearmente) para cada frequência (PENNY, 2009). Com valores entre 0 e 1 tem-se, respectivamente, os extremos de completa falta de correlação e relação perfeitamente linear entre dois sinais (SAGARTZAZU; SCHUHMACHER; ISASA, 2010).

A correlação entre dois sinais $x(t) \in y(t)$ é dada pela equação 2.6.

$$C_{xy}(f) = \frac{|G_{xy}(f)|^2}{G_{xx}(f)G_y(f)}$$
(2.6)

Onde $G_{xy}(f)$ é a densidade espectral de potência cruzada entre $x \in y$, e $G_{xx}(f) \in G_{yy}(f)$ são as densidades auto-espectrais de $x \in y$, respectivamente.

Esta técnica pode ser utilizada com um ORD para diversos tipos de entradas que criarão uma resposta a ser detectada. Para um estímulo periódico, quando as estimativas espectrais, ou seja, as transformadas de Fourier, são realizadas em sinais janelados, tem-se que a transformada de Fourier do estímulo é invariante. Para este caso específico, o valor da MSC depende apenas da transformada de Fourier do sinal de saída Y(f) e é denotada pela equação 2.7 (DOBIE; WILSON, 1989).

$$MSC(f) = \frac{\left|\sum_{i=1}^{M} Y_i(f)\right|^2}{M\sum_{i=1}^{M} |Y_i(f)|^2}$$
(2.7)

Onde $Y_i(f)$ é a transformada de Fourier da i-ésima janela do sinal a ser testado e M é o número de janelas utilizadas.

O numerador e o denominador da MSC, bem como sua versão completa, foram utilizados como elementos a serem recombinados.

2.2 Algoritmos Evolutivos

Os algoritmos evolutivos têm fundamentação na teoria da evolução biológica. Do mesmo modo que, em geral, a evolução biológica otimiza uma população de indivíduos para o ambiente em que estão inseridos, os algoritmos evolutivos otimizam uma população de soluções para uma determinada função objetivo, a qual mede o nível de adaptabilidade, ou *fitness*, de cada indivíduo.

Por se tratar de uma representação computacional da teoria de seleção natural, proposta por Charles Darwin no livro A Origem das Espécies (1859), os algoritmos evolutivos seguem a seguinte definição: "[...] qualquer variação, por menor que seja e por qualquer que seja a causa, se for de algum modo lucrativa para um indivíduo de qualquer espécie [...], tenderá à preservação daquele indivíduo, e geralmente será herdada pelos descendentes." Darwin (1859). Este conceito simples é a base de todos os algoritmos evolutivos baseados em populações, desse modo, enquanto existir alguma diferença, por mais sutil que seja, inevitavelmente haverá a seleção dos indivíduos melhor adaptados, ou seja, com maiores vantagens para uma determinada situação.

Os principais postulados da genética e da seleção natural , utilizados nos algoritmos evolutivos podem ser resumidos, de acordo com Barcellos (2000), em:

- A evolução atua apenas nos cromossomos e não nos indivíduos. Deste modo a vida do indivíduo não influenciará os cromossomos, já os cromossomos influenciarão no indivíduo.
- A seleção natural é o processo responsável por fazer com que os cromossomos que geram os indivíduos melhores adaptados para o ambiente sejam mais prósperos em relação à reprodução e sobrevivência, assim perpetuando através das gerações.
- A evolução ocorre ao longo dos processos de reprodução, durante os quais ocorre a recombinação dos genes dos pais (*crossover*) e podem ocorrer mutações aleatórias. Tais fatos tornam o material genético dos filhos diferente do material genético dos seus genitores.

A partir destes postulados é possível definir a estrutura básica presente em todos os algoritmos evolutivos, a qual pode ser sintetizada no seguinte pseudocódigo:

Algoritmo 1: Algoritmo Evolutivo Genérico			
1	Gerar população inicial aleatória		
2	Calcular o fitness de cada indivíduo		
3	Enquanto fitness_médio $<$ fitness alvo faça		
4	Selecionar os indivíduos com melhores fitness para reprodução		
5	Criar novos indivíduos através de crossover		
6	Aplicar operadores de mutação		
7	Calcular o fitness de cada indivíduo novo		
8	Substituir a população antiga pela nova		

Para a implementação de um algoritmo evolutivo é importante atentar para a forma de simulação dos indivíduos, ou seja, como será codificado o material genético e como será realizado o cálculo do *fitness*. O tipo de indivíduo utilizado, ou seja, o tipo da solução a ser encontrada, e a forma de representa-la são as características que separam os diferentes tipos de algoritmos evolutivos. A seguir serão apresentados os dois tipos de algoritmos evolutivos utilizados neste trabalho e como foram implementados.

2.2.1 Algoritmo genético

O algoritmo genético (AG), inicialmente proposto em (HOLLAND, 1975), apresenta uma representação cromossômica numérica e linear, ou seja, todas as características de um indivíduo serão números, ou informações que podem ser codificadas em números, agrupadas em um vetor.

Devido à possibilidade de codificação de informações em números correspondentes, o algoritmo genético pode ser utilizado para otimizar funções objetivos que utilizam os mais diversos tipos de entradas. Com isso é possível lidar com otimização envolvendo variáveis estritamente inteiras, reais, complexas, binárias, literais ou qualquer outro tipo de enumeração.

Como todos os tipos de variáveis suportadas por computadores são codificadas como binárias, esta é a representação mais genérica que pode ser utilizada em um AG.

Um exemplo simples de aplicação de AG em otimização é a busca da raiz de uma função. É possível adotar diversas metodologias de representação de soluções para encontrar a raiz real da função $f(x) = (0, 3x)^3 - 0, 25x^2 - 17,069$, e por consequência minimizá-la, utilizando um AG. Uma dessas possíveis metodologias é a codificação binária em 6 bits para a entrada x. A Figura 4 mostra a representação do cromossomo de 6 possíveis indivíduos, o *fitness* obtido quando a métrica utilizada é |f(x)|, um *crossover* entre os dois melhores indivíduos (menor valor de *fitness*) com troca gênica de cromossomos nos seus pontos médios e uma mutação no primeiro filho na segunda posição do vetor que representa seu material genético. Neste exemplo é mostrado apenas uma pequena população de indivíduos e apenas um processo de reprodução (*crossover* e mutação), porém na resolução de problemas práticos o tamanho da população deverá ser ajustado de acordo com o número de parâmetros existentes na solução e o processo de *crossover* e mutação ocorrerão diversas vezes até criar indivíduos suficientes para a próxima geração.



Figura 4 – Exemplo de codificação de genes, cálculo de *fitness, crossover* e mutação de um AG para encontrar a solução real da função $f(x) = (0, 3x)^3 - 0, 25x^2 - 17,069$.

O processo de escolha dos pais pode ser realizado de diversas formas, as quais tentam emular a forma com que seres vivos escolhem seus parceiros baseados nos *fitness*, ou prezam pela manutenção da pressão evolutiva em determinados níveis, para evitar uma convergência precoce, evitar a dominância de indivíduos que representam mínimos/máximos locais e promover a diversidade genética da população. A seguir são apresentados alguns operadores de seleção segundo Souza (2014):

• *Método da roleta*: Cada indivíduo possui uma probabilidade de escolha diretamente proporcional ao *fitness* obtido, dado por

$$P(i) = \frac{fitness_i}{\sum_j fitness_j} \tag{2.8}$$

Este método não aceita valores negativos de *fitness* e possui problemas de super indivíduos quando a diferença de *fitness* dentro de uma população é discrepante e de pouca pressão evolutiva quando ocorre o contrário.

- *Estocástico uniforme*: Cada indivíduo representará uma seção em uma linha, sendo que o comprimento desta seção é proporcional ao *fitness* obtido. A cada seleção de pais um marcador é movido ao longo da linha em passos de tamanhos iguais e o pai selecionado é o que corresponde à seção na qual o marcador parou. Na primeira seleção o marcador é colocado aleatoriamente em alguma posição na linha.
- *Escalonamento Sigma*: Cada indivíduo possui uma probabilidade de escolha proporcional ao *fitness* obtido, porém dado pela função de mapeamento

$$fitness(i) = 1 + \frac{f(i) - \bar{f}}{2\sigma}$$
(2.9)

Onde f(i) é o *fitness* do indivíduo, \overline{f} é o *fitness* médio da população e σ é o desvio padrão dos *fitness* da população. O valor do *fitness* então é utilizado no método da roleta.

Este método corrige os problemas do método da roleta puro, desse modo é menos susceptível a uma convergência precoce, a qual pode levar a um máximo/mínimo local.

Método de Ranking: A probabilidade de escolha de um indivíduo será proporcional à posição de seu *fitness* em relação ao dos demais. Para utilizar no método da roleta, o *fitness* é mapeado segundo a função

$$fitness(i) = Min + (Max - Min)\frac{rank(i) - 1}{N - 1}$$
(2.10)

Sendo Min e Max, respectivamente, os valores mínimo e máximos do *fitness* mapeado, N o tamanho da população e rank(i) a posição do indivíduo no ranking da população. Este método busca manter a pressão evolutiva constante ao longo das gerações e também evita os problemas de utilizar o método da roleta puro.

 Seleção por torneio: Esta seleção emula o comportamento típico de populações biológicas que se agrupam em durante o período de reprodução. Dois subgrupos da população são escolhidos aleatoriamente e o casal que irá reproduzir é definido pelos indivíduos com o maior *fitness* em cada grupo. Este método permite que indivíduos com *fitness* melhores sejam reproduzidos, quando estão em grupos nos quais os demais indivíduos são ainda piores, e desse modo permite uma maior variedade genética.

O operador de seleção deve ser escolhido de acordo com a complexidade do problema a ser resolvido. Apesar de apresentar alguns problemas, o método da roleta pode ser utilizado em diversos casos como um método *default*.

O operador de cruzamento depende exclusivamente da representação de cromossomos adotada. O operador mais comum para uma representação binária é a permutação de bits, no qual determinadas posições do cromossomo serão trocadas entre os dois pais, semelhante ao *crossover* biológico. Para representações que utilizam números reais temos os seguintes cruzamentos (PELTOKANGAS; SORSA, 2008):

- Simulated Binary Crossover: Realiza o crossover binário em cada representação binária dos números reais que compõem os cromossomos dos pais.
- *Média*: O valor resultante para cada posição do código genético resultante é a média dos valores dos cromossomos dos pais.
- Aritmético: Chamando cada gene dos cromossomos dos pais de $X_i^{(1)}$ e $X_i^{(2)}$, os genes dos cromossomos do filho serão dados por

$$Y_i = \alpha_i X_i^{(1)} + (1 - \alpha_i) X_i^{(2)}$$
(2.11)

Sendo que α_i é um número entre 0 e 1. Podendo ser constante, no *crossover* aritmético uniforme, ou aleatório entre as gerações, seguindo uma distribuição uniforme, no *crossover* aritmético não uniforme.

• Heurístico: Novamente chamando cada gene dos cromossomos dos pais de $X_i^{(1)}$ e $X_i^{(2)}$, os genes dos cromossomos dos filhos serão

$$Y_i = \alpha (X_i^{(2)} - X_i^{(1)}) + X_i^{(2)}$$
(2.12)

Sendo α_i um valor aleatório gerado a partir de uma distribuição uniforme entre 0 e 1. Caso o valor do gene seja um valor não permitido, um novo gene será gerado seguindo a equação

$$Y_i = X_i^{(2)} + \beta_i |X_i^{(1)} - X_i^{(2)}|$$
(2.13)

Sendo β_i um valor aleatório gerado por uma distribuição de Laplace.

• BLX- α : Utilizando a mesma notação para os genes dos cromossomos dos pais, os genes dos filhos serão números aleatórios gerados por uma distribuição uniforme no intervalo $[min(X_i^{(1)}, X_i^{(2)}) - \alpha I, max(X_i^{(1)}, X_i^{(2)}) + \alpha I]$. Sendo que α é um número fixo, geralmente 0,05 ou 0,1, e $I = |X_i^{(1)} - X_i^{(2)}|$. Este crossover tem como característica a capacidade de gerar genes com valores que estão fora do intervalo entre os valores dos genes dos pais.

É importante notar que todas as operações de *crossover* para AG é realizada termo a termo nos elementos dos cromossomos. Com isso o tamanho do material genético é o mesmo para todos os indivíduos ao longo das gerações.

O uso de AG é muito útil quando é necessário realizar a otimização de parâmetros, outros tipos de otimização requerem outros tipos de AE.

2.2.2 Programação genética

A programação genética (PG) é um AE que visa um dos principais objetivos da ciência da computação, a programação automática (KOZA, 1997). Esta AE aplica os fundamentos da teoria de Darwin em indivíduos que representam programas, rotinas ou funções, de modo a produzir como solução um programa (KOZA, 1997; POLI et al., 2008; MONTANA, 1995). Este programa não é explicitamente programado, sendo necessário apenas definir o domínio (definido pela técnica de PG escolhida) e uma forma de calcular o *fitness* para um determinado objetivo (KOZA; POLI, 2003).

A principal diferença em relação ao AG está no fato de que o tamanho e formato da representação do programa podem variar (KOZA, 1992), já que a princípio um *script* linear com um número de linhas definido pode ser uma solução que um AG consegue otimizar.

Usualmente os programas são representados por meio de árvores lógicas ou representações lineares destas (PASSARELLA et al., 2018), representações cartesianas e em *bytecodes* lineares também são utilizados, sendo esta última também conhecida como programação genética linear (WILSON; BANZHAF, 2008). A Figura 5 apresenta a representação em árvore da função max(3 + z, x - y), a qual também poderia ser representada em sua notação linear de prefixo(max(+3z)(-xy)).



Figura 5 – Representação em árvore da função max(3 + z, x - y).

A notação linear de prefixo, consiste de uma das possíveis formas de representar uma árvore como uma estrutura linear, não devendo ser confundido com a representação por *bytecodes*. O tipo de representação adotada pode variar dependendo da linguagem de programação adotada e do tipo de problema (POLI et al., 2008), porém os cromossomos no formato de árvore são os mais simples de entender e implementar em diversas linguagens de programação, como Matlab, Java, C#, Lisp, entre outras. Esta estrutura permite visualizar facilmente como o tamanho e formato do cromossomo podem sofrer alterações. Dentre os operadores de crossover utilizados na PG temos a remoção de nós terminais e substituição de nós por subárvores, ao contrário do operador de permuta existente no AG, ambos operadores alteram tanto o tamanho quanto a forma do cromossomo. Disso tem-se outra característica da PG: a princípio, com o passar das gerações, o tamanho do cromossomo é ilimitado. No entanto, essa característica encontra limitações na memória ocupada e, portanto, é necessário limitar de alguma forma o crescimento dos cromossomos em uma PG. A figura 6 mostra essa maleabilidade no tamanho e forma do material genético em uma PG, nela está exemplificado um crossover entre as funções $(x \times y) + 1 e 0 - (x + y)$, resultando nas funções $0 - y e (x \times (x + y)) + 1$.



Figura 6 – Crossover entre duas árvores gerando árvores de tamanhos e formas diferentes.

Esta maleabilidade do material genético em uma PG a torna uma boa opção para a busca em espaços de busca virtualmente infinitos, como é o caso da combinação de comandos em um programa ou da combinação de operadores em uma função.

2.2.3 Programação genética emulada

Para encontrar a equação de novos ORDs a partir dos já existentes, foi proposta uma adaptação da técnica de PG utilizando árvores binárias para gerar as funções. A estratégia consiste em utilizar duas árvores binárias, a principal consiste de operadores matemáticos e funções enquanto a segunda consiste de pesos pelos quais cada nó da árvore principal será ponderado. Ambas as árvores serão estritamente binárias e completas, e serão representadas por *arrays* de tamanho fixo (SHAFFER, 2013). O material genético de cada indivíduo constituirá das duas *arrays* concatenadas, sendo que os indivíduos da PG são as funções dos novos ORDs.

Operadores matemáticos binários foram utilizados, sendo seus operandos os valores retornados pelos nós filhos. As funções utilizadas foram as técnicas ORDs apresentadas neste trabalho e partes destas (como numerador e/ou denominador das expressões), tais funções possuem apenas entradas advindas do sinal a ser testado, logo os nós filhos de nós contendo funções não serão utilizados e, portanto, todos os nós descendentes serão desconsiderados. Apesar de serem desconsiderados na construção da função-solução, estes nós continuarão a fazer parte do material genético, já que a recombinação pode colocá-los como filhos de um nó contendo operadores matemáticos.

A Figura 7 apresenta um exemplo de uma função representada pelas árvores e seu material genético correspondente. Os nós 6 e 7 da árvore principal são desconsiderados na construção da função representada, pois são filhos de um nó de função.



Figura 7 – Um exemplo de uma representação em árvore e sua array de código genético. A expressão representada é 9, 8(-6(-8MSC*0, 3CSM) + 0, 1GFT), contendo nós não utilizados nas posições 6 e 7.

Para evitar códigos genéticos impossíveis, como um nó de operador matemático no último nível da árvore, foi utilizada uma restrição na qual apenas funções podem ser atribuídas aos nós do último nível. Uma restrição adicional foi atribuída de forma a possibilitar um controle no nível de complexidade mínimo da função gerada, na qual os k primeiros níveis deverão conter apenas operadores matemáticos, dessa forma a função final consistirá de no mínimo uma combinação matemática de 2^k funções. Os nós da árvore de ponderação possuem a mesma restrição para todos os níveis, sendo todos os seus genes números reais entre -10 e +10. Estes limites foram adotados devido aos custos computacionais. Note que estes limites são aplicados a cada nó individual e portanto a função final simplificada pode conter pesos fora destes limites, como é possível ver na versão simplificada da função apresentada na Figura 7 que é 141, 12MSC * CSM + 0, 98GFT. Uma restrição intrínseca da representação por meio de vetores de tamanho fixo é o próprio tamanho da árvore, o qual será definido através da profundidade (número de níveis) da árvore.

Os operadores aritméticos e as funções utilizadas são enumeradas na Tabela 1, de acordo com a codificação adotada. As funções utilizadas estão descritas na seção 2.1.

ID	Operador/Função		
-5	Exponenciação		
-4	Divisão		
-3	Multiplicação		
-2	Subtração		
-1	Adição		
0	Constante unitária		
1	MSC		
2	CSM		
3	TFG		
4	TFL		
5	MSC numerador		
6	MSC denominador		
7	CSM seno		
8	CSM cosseno		
9	TFG numerador		
10	TFG denominador		
11	TFL numerador		
12	TFL denominador		
13	CSM hiperbólico		
14	TFL média		

Tabela 1 – Codificação adotada no material genético. Números negativos representam operadores e números positivos representam funções.

Um AG foi adotado para realizar a evolução das populações de soluções, visto que o material genético desta metodologia consiste de um vetor de tamanho fixo contendo números inteiros e números reais. O algoritmo foi executado por meio da função ga.m da *Global Optimization Toolbox* do Matlab[®], utilizando seleção estocástica uniforme, *crossover* BLX- α , 80% de taxa de *crossover*, população de 200 indivíduos, com elitismo de 10 indivíduos, e um máximo de 100 gerações. Por emular a PG por meio de um AG, esta estratégia é referenciada neste trabalho como PG emulada.

2.2.4 Programação genética não emulada

O uso de programação genética não emulada, ou seja, um implementação da PG que realiza todo o processo de evolução por meio de árvores, incluindo *crossover* por meio da troca de subárvores, também foi testada. Neste trabalho foi implementada uma PG no Matlab, representando as funções por meio de árvores, porém desta vez é necessária apenas uma árvore para representar uma função por completo, visto que cada nó é uma entidade que já contém as informações da operação/função e respectivo peso. A representação em árvore abriu a possibilidade de utilizar operadores unários, com isso foram adicionados os operadores logaritmo neperiano e valor absoluto, possuindo ID -6 e -7, respectivamente.

A princípio a árvore pode possuir profundidade ilimitada, porém é necessário impor um limite, visto que a função é calculada de forma recursiva (cada nó pai chama as funções/operadores do nó filho) e o Matlab possui um limite de chamadas recursivas. Desse modo foi necessário restringir a profundidade máxima da árvore em 10 níveis, é importante notar que uma árvore com 10 níveis pode representar a combinação de até 2⁹ funções. Esta restrição foi imposta no *crossover*, sendo que qualquer indivíduo com mais de 10 níveis não foi incluído na próxima geração, e um novo indivíduo é gerado para compensar.

A PG implementada faz uso de seleção por torneio, o *crossover* ocorre com a troca de subárvores em nós dos pais e dois tipos de mutação podem ocorrer: substituição de uma subárvore por outra gerada aleatoriamente (em 10% das mutações) ou exclusão de uma subárvore (com substituição por um nó do tipo função, o qual assegura que a árvore continuará válida, em 10% das mutações). Foram utilizados 100 indivíduos por geração e um limite de 500 gerações, também foi implementado um sistema de elitismo, no qual os 4 melhores indivíduos de cada geração são mantidos para a geração seguinte. O único critério de parada implementado foi o máximo de gerações, diferente da PG emulada, que tem um critério de parada adicional, quando o *fitness* médio da população não varia ao longo de gerações sucessivas.

2.3 Simulações

Em ambas as PGs implementadas os valores críticos, o *fitness* e as curvas de probabilidade de detecção (curvas PD) dos indivíduos foram determinados por meio de simulações de Monte Carlo a um nível de significância de 5% (FELIX et al., 2018). As configurações utilizadas em cada uma das PGs foram ligeiramente diferentes.

2.3.1 PG emulada

Os valores críticos de cada indivíduo foram determinados por meio de simulações de Monte Carlo com 100.000 iterações. Estas simulações foram realizadas utilizando ruídos

Gaussianos, independentes e normalizados para variância unitária, divididos em 30 janelas de 1 segundo (256 pontos por janela, emulando uma frequência de amostragem de 256 Hz). Como o valor crítico é definido por simulações de Monte Carlo, a taxa de falso positivos (FP) para sinais simulados é sempre garantida.

Os sinais de teste foram simulados pela soma de um ruído Gaussiano a uma senóide de 25 Hz e fase aleatória (uniformemente distribuída entre 0 e 2π), com amplitude ajustada de forma a obter uma determinada relação sinal-ruído (SNR). Os sinais resultantes foram normalizados para uma variância unitária, assim funções susceptíveis a variações no valor retornado apenas pela variação da amplitude total do sinal a ser testado não são falseadas nas condições reais de utilização devido às condições impostas pela simulação. Esta normalização é, portanto, obrigatória para a aplicação das funções encontradas.

Para o cálculo do *fitness* foi utilizado um conjunto de 2000 sinais simulados, os quais possuíam SNR aleatória e seguindo uma distribuição gaussiana com média -15 dB e variância 10. Esta faixa está em acordo com os resultados de SNR encontrados em (GOLDENHOLZ et al., 2009). A SNR aleatória foi utilizada para que os detectores obtidos não fossem específicos para uma determinada SNR. Os sinais simulados foram criados com diferentes SNRs, porém, como o sinal é normalizado para variância unitária, a energia total não depende da SNR. A função de *fitness* para o AG foi (1 - PD), onde PD é a probabilidade de detecção, ou seja, o número de detecções em relação ao número de sinais simulados, esta função foi utilizada devido ao fato de o AG utilizado realizar otimizações do tipo minimização. O conjunto de sinais era trocado a cada 8 gerações, para evitar que os detectores se tornassem específicos para um determinado conjunto de sinais simulados.

As curvas PD foram levantadas utilizando 10 mil sinais simulados para cada SNR entre -30 dB e 5 dB.

2.3.2 PG não emulada

Nesta PG as simulações foram realizadas de forma a se assemelharem aos dados reais utilizados para validação, com isso a frequência de amostragem em todos os sinais foi de 1000 Hz e o sinal adicionado ao ruído para calcular o *fitness* e a curva PD é constituído de uma senóide de 80 Hz, também de fase aleatória. Foram mantidos o número de janelas do sinal (sendo que dessa vez cada janela corresponde a 1000 pontos) e o número de iterações para cálculo do valor crítico, em relação à PG emulada.

O fitness foi calculado com 100 mil sinais simulados, também possuindo SNR aleatória e seguindo uma distribuição gaussiana com média -15 dB e variância 10, valores estes que foram escolhidos para que grande parte dos sinais apresentem SNR próxima à SNR para a qual a MSC apresenta 50% de probabilidade de detecção. A função de fitness nesta PG foi apenas a PD calculada para os 100 mil sinais. Como o conjunto de

sinais simulados é muito grande, não foi necessário realizar a troca dos sinais simulados após um determinado número de gerações, pois foi assumido que essa amostra é uma boa representação da população de sinais simulados.

As curvas PD também utilizaram 10 mil sinais simulados para cada SNR, porém foram utilizadas SNRs de -40 dB a 0 dB, com passos de 0,25 dB. Este limite foi ajustado após serem calculadas as curvas para os detectores obtidos com a PG emulada e foi escolhido de forma a ter uma melhor representação das regiões de interesse da curva.

2.4 Determinação do Melhor ORD

Como a PG emulada possui duas restrições a serem impostas (profundidade e número de níveis exclusivos de operados matemáticos) foi necessário realizar uma variação nestes parâmetros e posteriormente realizar uma busca pelo melhor detector entre eles. Para cada configuração de restrições listada na Tabela 2 foram realizadas duas execuções do AE proposto.

Configuração	Profundidade	k níveis com apenas operadores matemáticos
Ι	5	1
II	5	2
III	5	3
IV	5	4
V	10	1
VI	10	2
VII	10	4

Tabela 2 – Configurações de restrições de níveis utilizadas.

Como o cálculo do *fitness* para a PG emulada é afetada a cada oito gerações pela renovação dos sinais utilizados para a análise, é possível que uma mesma função tenha *fitness* diferentes em duas gerações. Desse modo é possível que o melhor *fitness* seja alcançado em alguma geração propícia à função avaliada, logo falseando a análise. Este efeito pode ocorrer inclusive na última geração executada, desse modo o melhor resultado retornado pelo AE proposto não corresponderá à melhor função encontrada dentro de todas as gerações. Porém as melhores funções tendem a perpetuar por diversas gerações e desse modo uma função que tenha seu *fitness* falseado será gradualmente deixada de lado ao longo de gerações que utilizem um novo conjunto de sinais simulados. Para evitar o falseamento de *fitness*, foi levantado um histograma dos 1000 melhores indivíduos, de acordo com o *fitness* obtido no momento de sua avaliação no AG, e o melhor indivíduo foi definido como o que apresentou maior frequência, em caso de empate foi utilizado o critério de melhor *fitness* médio. Para a PG não emulada, foram executadas 20 rodadas de evolução e o melhor indivíduo foi determinado como aquele com maior *fitness* dentre os indivíduos da última geração de cada uma das execuções da PG.

Os melhores ORDs obtidos foram comparadas por meio do levantamento da curva PD. Estes detectores foram comparados com a MSC (dentre os ORDs originais, a MSC apresentou a melhor performance em termos de área abaixo da curva PD, como é mostrado na Figura 8). Nesta comparação foi calculado o ganho de área, denotado pela equação

$$ganho(i) = \frac{APD(i) - APD_{MSC}}{APD_{MSC}}$$
(2.14)

Sendo APD(i) a área abaixo da curva PD do ORD *i* e APD_{MSC} a área abaixo da curva PD da MSC. O cálculo da área abaixo da curva PD foi realizado entre as SNR -19 a -6 dB, que correspondem, respectivamente, às probabilidades de 10% e 95% de detecção para a MSC, ou seja, 5% acima da detecção aleatória e 5% abaixo da detecção total.



Figura 8 – PD dos ORDs originais. Na legenda são apresentadas as respectivas áreas abaixo da curva PD.

2.5 Validação

Visto que o cálculo do *fitness* durante o algoritmo evolutivo foi realizado com dados simulados, é necessário realizar uma validação utilizando dados reais.

2.5.1 Banco de dados

Foram utilizados dados coletados durante um protocolo de audiometria. A aquisição dos EEG foi realizada no Núcleo Interdisciplinar de Análise de Sinais da Universidade Federal de Viçosa. Foram utilizados EEGs provenientes de 11 voluntários, com faixa etária de 20 a 35 anos, com audição normal. O protocolo de audiometria foi realizado em uma cabine com isolamento acústico.

O protocolo da audiometria consistia de sessões com estimulação múltipla, utilizando oito tons modulados exponencialmente de segunda ordem (AM2) (JOHN; DIMITRIJEVIC; PICTON, 2002), sendo quatro para cada orelha. As portadoras dos estímulos consistem de tons de 500, 1000, 2000 e 4000 Hz, com moduladoras de 81, 85, 89 e 93 Hz para a orelha direita e 83, 87, 91 e 95 para a orelha direita. Cada voluntário foi submetido a uma sessão com os estímulos apresentados em 70 dB e a uma sessão sem estimulação para obter EEG espontâneo.

Para a aquisição do EEG foi utilizado um eletroencefalógrafo construído no NIAS (SOARES; FELIX, 2019). Neste eletroencefalógrafo os eletrodos são conectados a um analog front-end (RHA2216, Intan Technologies) e o sinal é digitalizado por um conversor analógico-digital (ADS127L01, Texas Instruments). São utilizados filtros passa-altas de 0,5 Hz e passa-baixas de 300 Hz. Para 7 voluntários a frequência de amostragem foi de 1000 Hz por canal e para os demais voluntários foi utilizado 1750 Hz por canal, sendo que os sinais coletados a 1750 Hz foram reamostrados para 1000 Hz. As aquisições foram realizadas com 16 eletrodos, com referência na nuca e terra no FP_z.

Para os propósitos da validação por meio da taxa de detecção da ASSR, foram utilizados apenas os eletrodos C_Z , FC_Z e F_Z , por serem os canais que apresentaram melhores desempenhos com os ORDs existentes. Cada combinação de indivíduo, eletrodo e frequência moduladora serão tratadas como um sinal distinto, resultando em um total de 264 sinais nos quais serão aplicados os detectores.

Para validar a taxa de FP dos detectores serão utilizados os sinais de EEG espontâneos. Neste caso foram utilizados todos os bins para as frequências inteiras entre 80 Hz e 99 Hz para cada indivíduo e todos os 16 canais, resultando em um total de 3520 sinais nos quais serão aplicados os detectores. Para o cálculo da taxa de FP é possível utilizar todos os canais e bins de frequências que não foram utilizadas para o cálculo da taxa de detecção, pois o objetivo desta análise é verificar a probabilidade de o detector detectar uma resposta para um sinal que definitivamente não a possui.

2.5.2 Métricas de validação

Na validação foram calculados dois indicadores para os dados reais: taxa de FP e taxa de detecção. Estas métricas foram utilizadas como critérios eliminatório e classificatório,

respectivamente. Todos os ORDs que foram avaliados para determinar o melhor ORD para os dados simulados, ou seja, os 1000 melhores indivíduos para cada execução da PG emulada e os indivíduos da última geração de cada execução da PG não emulada, também foram validados com dados reais. É desejável que os melhores ORDs para os dados simulados e para os dados reais sejam os mesmos, porém esse fato não é garantido, já que a simulação de Monte Carlo utilizada é uma simplificação que não aborda todas as características do sinal real. Com isso é esperado que haja uma divergência entre os melhores ORDs na validação e na simulação.

Os indicadores de FP e taxa de detecção foram calculados para 30 e 60 janelas de sinal, de modo a verificar se a eficiência na detecção do ORD é mantida quando o número de janelas avaliado não é o mesmo para o qual ele foi evoluído.

Na validação foram determinados os melhores ORDs encontrados para os dados reais em cada configuração de restrição aplicada à PG emulada e o melhor ORD encontrado dentre todas as execuções da PG não emulada. Para tal, inicialmente foram descartados todos os ORDs que apresentaram taxas de FP médio, entre a análise com 30 e 60 janelas, acima de 7% e abaixo de 3%. Dentre os restantes, foi apurado aquele que apresentou maior taxa de detecção média. A validação também foi aplicada à MSC, para efeito de comparação dos ORDs encontrados com as originais. O critério de FP foi definido devido ao fato de que, de acordo com as suposições de que ruído do EEG é gaussiano e ergódico, é esperado que hajam detecções de resposta em sinais que definitivamente não as contém. Essas falsas detecções são os FP, os quais devem ocorrer em uma taxa igual ao nível de significância adotado, que neste trabalho foi de 5%. O intervalo entre 3% e 7% é o intervalo de confiança de tal valor devido ao número de sinais utilizados para o calcular.

3 Resultados e Discussão

3.1 Desempenho da PG Emulada

Para uma complexidade mínima baixa (ou seja, menor número de níveis compostos estritamente por operadores matemáticos), como ocorre nas configurações I e V, observa-se uma convergência rápida e capaz de ocorrer dentro das 100 primeiras gerações. Essa convergência é mostrada na Figura 9, onde é possível notar que o valor do *fitness* médio diminui até a geração 40 e depois mantém praticamente constante, sendo que a cada 8 gerações ocorre um distúrbio nos valores de *fitness* devido à renovação dos sinais simulados, o que resulta em uma variância do *fitness* mesmo depois da convergência e também impossibilita que a convergência ocorra com valor de *fitness* próximo do melhor *fitness*.



Figura 9 – *fitness* ao longo da primeira execução da configuração I.

Quando a complexidade aumenta a convergência demora mais tempo para ocorrer, e pode inclusive não ocorrer nas primeiras 100 gerações, como é o caso da segunda execução da configuração VII exibida na Figura 10. Essa não convergência está associada com a criação da população inicial e com o cruzamento dos indivíduos que, por serem aleatórios, terão maior probabilidade de gerar indivíduos inúteis quando a complexidade mínima é aumentada. Os indivíduos inúteis são aqueles que, em algum ponto da árvore geradora principal, possuem uma combinação de funções que resulta em uma distribuição estatística para a qual o valor crítico seja sempre maior que o valor obtido quando o sinal possui resposta. Para a população inicial, de 200 indivíduos, a configuração I apresentou 17 indivíduos inúteis enquanto a configuração IV apresentou 86, observando todos os indivíduos gerados durante a execução do algoritmo, a configuração I apresentou 2,75% de indivíduos inúteis enquanto a configuração V apresentou 30%. O total de indivíduos inúteis decai com as gerações, já que estes apresentam o pior *fitness* possível, porém a uma taxa menor quando a complexidade é aumentada.



Figura 10 – *fitness* ao longo da segunda execução da configuração VII.

As curvas PD dos cinco melhores ORDs encontrados dentre todas as execuções da PG emulada são mostradas na Figura 11 (sendo que suas curvas PD estão sobrepostas, devido à escala do gráfico), junto à curva da MSC, para comparação. Os subíndices ae b referem à cada uma das duas execuções de cada configuração. Os cinco detectores aqui exibidos apresentaram desempenho quase idêntico quando comparados à diferença de desempenho em relação à MSC e entre os ORDs originais. É possível notar que a PD dos detectores obtidos através do AE proposto é ligeiramente superior à PD da MSC. A curva PD, estimada com 10 mil sinais simulados, do melhor ORD encontrado é estatisticamente diferente da MSC de acordo com o teste T pareado (p-valor menor que 0,05).

A Figura 12 exibe uma comparação entre as curvas PD dos detectores obtidos e da MSC através do teste de Tukey. As linhas representam o intervalo de confiança a



Figura 11 – PD dos melhores detectores encontrados. A PD da MSC também é mostrada em linha pontilhada para possibilitar a comparação.

um nível de significância de 5% e o marcador circular indica a média da PD de cada um dos detectores comparados. Quanto maior a média melhor o desempenho, porém não é possível afirmar que existe diferença estatística entre detectores que tenham intervalos de confiança que se sobreponham. Portanto, os detectores encontrados possuem desempenhos estatisticamente diferentes e melhores que a MSC e não existe diferença estatística entre os cinco melhores detectores.



Figura 12 – Teste Tukey entre as curvas PD dos melhores detectores encontrados e da MSC, evidenciando a diferença estatística dos novos detectores em relação à MSC e à falta de diferença estatística entre os novos detectores.

A Tabela 3 mostra o incremento da área abaixo da curva PD, em relação à curva da MSC, para todos os melhores detectores encontrados em cada execução das configurações listadas na Tabela 2. O melhor resultado encontrado, segundo o critério de maior incremento na área abaixo da curva PD, foi encontrado para a configuração I na primeira execução, com incremento de 3,57%. É importante salientar que, apesar deste critério definir a execução I.a como a melhor, não existe diferença estatística entre esta execução e as execuções I.b, III.a, III.b, V.a, V.b e VI.a, como pode ser visto no teste Tukey entre a curva PD para todos os detectores encontrados nas execuções, exibido na Figura 13.

Configuração	Execução A	Execução B
Ι	$3{,}57\%$	$3{,}35\%$
II	$1,\!38\%$	$2,\!26\%$
III	$3,\!26\%$	$2,\!87\%$
IV	2,75%	$2,\!87\%$
V	3,40%	$3{,}33\%$
VI	3,00%	$2,\!07\%$
VII	$2,\!60\%$	$2,\!46\%$

Tabela 3 – Incremento na área abaixo da curva PD dos detectores resultante de cada configuração, quando comparados à MSC.

A Figura 14 mostra a diferença entre as curvas PD do melhor detector encontrado em relação à MSC. Embora a simulação tenha utilizado sinais com distribuição de SNR centrada em -15 dB, os maiores incrementos foram encontrados para as SNR entre -10 e -8 dB. Deste modo fica evidenciado que a técnica adotada não apresentou falseamento devido à distribuição de SNR utilizada nos sinais simulados.

Na Figura 14 também é possível notar que os maiores incrementos ocorreram na região com maiores gradientes, ou seja, próximo ao ponto de inflexão das curvas PD da MSC e do melhor detector. Este fato está atrelado com a imagem da função que é definida pela PD, a qual idealmente é $[\alpha, 1]$, deste modo não é possível obter grandes incrementos na região próxima a PD = 1. Na região próxima a $PD = \alpha$ qualquer incremento obtido ainda fornecerá uma PD próxima ao valor de PD da MSC, que é o próprio α , logo o incremento obtido não é tão grande quanto a região de maiores gradiente para os detectores.

3.2 Desempenho da PG não Emulada

Por não possuir mudança no conjunto de sinais utilizados para o cálculo do *fitness*, esta estratégia de PG mostrou uma convergência mais comportada, se comparada à PG emulada. As Figuras 15 e 16 mostram o comportamento médio da população de indivíduos ao longo das gerações e o comportamento do melhor indivíduo, quanto ao número de nós e a profundidade da árvore geradora do indivíduo e quanto ao *fitness*. Na Figura 15 ocorre uma convergência para o *fitness* do melhor indivíduo, já na Figura 16 existe uma tendência,



Figura 13 – Teste Tukey entre as curvas PD de todos os melhores detectores encontrados na PG emulada, evidenciando que não foram encontradas diferenças estatísticas entre os sete melhores detectores.

porém seriam necessárias mais gerações para confirmar a convergência. Apesar de nesta PG ocorrerem casos de convergência para o *fitness* do melhor indivíduo, sendo que a PG emulada às convergências observadas não ficaram próximas ao *fitness* do melhor indivíduo, é importante notar que foram utilizadas 500 gerações, em comparação com 100 na PG emulada. Deste modo é possível especular que a PG emulada também poderia convergir para o melhor *fitness* se o limite máximo de gerações fosse maior.

Quanto ao comportamento da profundidade, é possível notar que a mesma tem uma tendência de ser alta, próximo ao limite de 10 níveis, porém o número de nós utilizados está longe do limite máximo admitido para os 10 níveis (uma árvore completa com n níveis conterá $2^n - 1$ nós, para o limite de 10 níveis tem-se um máximo de 1023 nós). Isto indica que as árvores geradoras são esparsas, contendo ramos que atingem grandes profundidades e ramos com baixa profundidade. Caso este comportamento seja seguido pela PG emulada, haveria um grande número de genes não utilizados, mas que continuariam a fazer parte do DNA dos indivíduos, podendo serem utilizados nas gerações seguintes. Tal efeito não foi estudado e estudos futuros podem avaliar se a existência de muitos genes não utilizados traz benefícios ou não à evolução dos detectores na PG emulada.



Figura 14 – Incremento na probabilidade de detecção do melhor detector comparado à MSC.



Figura 15 – Número de nós e profundidade da árvore e *fitness* ao longo da primeira execução da PG não emulada.

Para a PG não emulada foi determinado apenas um melhor ORD, visto que não foram avaliadas mais de uma configuração de restrições. A Figura 17 mostra a curva PD para este melhor detector. Nesta curva não foi necessário dar destaque apenas na região



Figura 16 – Número de nós e profundidade da árvore e *fitness* ao longo da nona execução da PG não emulada.

analisada para o cálculo do incremento na PD, pois o incremento é muito maior do que os alcançados para a PG emulada. Este ORD apresentou um incremento de 24,68% na área abaixo da curva PD na região para a qual a MSC apresenta PD entre 10% e 95% (de -19 a -6 dB). Utilizando o teste T pareado, foi encontrado que as curvas são estatisticamente diferentes, com p-valor igual a $2,5 \times 10^{-22}$.

Apesar do grande incremento na probabilidade de detecção, estudos futuros serão necessários para avaliar a falta de suavidade da curva PD, visto que foi estimada com o mesmo número de sinais que a curva da PD e dos ORDs encontrados na PG emulada.

3.3 Função Otimizada

A seguir são listadas as cinco funções que obtiveram os melhores desempenhos na PG emulada e a função que obteve o melhor desempenho na PG não emulada. As funções estão simplificadas, porém em função das funções utilizadas durante o algoritmo genético. O subscrito num e den se referem, respectivamente ao numerador e ao denominador da função. CSM_{sen} e CSM_{cos} são, respectivamente, as somas dos senos e dos cossenos presentes na CSM. É interessante de notar que o numerador do TFL aparece consistentemente em todos os cinco melhores detectores encontrados para a PG emulada. Para a PG não emulada a função resultante é grande e combina diversas funções que foram utilizadas como genes da PG, com destaque especial para para TFL e CSM.



Figura 17 – PD do melhor detector encontrado na PG não emulada. A PD da MSC também é mostrada em linha pontilhada para possibilitar a comparação.

Tabela 4 – Equações para os melhores detectores encontrados em dados simulados.

Execução	ão Função			
I.a	$f(y) = -2,75TFL + 4,75TFL_{num}$			
I.b	$f(y) = 6,48TFL_{num} + 3,24TFL_{den}$			
III.a	$f(y) = -409,08CSM - 660,44TFL_{num} + 2951,92MSC_{num} - ((8,64CSM_{sen} + 193,06TFG) \times (-42,7MSC + 14TFL))$			
V.a	$f(y) = 40,32TFL_{num} - 410,13TFL - 111,32MSC$			
V.b	$f(y) = 12, 18TFL_{num} - 6, 09TFG$			
PG não emulada	$\begin{split} f(y) &= 1,48e8 \times TFL - 3,46E6 \times CSM + 1,89e7 \times TFL_{den} + 14,32 \times TFL_{den}^2 + 0,10 \times (1,43e8 \times CSM + 1,89e7 \times TFL) \times (4,91e4 \times CSM + 1,83e5 \times TFG) \times (1,77e2 \times MSC + 4,02e2 \times TFG) + 2,67e5 \times CSM_{cos} \times TFL_{den}^3 \times (4,86 \times CSM_{cos} - 3,67e7 \times TFL_{den} + 3,89e7 \times TFL_{num} + 1,73e5 \times CSM_h \times (5,34e10 \times CSM_{cos} + 2,15e10 \times TFL - 4,85e12 \times TFL_{den})) \end{split}$			

Estudos futuros podem abordar simplificação dos resultados obtidos, otimizando a função ao remover os nós que menos contribuem para o desempenho dos detectores.

3.4 Validação

Para os resultados obtidos com a PG emulada, nenhum dos melhores detectores para os dados simulados atingiram o critério de FP. De todo o universo de análise, 1000 detectores para cada uma das 14 execuções, apenas 595 passaram pelo critério de FP. Destes apenas 221 tiveram uma taxa de detecção superior à taxa de detecção da MSC.

Para os resultados obtidos com a PG não emulada, o melhor detector encontrado para os dados simulados também não passou pelo critério de FP. De todo o universo de análise, 2000 detectores, apenas 25 passaram pelo critério de FP e apenas um apresentou desempenho superior à MSC. A tabela 5 exibe o desempenho dos melhores detectores encontrados na validação. A equação 3.1 exibe a função do melhor detector encontrado para a PG emulada e a equação 3.2 exibe a função encontrada com a PG não emulada.

Tabela 5 – Melhores detectores encontrados para a validação com dados reais e suas respectivas métricas (a taxa de detecção é referenciada por VP, sendo apresentada para 30 e 60 janelas e seu valor médio).

Detector	FP Médio	VP 30	VP 60	VP Médio	Incremento Médio VP
MSC	2,8%	$30,\!3\%$	43,9%	37,1%	
PG emulada	$6{,}6\%$	42,8%	$57,\!5\%$	50,2%	13,1%
PG não emulada	$3{,}0\%$	33,0%	42,1%	37,5%	0,4%

$$f(y) = 23, 13 \times CSM_s \times TFL \times (15, 62 \times CSM_h - 4464, 57 \times CSM_c \times TFG^{3/10} \times (3, 8 \times MSC + 0, 14 \times TFL_n - 3, 78)) \times (3, 2 \times CSM_s \times (4, 79 \times TFG_n - 5, 44) + 20, 88 \times CSM_h \times MSC_d) - \frac{222, 45 \times CSM_c \times (1, 45 \times CSM_c)^{1,9}}{(6, 6 \times MSC_n - 4, 06 \times MSC \times TFG_d)^{0,8}}$$
(3.1)
$$- \frac{632, 9 \times MSC_n \times TFG \times TFG_d$$

$$f(y) = -142, 8 \times MSC \times (8,02e14 \times TFL \times CSM^2 + 2,68e4 \times TFL_d)$$
(3.2)

Enquanto o ORD encontrado com a PG não emulada obteve um desempenho melhor para os dados simulados, o desempenho do melhor ORD na validação obteve um desempenho praticamente igual ao da MSC. Já o melhor detector encontrado na PG emulada para os dados de validação obteve um desempenho consideravelmente superior à MSC, enquanto o desempenho do melhor ORD para os dados simulados teve desempenho inferior ao do ORD encontrado com a PG não emulada. Tal característica pode estar relacionada com a convergência das PGs. A PG não emulada convergiu para detectores otimizados para dados simulados, já a PG emulada não convergiu completamente, deste modo existiam ORDs não otimizados para os sinais simulados, abrindo uma margem para os mesmos estarem mais otimizados para os dados reais.

Estudos futuros devem ser realizados para avaliar essa diferença entre os resultados para as simulações e para os dados de validação. Tais estudos podem avaliar outras técnicas de geração de sinais simulados, de modo a obter uma representação mais fidedigna ao sinal de EEG real na presença de ASSR.

4 Conclusões

Com a estratégia proposta de emular PG por meio de AG foi possível encontrar novos ORDs com taxas de detecção superiores às da MSC tanto em dados simulados quanto em dados reais para validação, apresentando 3,57% de incremento na área abaixo da curva PD e 13,1% de incremento na taxa de detecção da ASSR durante o protocolo de audiometria. Contudo esta estratégia não apresentou desempenho satisfatório quanto à convergência para o limite de gerações analisadas, sendo necessários estudos futuros para analisar a convergência em um número maior de gerações.

A PG aplicada em sua forma original, sem utilizar de AG para a emular, apresentou características de convergência dentro do limite de gerações estabelecidas, obtendo uma ORD com uma área abaixo da curva PD 24,68% superior à MSC, porém o melhor ORD encontrado na validação apresentou apenas 0,4% a mais de taxa de detecção. Este foi um AE que resultou em ORDs com melhores desempenhos para dados com as mesmas características dos dados que foram utilizados para o cálculo do *fitness*. Logo é esperado que ORDs com bons desempenhos para dados de EEG reais sejam encontrados ao utilizar simulações mais fidedignas às características dos sinais de EEG para o cálculo do *fitness*.

Apesar deste ser um dos primeiros estudos realizados no campo da geração de detectores de forma automática, as técnicas aqui abordadas foram capazes de encontrar detectores com desempenhos superiores à MSC, melhor detector univariado original, tanto em dados simulados como em dados reais.

Os resultados aqui apresentados abrem caminho para estudos futuros que podem realizar abordagens diferenciadas baseadas nas técnicas aqui apresentadas.

5 Trabalhos Futuros

Este trabalho possui diversas possibilidades de trabalhos futuros. A pesquisa na criação de detectores automáticos possui pelo menos três áreas de investigação: técnicas de geração dos sinais simulados, métodos de cálculos de *fitness* e algoritmos evolutivos utilizados.

Este trabalho analisou apenas duas técnicas evolutivas, utilizando apenas uma configuração de operadores genéticos para cada. Próximos estudos podem investigar outros algoritmos evolutivos, bem como outras configurações de operadores genéticos. Também seria possível realizar análises com outros detectores utilizados como base para a recombinação.

Quanto às técnicas de geração de sinais simulados, é possível investigar o uso de sinais com características mais próximas dos EGGs reais. Técnicas como *bootstraping* e *surrogate* podem ser adotadas para gerar tais sinais. Outra possibilidade é a substituição do uso de sinais simulados por bancos de dados de EEGs reais suficientemente grandes.

O fitness adotado neste trabalho é muito simples, tratando-se apenas da probabilidade de detecção em um conjunto de sinais, visto que não é necessário verificar a taxa de FP neste conjunto, pois o mesmo é fixado ao realizar o cálculo do limiar de detecção. *Fitness* mais complexos devem ser adotados caso sejam utilizados dados reais, visto que será necessário validar a taxa de FP. Mesmo ao utilizar sinais simulados é possível explorar outros indicadores de qualidade do detector, como o incremento na área abaixo da curva PD. Também é possível mesclar indicadores de dados simulados e dados reais, como por exemplo utilizar a taxa de detecção em sinais simulados e descontar a taxa de FP que exceda os limites estabelecidos.

Após a realização destes estudos futuros, a continuidade natural da linha de pesquisa é extrapolar a técnica para a criação de técnicas ORD multivariadas.

Referências

AMASIFEN, J. C. C.; ROMERO, R.; MANTOVANI, J. R. S. Algoritmos evolutivos dedicados à reconfiguração de redes radiais de distribuição sob demandas fixas e variáveis - Estudo dos operadores genéticos e parâmetros de controle. *Revista Controle & Automação*, v. 16, n. 3, 2005. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592005000300004&lng=pt&tlng=pt>.. Citado na página 15.

BARCELLOS, J. C. H. de. Algoritmos genéticos adaptativos: Um estudo comparativo. Tese (Dissertação) — Universidade de São Paulo, 2000. Disponível em: http://stoa.usp.br/algoritmos/files/2349/13122/Tag.PDF. Citado na página 20.

BRONZINO, J. D. *Medical Devices and Systems.* 3. ed. [S.l.]: CRC Press, 2006. ISBN 9780849321221. Citado na página 13.

CAGY, M. Monitorização do Plano Anestésico Usando o Potencial Evocado Auditivo de Média Latência: Técnicas no Domínio do Tempo e Coerência Espectral. Tese (Tese) — Universidade Federal do Rio de Janeiro, 2003. Citado na página 13.

CREELMAN, C. D. Signal Detection Theory, History of. In: International Encyclopedia of the Social & Behavioral Sciences. Second edi. Elsevier, 2015. v. 21, p. 952–956. ISBN 9780080970875. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/ B9780080970868430916>. Citado na página 13.

CRUCCU, G. et al. Recommendations for the clinical use of somatosensory-evoked potentials. *Clinical Neurophysiology*, v. 119, n. 8, p. 1705 – 1719, 2008. ISSN 1388-2457. Disponível em: http://www.sciencedirect.com/science/article/pii/S1388245708002046. Citado na página 13.

DARWIN, C. R. On The Origin of Species by Means of Natural Selection, or Preservation of Favoured Races in the Struggle for Life. 1. ed. London: John Murray, 1859. ISSN 03615235. ISBN 0361-5235. Disponível em: http://darwin-online.org.uk/converted/pdf/1859_Origin_F373.pdf>. Citado na página 20.

DHIFLI, W.; KARABADJI, N. E. I.; ELATI, M. Evolutionary mining of skyline clusters of attributed graph data. *Information Sciences*, Elsevier Inc., n. xxxx, 2018. ISSN 00200255. Disponível em: https://doi.org/10.1016/j.ins.2018.09.053. Citado na página 15.

DOBIE, R. A.; WILSON, M. J. Analysis of Auditory Evoked Potentials by Magnitude-Squared Coherence. *Ear and Hearing*, v. 10, n. 1, p. 2–13, feb 1989. ISSN 0196-0202. Disponível em: https://insights.ovid.com/crossref?an=00003446-198902000-00002. Citado na página 19.

DOBIE, R. A.; WILSON, M. J. Objective response detection in the frequency domain. *Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section*, v. 88, n. 6, p. 516–524, nov 1993. ISSN 01685597. Disponível em: http://linkinghub.elsevier.com/retrieve/pii/016855979390040V>. Citado 2 vezes nas páginas 13 e 18.

DOLPHIN, W. F.; MOUNTAIN, D. C. The envelope following response: Scalp potentials elicited in the mongolian gerbil using sinusoidally AM acoustic signals. *Hearing Research*, v. 58, n. 1, p. 70–78, 1992. ISSN 03785955. Citado na página 15.

ELOI, B. F. d. S.; ANTUNES, F.; FELIX, L. B. Improving the detection of auditory steady-state responses near 80 Hz using multiple magnitude-squared coherence and multichannel electroencephalogram. *Biomedical Signal Processing and Control*, Elsevier Ltd, v. 42, p. 158–161, 2018. ISSN 17468108. Disponível em: <<u>https://doi.org/10.1016/j.bspc.2018.01.017></u>. Citado 2 vezes nas páginas 13 e 15.

FELIX, L. B. et al. A spatial approach of magnitude-squared coherence applied to selective attention detection. *Journal of Neuroscience Methods*, Elsevier B.V., v. 229, p. 28–32, 2014. ISSN 1872678X. Disponível em: http://dx.doi.org/10.1016/j.jneumeth.2014.03.014. Citado na página 14.

FELIX, L. B. et al. Multivariate approach for estimating the local spectral F-test and its application to the EEG during photic stimulation. *Computer Methods and Programs in Biomedicine*, Elsevier B.V., v. 162, p. 87–91, 2018. ISSN 18727565. Disponível em: https://doi.org/10.1016/j.cmpb.2018.05.010. Citado na página 29.

FRIDMAN, J. et al. Application of Phase Spectral Analysis for Brain Stem Auditory Evoked Potential Detection in Normal Subjects and Patients with Posterior Fossa Tumors. *International Journal of Audiology*, Taylor & Francis, v. 23, n. 1, p. 99–113, jan 1984. ISSN 1499-2027. Disponível em: https://www.tandfonline.com/doi/abs/10.3109/0020609840907282>. Citado na página 19.

GOLDENHOLZ, D. M. et al. Mapping the signal-to-noise-ratios of cortical sources in magnetoencephalography and electroencephalography. *Human Brain Mapping*, v. 30, n. 4, p. 1077–1086, apr 2009. ISSN 10659471. Disponível em: http://doi.wiley.com/10.1002/hbm.20571. Citado na página 30.

HERNANDEZ-BELTRAN, J. E. et al. Design of estimators for restoration of images degraded by haze using genetic programming. *Swarm and Evolutionary Computation*, Elsevier B.V., v. 44, n. October 2018, p. 49–63, feb 2019. ISSN 22106502. Disponível em: <<u>https://linkinghub.elsevier.com/retrieve/pii/S2210650218301366</u>>. Citado na página 15.

HOLLAND, J. H. Adaptation in natural and artificial systems: an introductory analysis. [S.l.: s.n.], 1975. ISBN 0472084607. Citado na página 21.

JOHN, M. S.; DIMITRIJEVIC, A.; PICTON, T. W. Auditory steady-state responses to exponential modulation envelopes. *Ear and Hearing*, 2002. ISSN 01960202. Citado na página 33.

KEYHANI, K. et al. Analysis of motor and somatosensory evoked potentials during thoracic and thoracoabdominal aortic aneurysm repair. *Journal of Vascular Surgery*, The Society for Vascular Surgery, v. 49, n. 1, p. 36–41, 2009. ISSN 07415214. Disponível em: <<u>http://dx.doi.org/10.1016/j.jvs.2008.08.005></u>. Citado na página 13.

KOZA, J. R. Genetic Programming: On the Programming of Computers by Means of Natural Selection (Complex Adaptive Systems). [S.l.: s.n.], 1992. ISSN 03032647. ISBN 0262111705. Citado na página 25.

KOZA, J. R. Genetic Programming. 1997. Citado na página 25.

KOZA, J. R.; POLI, R. A genetic programming tutorial. *Introductory tutorials in* optimization, search and decision support, Chap, v. 8, 2003. Citado na página 25.

LEE, C. A review of applications of genetic algorithms in operations management. *Engineering Applications of Artificial Intelligence*, Elsevier Ltd, v. 76, n. August, p. 1–12, nov 2018. ISSN 09521976. Disponível em: https://doi.org/10.1016/j.engappai.2018.08. 011>. Citado na página 15.

LOPES, S. Bio: Volume único. 2. ed. São Paulo: Saraiva, 2008. Citado na página 13.

LUTS, H. et al. Objective assessment of frequency-specific hearing thresholds in babies. *International Journal of Pediatric Otorhinolaryngology*, Elsevier, v. 68, n. 7, p. 915–926, jul 2004. ISSN 01655876. Disponível em: https://www.sciencedirect.com/science/article/pii/S0165587604000692. Citado na página 13.

MANTRI, S. et al. A Survey : Fundamental of EEG. International Journal of Advance Research in Computer Science and Management Studies, v. 1, n. 4, p. 83–89, 2013. Citado na página 14.

MELGES, D. B.; SÁ, A. M. F. L. de; INFANTOSI, A. F. C. Frequency-Domain Objective Response Detection Techniques Applied to Evoked Potentials: A Review. In: *Applied Biological Engineering - Principles and Practice*. InTech, 2012. Disponível em: http: //www.intechopen.com/books/applied-biological-engineering-principles-and-practice/ frequency-domain-objective-response-detection-techniques-applied-to-evoked-potentials-a-review>. Citado na página 13.

MONTANA, D. J. Strongly Typed Genetic Programming. *Evolutionary Computation*, v. 3, n. 2, p. 199–230, jun 1995. ISSN 1063-6560. Disponível em: http://www.mitpressjournals.org/doi/10.1162/evco.1995.3.2.199>. Citado na página 25.

PASSARELLA, M. et al. The use of genetic programming to develop a predictor of swash excursion on sandy beaches. *Natural Hazards and Earth System Sciences*, v. 18, n. 2, p. 599–611, feb 2018. ISSN 1684-9981. Disponível em: https://www.nat-hazards-earth-syst-sci.net/18/599/2018/. Citado na página 25.

PELTOKANGAS, R.; SORSA, A. Real-coded genetic algorithms and nonlinear parameter identification. [S.I.], 2008. Citado na página 24.

PENNY, W. D. Multiple Time Series. In: *Signal Processing*. [s.n.], 2009. cap. 7, p. 87–98. Disponível em: http://www.fil.ion.ucl.ac.uk/~wpenny/course/array.pdf>. Citado na página 19.

PICTON, T. W. et al. Estimating Audiometric Thresholds Using Auditory Steady-State Responses. *Journal of the American Academy of Audiology*, v. 16, n. 3, p. 140–156, 2008. ISSN 10500545. Citado 3 vezes nas páginas 8, 17 e 18.

POLI, R. et al. A Field Guide to Genetic Programming. [S.l.: s.n.], 2008. ISBN 978-1-4092-0073-4. Citado na página 25.

RAM, K. R.; LAL, S. P.; AHMED, M. R. Design and optimization of airfoils and a 20 kW wind turbine using multi-objective genetic algorithm and HARP_Opt code. *Renewable Energy*, p. 1–12, aug 2018. ISSN 09601481. Disponível em: <<u>https://linkinghub.elsevier.com/retrieve/pii/S096014811830990X</u>>. Citado na página 15.

SAGARTZAZU, X.; SCHUHMACHER, A.; ISASA, I. Multiple coherence method in time domain for the analysis of the transmission paths of noise and vibrations with non stationary signals. *Isma*, p. 3927–3942, 2010. Disponível em: https: //www.isma-isaac.be/past/conf/isma2010/proceedings/papers/isma2010_0289.pdf>. Citado na página 19.

SHAFFER, C. A. Data Structures and Algorithm Analysis in Java. 3. ed. Dover Publications, 2013. ISBN 978-0486485812. Disponível em: ">h

SHUMWAY, R. Applied statistical time series analysis. 1. ed. Prentice-Hall, 1988. ISBN 9780130415004. Disponível em: <a href="https://books.google.com.br/books?id="https://books.google

SOARES, Q. B.; FELIX, L. B. Instrumentação do EEG usando o RHA2216. In: *Anais do Simpósio de Integração Acadêmica*. Viçosa: Universidade Federal de Viçosa, 2019. Citado na página 33.

SOUZA, G. P. K. de. Otimização de funções reais multidimensionais utilizando algoritmo genético contínuo. Tese (Monografia) — Universidade Federal de Santa Catarina, 2014. Citado na página 22.

SUBHA, D. P. et al. EEG Signal Analysis: A Survey. *Journal of Medical Systems*, v. 34, n. 2, p. 195–212, apr 2010. ISSN 0148-5598. Disponível em: <<u>http://link.springer.com/10.1007/s10916-008-9231-z--></u>. Citado na página 14.

TANNUS, A. M.; TIERRA-CRIOLLO, C. J.; MELGES, D. B. Objective detection of Steady State Visual Evoked Responses for different lighting conditions. *Journal of Physics: Conference Series*, v. 477, n. 1, 2013. ISSN 17426596. Citado na página 13.

VIKHAR, P. A. Evolutionary algorithms: A critical review and its future prospects. Proceedings - International Conference on Global Trends in Signal Processing, Information Computing and Communication, ICGTSPICC 2016, IEEE, p. 261–265, 2017. Citado na página 15.

WILSON, G.; BANZHAF, W. A Comparison of Cartesian Genetic Programming and Linear Genetic Programming. In: Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). [s.n.], 2008. v. 4971 LNCS, p. 182–193. ISBN 3540786708. Disponível em: <http://link.springer.com/10.1007/978-3-540-78671-9_16>. Citado na página 25.