

# Classificação Automática de Modulações utilizando Redes Neurais Artificiais com Regularização Bayesiana e Algoritmo de Retropropagação de Levenberg-Marquardt

Myke D. M. Valadão<sup>1</sup>, Antonio M. C. Pereira<sup>1</sup>, Diego A. Amoedo<sup>2</sup>, Eddie B. L. Filho<sup>1</sup>,  
Celso B. Carvalho<sup>1</sup>, André L. A. da Costa<sup>3</sup>, Lucas C. Cordeiro<sup>1,4</sup>, Waldir S. S. Júnior<sup>1</sup>

<sup>1</sup>Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas (PPGEE/UFAM), Manaus-AM

<sup>2</sup>Agência Nacional de Telecomunicações (ANATEL), Manaus-AM

<sup>3</sup>Universidade Federal de Uberlândia (FEELT/UFU), Uberlândia-MG

<sup>4</sup>University of Manchester, Manchester-UK

**Resumo**—Com o aumento da demanda por espectro de frequência, foi necessário buscar maneiras mais eficientes de alocar usuários no espectro. O rádio cognitivo sensoria o espectro e aloca dinamicamente usuários em espaços inutilizados. As técnicas de classificação automática de modulação vieram para fornecer informações que auxiliam no sensoriamento do espectro. Neste trabalho, foram extraídas características de sinais modulados em banda passante em diferentes SNR (do inglês *signal noise ratio*). O classificador utilizado foi uma rede *perceptron* com Regularização Bayesiana (RB) e algoritmo de retropropagação de Levenberg-Marquardt (LM). Para o método proposto, obteve-se acurácias que variam de 74,8% a 95,5%.

**Palavras-Chave**—Classificação Automática de Modulação, Redes Neurais Artificiais, Rádio Cognitivo.

**Abstract**—With the increase in demand for frequency spectrum, it was necessary to search for more efficient ways to allocate users in the spectrum. The cognitive radio senses the spectrum and dynamically allocates users in unused spaces. The techniques for automatic classification of modulation have come to provide information that assist in spectrum sensing. For this work, characteristics were extracted from signals modulated in passband in different SNR. The classifier used was a *perceptron* network with Bayesian regularization and Levenberg-Marquardt backpropagation algorithm. For the proposed method, obtained accuracy that varies from 74.8% to 95.5%.

**Keywords**—Automatic Modulation Classification, Artificial Neural Network, Cognitive Radio.

Myke D. M. Valadão, Antônio M. C. Pereira, Eddie B. L. Filho, Celso B. Carvalho, Lucas C. Cordeiro e Waldir S. S. Júnior, Pós-Graduação em Engenharia Elétrica, Universidade Federal do Amazonas (PPGEE/UFAM), Lucas Carvalho Cordeiro, University of Manchester, Manchester-UK, André L. A. da Costa, Universidade Federal de Uberlândia (UFU), Uberlândia-MG, Diego A. Amoedo, Agência Nacional de Telecomunicações (ANATEL), Manaus-AM. E-mails: myke.medeiros@gmail.com, antonio.tech@yahoo.com, diegoalves@anatel.gov.br, eddie.filho@tpv-tech.com, andre-aguiar@mtel.inatel.br, lucas.cordeiro@manchester.ac.uk, ccarvalho@ufam.edu.br, waldirsabino@gmail.com. Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Esta pesquisa foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº 8.387 / 91, através de convênio firmado com o CETELI/UFAM.

## I. INTRODUÇÃO

Com popularização dos dispositivos e serviços de comunicação remota a demanda por espectro de frequência vem aumentando drasticamente, porém, esse recurso natural é finito e sua política de distribuição tornou-se ineficiente [1]. Parte desta ineficiência é causada pela política de distribuição sugerida pela UIT (União Internacional de Telecomunicações) [1]. Entretanto, esta subutilização de espectro é sanada com a utilização do rádio cognitivo [2]. O rádio cognitivo aplica técnicas de sensoriamento para mapear o espectro de frequência, e identificar espaços inutilizados para, então, alocar de maneira dinâmica usuários secundários. A classificação automática de modulações (AMC, do inglês *automatic modulation classification*) foi necessária para fornecer informações a priori e auxiliar no processo de sensoriamento de espectro. Neste método de sensoriamento avalia-se se há ou não presença de usuário primário no canal correlacionando a modulação [2]. A AMC é o processo no qual um conjunto de informações extraída dos sinais modulados é utilizado para treinar um classificador, gerando um modelo utilizado para identificar a modulação do sinal avaliado pelo rádio cognitivo.

O método de extração das informações dos sinais modulados é uma etapa crítica para a AMC, porque impactará diretamente no desempenho do classificador e consequentemente na boa operação do rádio cognitivo. Dentre os métodos mais comuns na literatura encontra-se os baseados em extração de características (FB, do inglês *feature-based*) [1][3], verossimilhança (LB, do inglês *likelihood-based*) [4] e matriz de constelações de grade (CGM, do inglês *grid constellation matrix*) [5][6]. Para esse trabalho foi proposto a extração de 29 características, tais como: características espectrais, por transformada, estatísticas, de teste de distribuição e cicloestacionárias. Os sinais modulados foram gerados em banda base, adicionou-se, também em banda base, ruídos modelados pelos canais AWGN (do inglês *additive white gaussian noise*) e Rayleigh. Em seguida foi aplicado o elevador de frequência (do inglês *upconverter*) e, por fim, amostragem e determinação de envoltória, para, então, que suas características sejam

extraídas.

Dentre os métodos de classificação mais utilizados na literatura atualmente estão as redes neurais artificiais (ANN, do inglês *artificial neural network*) [7], redes neurais convolucionais (CNN, do inglês *convolutional neural network*) [8] [9] e SVM (do inglês *support vector machine*) [1]. O método de classificação proposto neste trabalho é uma ANN com RB e algoritmo de retropropagação (do inglês *backpropagation*) de LM. A ANN é um método de classificação recorrente que tenta simular o funcionamento do cérebro humano. Já a técnica de regularização e algoritmo de retropropagação são utilizados simultaneamente para maximizar o aprendizado da rede e reduzir o erro [10], evitando possíveis problemas com sobreajuste (do inglês *overfitting*). Dentre os métodos de regularização, LM e RB obtiveram ótimos resultados de erro médio quadrático (MSE, do inglês *mean square error*), como visto por [10].

Podemos notar que a AMC utilizando ANN com os métodos de regularização e retropropagação propostos obtiveram bons resultados se comparados com trabalhos similares. Para o trabalho proposto foi alcançado uma acurácia de 95,5% no melhor caso, além da, precisão de aproximadamente 100% na correta classificação das modulações analógicas e por técnica de multiplexação para as SNR abordadas. Em comparação a literatura, em [11], a acurácia em 20db foi de 91% enquanto na metodologia proposta foi de 93,7%. Assim, realizando uma análise entre as metodologias presentes na literatura, pode-se dizer que os métodos, tanto de geração de sinais quanto de classificação de modulação, abordados neste trabalho demonstram relevância para o contexto de sistemas que procuram aumentar a eficiência do espectro de frequência.

#### A. Contribuições do Artigo

As contribuições científicas desta pesquisa são descritas conforme a seguir: primeiramente, utiliza-se um sistema similar ao proposto por [1], para AMC, o qual utiliza sinais corrompidos por ruído modelados por canais AWGN e Rayleigh e modulados em banda base, amostragem em banda passante e formatação de pulso. A contribuição específica proposta neste artigo concentra-se em explorar uma ANN que emprega o algoritmo de retropropagação de LM simultaneamente com a RB que, quando combinados, reduzem o MSE além de evitar o sobreajuste [10]. LM é um algoritmo que busca o mínimo local de uma função mesmo que seu estado inicial seja distante do mínimo. Assim, pode-se considerar que o algoritmo de LM é um bom método de atualização dos pesos pois tende a buscar o mínimo da função erro independente da condição inicial [10][12]. Adicionalmente, a quantidade de sinais utilizados para os experimentos foi consideravelmente ampliada. De fato, neste artigo utiliza-se 47100 sinais modulados para cada modulação em contrapartida aos 400 sinais modulados para cada modulação utilizados em [1]. Foi realizada uma avaliação da ANN com variação do número de camadas ocultas, similar ao estudo realizado por [13].

## II. TRABALHOS RELACIONADOS

Em [9] é proposta uma metodologia de classificação baseada em CNN devido sua aptidão para lidar com sinais multidimensionais, apoiada na sua característica de invariabilidade

espacial. Os autores criaram uma CNN com 4 camadas, com duas camadas convolucionais e duas camadas completamente conectadas para classificar os sinais AM, FM e SSB (do inglês, *amplitude modulation*, *frequency modulation* e *single-sideband modulation*), utilizando a função RELU (do inglês *rectified linear unit*). Foram simulados dois cenários: com e sem extração de características. No primeiro cenário, as taxas de acerto foram de 60 a 62% com SNR de 10 e 16dB. No segundo, as taxas foram de 70 a 72% com as mesmas SNR. Entretanto, neste trabalho, a quantidade de modulações abordadas e a variação de níveis de SNR são pequenas, o que não retrata a pluralidade dos sistemas de comunicação atuais.

No trabalho de [11] é utilizada uma rede neural recorrente (RNN, do inglês *recurrent neural network*). RNN são conhecidas pela capacidade de explorar características das sequências temporais. Foram montados três cenários de experimentação com a utilização de (a) RNN simples e padrão, (b) com memória de curto prazo e (c) uma variante da RNN com memória de curto prazo com menos portas. Foram utilizadas 11 classes de sinais. Os resultados apresentados mostram que a proposta apresentou resultados relevantes, considerando as taxas de acerto de 79, 82 e 87% para os sinais 16-QAM, 64-QAM e QPSK (do inglês, respectivamente, *quadrature amplitude modulation* e *quadrature phase-shift keying*), respectivamente, a 0dB.

Por último, o trabalho de [14] propõe a utilização de redes neurais artificiais ART (do inglês *adaptive resonance theory*), com métricas de dissimilaridade euclidiana e Manhattan sobre os sinais BPSK, 2FSK e 4PSK (do inglês, respectivamente, *binary phase-shift keying*, *frequency-shift keying* e *phase-shift keying*). São criadas 3 redes ART treinadas independentes, com seus respectivos símbolos. Como a técnica seleciona o melhor neurônio pelas métricas de dissimilaridade, a complexidade computacional é bastante reduzida neste trabalho. A taxa de acerto fica em torno de 80% a 0dB. Entretanto, neste trabalho, foi proposto a classificação de somente 3 modulações, além da adição de um só tipo de canal ruidoso (AWGN), o que não retrata com fidelidade um sistema real de transmissão de sinais.

## III. METODOLOGIA PROPOSTA PARA PROJETO DO CLASSIFICADOR UTILIZANDO ANN

### A. Introdução

Normalmente, um sistema de AMC, pertencente a categoria de métodos FB, é descrito por três etapas: geração dos sinais modulados, extração de características e projeto do classificador [1][7][8]. No sistema proposto neste artigo, para a etapa de geração de sinais modulados, utilizou-se as modulações AM, FM, BPSK, QPSK, 16-QAM, 64-QAM, GMSK (do inglês *gaussian minimum shift keying*) e WCDMA (do inglês *wideband code division multiple access*) todas em banda base, adição de ruído (Rayleigh e AWGN) em banda base, amostragem em banda passante e formatação de pulso. Para a etapa de extração de características, considerase características espectrais, estatísticas, por transformada, por teste de distribuição e cicloestacionárias. A Tabela I apresenta uma descrição das características extraídas. Estas duas etapas são similares ao sistema proposto por [1].

TABELA I  
CATEGORIAS E DESCRIÇÃO DAS CARACTERÍSTICAS EXTRAÍDAS PARA O CLASSIFICADOR PROPOSTO.

Características	
Categoria	Descrição
Espectrais	Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada
	Desvio padrão da amplitude instantânea normalizada e centralizada
	Desvio padrão da fase instantânea absoluta não linear centralizada
	Desvio padrão da fase não linear direta centralizada
	Desvio padrão da frequência instantânea normalizada e centralizada
	Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada
Transformada	Valor máximo da transformada discreta de cosseno
	Desvio padrão da transformada de Walsh-Hadamard
	Desvio padrão da transformada de Wavelet discreta
	Valor máximo dos coeficientes ceptrais na frequência mel
Estatísticas	Cumulantes de segunda ordem
	Cumulantes de terceira ordem
	Cumulantes de quarta ordem
Teste de Distribuição	Função de teste Gaussianidade
Cicloestacionárias	Curtose da densidade de correlação espectral
	Desvio padrão da densidade de correlação espectral
	Variância da densidade de correlação espectral
	Cumulantes cíclicas de terceira ordem
	Cumulantes cíclicas de quarta ordem

### B. Projeto do Classificador

Para a etapa de projeto do classificador utiliza-se o método de classificação por ANN com algoritmo de otimização de LM e RB. Esta etapa é descrita da seguinte maneira: na entrada da ANN temos a matriz de características, que contém todos os vetores de características, e a matriz de rótulos, que mapeia o valor a cada classe, denominada *target matrix*. A matriz de características é dividida em matrizes de treinamento (70%) e teste (30%). No processo de treinamento é realizado o somatório dos pesos em cada neurônio da camada conforme a expressão a seguir:

$$x = \sum_{i=1}^N w_i c_i + b \quad (1)$$

sendo  $w_i$  os pesos atribuídos a cada característica de entrada,  $c_i$ , onde  $N$  é o número de características na entrada do neurônio e  $b$  é a constante do neurônio. Na primeira camada da rede neural, aplica-se a função de ativação nas saídas dos correspondentes somatórios de cada neurônio da camada. A função de ativação dos neurônios da primeira camada é a tangente hiperbólica, demonstrada na eq. (2).

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2)$$

As saídas da primeira camada são as entradas da próxima camada, onde o processo de somatório é realizado novamente conforme a eq. (1), e assim por diante, até a camada de saída, onde a quantidade de neurônios é referente ao número de classes. A função de ativação das camadas intermediárias é também a tangente hiperbólica, eq. (2), e a da camada de saída é a *softmax* conforme eq. (3).

$$y = \frac{e^x}{\sum e^x} \quad (3)$$

Com os pesos da ANN calculados ao final da camada de saída, avalia-se os critérios de parada de treinamento, se os

critérios foram atingidos a rede é testada com os dados de teste, e o desempenho é calculado segundo eq. (4).

$$P = \gamma MSW + (1 - \gamma)MSE \quad (4)$$

sendo  $\gamma$  a taxa de regularização, MSW (do inglês *mean square weight*) a média dos quadrados dos pesos,  $\frac{1}{M} \sum_{i=1}^M w_i^2$ , com  $M$  sendo o número de elementos da matriz de pesos, MSE o erro quadrático médio,  $\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2$ , sendo  $N$  o número de elementos da *target matrix* ( $t_i$ ) e previsões ( $y_i$ ). Porém, caso os critérios não sejam atingidos, calcula-se o erro da rede através da eq. (5) e os pesos são atualizados utilizando o princípio de otimização de LM, conforme a eq. (6).

$$E = \frac{1}{N} \sum_{i=1}^N w_i^e (t_i - y_i)^2 \quad (5)$$

$$\Delta x = \frac{-J^T E}{J^T J + \mu I} \quad (6)$$

sendo  $w_i^e$  a matriz de pesos individuais de cada erro quadrático calculada pela distância euclidiana entre os valores esperados e os preditos pela rede,  $\sum_{i=1}^N \sqrt{(t_i - y_i)^2}$ , onde  $t_i$  são os rótulos,  $y_i$  as previsões e  $N$  é o número total de elementos. Na eq. (6),  $J$  é a matriz jacobiana que contém as primeiras derivadas dos erros da rede em relação aos pesos, conforme eq. (7),  $\mu$  é parâmetro de Marquardt e  $I$  é a matriz identidade.

$$J = \begin{pmatrix} \frac{\partial E_1}{\partial w_1^e} & \cdots & \frac{\partial E_1}{\partial w_n^e} \\ \vdots & \ddots & \vdots \\ \frac{\partial E_n}{\partial w_1^e} & \cdots & \frac{\partial E_n}{\partial w_n^e} \end{pmatrix} \quad (7)$$

Com os pesos atualizados o processo de treinamento repete-se até que os critérios de parada de treinamento da rede sejam alcançados.

## IV. PROCEDIMENTO EXPERIMENTAL

### A. Setup

Os algoritmos utilizados neste experimento foram implementados em MATLAB, na versão R2017b, em ambiente

Linux, Ubuntu versão 16.04.4 LTS, processador Intel(R) Core(TM) i7-3770 CPU 3,4GHz e memória RAM de 16GB. O projeto do classificador foi realizado em linguagem MATLAB, utilizando a *toolbox Neural Network*.

### B. Base de Dados

Para este experimento, utiliza-se uma base de dados formada por 47100 sinais modulados para cada uma das modulações AM, FM, BPSK, QPSK, 16-QAM, 64-QAM, GMSK e WCDMA. Dessa forma, a base de dados completa é formada por um total de 376800 sinais modulados. Em cada modulação foram gerados 9420 sinais para cada um dos cinco níveis SNR: 0, 5, 10, 20 e 30dB. Foram extraídas 29 características, descritas na Tabela I, de 1024 amostras de cada sinal.

### C. Parâmetros do classificador

A rede neural foi parametrizada utilizando-se a função *trainbr*, da *toolbox Neural Network* do MATLAB. Na Tabela II, apresenta-se como a ANN foi parametrizada. O processo de treinamento finaliza quando um dos seguintes critérios é atingido: (1) número máximo de épocas; (2) limite do tempo de treinamento; (3) gradiente atinge o mínimo; (4) máximo  $\mu$  é alcançado; ou (5) desempenho são alcançados.

TABELA II  
PARÂMETROS DA RNA PROPOSTA.

Número de características	29
Número de camadas internas	1:1:7
Número de neurônios da camada interna	15
Número de neurônios da camada de saída	8
Função de ativação das camadas internas	Tansig
Função de ativação da camada de saída	Softmax
Número máximo de épocas	200
Desempenho	0
Método de treinamento	Retropropagação por Regularização Bayesiana
Parâmetro de Regularização ( $\gamma$ )	0,5
Função de desempenho	MSE
Parâmetro de Marquardt inicial ( $\mu$ )	$5 \times 10^{-3}$
Fator de decrescimento do parâmetro de Marquardt ( $\mu$ )	$1 \times 10^{-1}$
Fator de crescimento do parâmetro de Marquardt ( $\mu$ )	10
Máximo valor do parâmetro de Marquardt ( $\mu$ )	$1 \times 10^{+10}$
Máximo valor de falhas de validação	$\infty$
Valor mínimo do gradiente de desempenho	$1 \times 10^{-7}$
Limite de tempo de treinamento	$\infty$
Base de dados de treinamento	263760
Base de dados de teste	113040

O número de neurônios das camadas internas foi determinado conforme mostrado em [12]:

$$N_h = \sqrt{N_i N_o} \quad (8)$$

onde  $N_i$  é o número de neurônios da camada de entrada e  $N_o$  o número de neurônios da camada de saída. O parâmetro de regularização ( $\gamma$ ) foi definido com o intuito minimizar o erro e suavizar a resposta do classificador, conforme mostrado por [10]. O número de épocas foi definido em 200 devido a rápida convergência da rede. O número de camadas foi variado para realizar uma avaliação da resposta da rede. Os outros parâmetros foram os *default* do MATLAB.

### D. Métricas Utilizadas

O desempenho da ANN proposta foi determinado pela eq. (4), também é calculado o erro durante o treinamento, com a finalidade de atualização dos pesos, conforme a eq. (5). Outras métricas como acurácia e precisão foram utilizadas e são demonstradas em forma de gráfico e tabela.

### E. Resultados

O gráfico da Fig. 1 mostra a resposta da ANN proposta para diferentes quantidades de camadas internas. Notamos que o melhor desempenho MSE ocorre com 5 camadas internas.

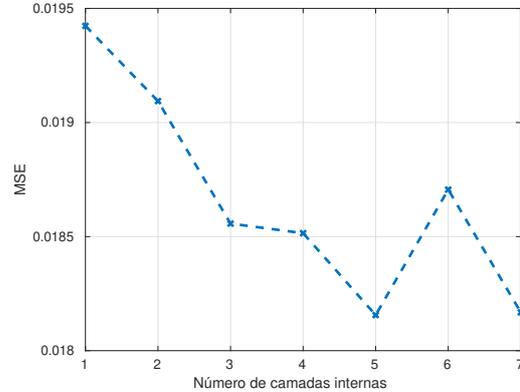


Fig. 1. Desempenho da ANN proposta de acordo com a variação do número de camadas internas.

É necessário mais investigações sobre os motivos da mudança do MSE com o aumento do número de camadas internas conforme visto na Fig. 1. Um possível fator influenciador é a mudança de base de dados no processo de treinamento, já que a divisão de base de treino e teste é feita de maneira aleatória a cada novo treinamento.

Na Fig. 2 é avaliado a acurácia, conforme variação da SNR, da rede que obteve o melhor desempenho MSE.

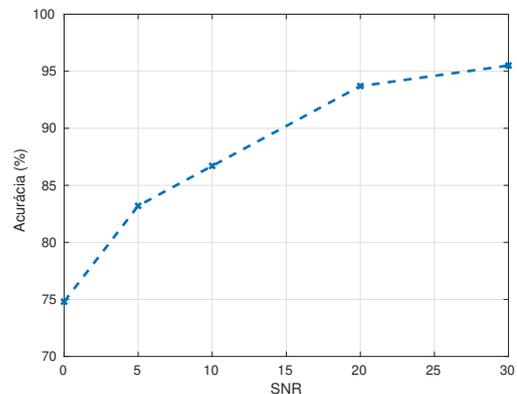


Fig. 2. Acurácia da ANN proposta de acordo com a variação da SNR.

Na Tabela III temos a resposta da rede de acordo com a SNR do sinal avaliado. Notamos que as modulações AM, FM e WCDMA obtiveram aproximadamente 100% de precisão em todos as SNR, o que implica que a presença de ruído não impacta tão fortemente na correta classificação destas modulações. As modulações BPSK e GMSK obtiveram taxas acima de 77% em 0db, o que demonstra que essas modulações sofrem com ação de alto nível de ruído, mas em níveis acima de 5db as taxas de precisão superam 96%. Em contrapartida, as modulações QPSK, 16-QAM e 64-QAM são altamente susceptíveis ao ruído, podemos notar que até 10db as taxas de precisão estão abaixo de 84%. Porém, conforme o gráfico

da Fig. 2, a acurácia da ANN proposta com 5 camadas foi acima de 95% para o maior nível de SNR abordado. Os métodos propostos por [11] e [1] obtiveram taxas de acurácia de 91% e 93,6% em 20db, respectivamente, enquanto no método proposto obteve 93,7% também em 20db.

TABELA III  
PRECISÃO POR SNR DAS MODULAÇÕES CLASSIFICADAS PELA ANN  
PROPOSTA. RESULTADOS EM PERCENTUAL (%).

	0(dB)	5(dB)	10(dB)	20(dB)	30(dB)
AM	100	100	100	100	100
FM	100	100	100	100	100
BPSK	77,6	97,2	99,2	99,3	98,9
QPSK	50,8	71,7	83,6	97,1	98,6
16-QAM	39	52,2	58,8	77,1	80
64-QAM	40,5	49,6	56,6	76,3	87,2
GMSK	83,3	96,6	99,7	99,9	100
WCDMA	100	100	100	99,8	100

## V. CONCLUSÕES

Neste artigo, abordou-se a AMC utilizando-se, na etapa de projeto do classificador, uma ANN com RB e algoritmo de retropropagação de LM. Neste sistema, considerou-se uma comunicação com canal ruidoso (AWGN e Rayleigh), formatador de pulso e amostragem em banda passante. Além disso, utilizou-se uma base de dados com um total de 376800 sinais modulados. Em relação aos resultados experimentais, em geral, percebe-se que o método proposto teve um ganho de acurácia de 91% [11] para 93,7% com um nível de SNR em 20db, em 30db a acurácia da ANN proposta alcançou 95,5%. Vale ressaltar também que os métodos de otimização utilizados retornam resultados significativos, porém, requerem um custo computacional mais elevado se em comparação com outras técnicas de otimização. Como trabalhos futuros, é proposto uma investigação mais profunda do por que as modulações QAM se confundem tanto, além da busca por melhoras nos resultados em SNR mais baixas.

## VI. AGRADECIMENTOS

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Esta pesquisa, conforme previsto no Art. 48 do decreto nº6.008/2006, foi financiada pela Samsung Eletrônica da Amazônia Ltda, nos termos da Lei Federal nº 8.387/1991, através do convênio nº 004, firmado com o CETELI/UFAM.

## REFERÊNCIAS

- [1] Amoedo D. A., Melo W. C., Cordeiro L. C., Filho E. B. L., Silva Júnior W. S., and Carvalho C. B. Classificação automática de modulações mono e multiportadoras utilizando método de extração de características e classificadores SVM. In *Proc. Simp. Brasileiro de Telecom. e Processamento de Sinais SBRT*, pages 393–397, São Pedro, Brazil, 2017.
- [2] Abdelmohsen Ali and Walaa Hamouda. Advances on spectrum sensing for cognitive radio networks: Theory and applications. *IEEE communications surveys & tutorials*, 19(2):1277–1304, 2016.
- [3] Tales VRO Câmara, Arthur DL Lima, Bruno MM Lima, Aluisio IR Fontes, Allan De M Martins, and Luiz FQ Silveira. Automatic modulation classification architectures based on cyclostationary features in impulsive environments. *IEEE Access*, 7:138512–138527, 2019.
- [4] Wenhao Chen, Zhuochen Xie, Lu Ma, Jie Liu, and Xuwen Liang. A faster maximum-likelihood modulation classification in flat fading non-gaussian channels. *IEEE Communications Letters*, 23(3):454–457, 2019.
- [5] Sai Huang, Yizhou Jiang, Yue Gao, Zhiyong Feng, and Ping Zhang. Automatic modulation classification using contrastive fully convolutional network. *IEEE Wireless Communications Letters*, 2019.
- [6] Jung Ho Lee, Kwang-Yul Kim, and Yoan Shin. Feature image-based automatic modulation classification method using cnn algorithm. In *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, pages 1–4. IEEE, 2019.
- [7] Afan Ali, Fan Yangyu, and Shu Liu. Automatic modulation classification of digital modulation signals with stacked autoencoders. *Digital Signal Processing*, 71:108–116, 2017.
- [8] Shengyun Wei, Shun Zou, Feifan Liao, Weimin Lang, and Wenhui Wu. Automatic modulation recognition using neural architecture search. In *Proc. Int. Conf. on High Performance Big Data and Intelligent Systems (HPBD&IS)*, pages 151–156. IEEE, 2019.
- [9] S Athira, Rohit Mohan, Prabaharan Poornachandran, and KP Soman. Automatic modulation classification using convolutional neural network. *IJCTA*, 9(16):7733–7742, 2016.
- [10] Murat Kayri. Predictive abilities of bayesian regularization and levenberg–marquardt algorithms in artificial neural networks: a comparative empirical study on social data. *Mathematical and Computational Applications*, 21(2):20, 2016.
- [11] Dehua Hong, Zilong Zhang, and Xiaodong Xu. Automatic modulation classification using recurrent neural networks. In *Proc. Int. Conf. on Computer and Communications (ICCC)*, pages 695–700. IEEE, 2017.
- [12] Azizah Suliman and Batyrkhan S Omaro. Applying bayesian regularization for acceleration of levenberg-marquardt based neural network training. *IJIMAI*, 5(1):68–72, 2018.
- [13] Satish Saini and Ritu Vijay. Optimization of artificial neural network breast cancer detection system based on image registration techniques. *International Journal of Computer Applications*, 105(14):26–29, 2014.
- [14] Yona Lopes, David L. Acosta, Antonio J.C.R. Coutinho, Fidel E. Souza, Joao M.M. Silva, and José S.G. Panaro. Reconhecimento automático de modulação digital e demodulação de sinais baseado em redes neurais artificiais. In *Proc. Simp. Brasileiro de Telecom. e Processamento de Sinais SBRT*, Brasília, Brazil, 2012.