



# CRICTE 2017

XXVIII Congresso Regional de Iniciação Científica e Tecnológica em Engenharia



## ESTUDO DE ALGORITMOS DE RECONHECIMENTO DE PADRÕES APLICADOS À RECONHECIMENTO DE MODULAÇÕES EM RÁDIO COGNITIVO

**André Luiz de Almeida Camargo**

Acadêmico do curso de Engenharia Elétrica - Universidade Federal do Paraná  
almeida.andre@ufpr.br

**Luis Henrique Assumpção Lolis**

Professor do curso de Engenharia Elétrica - Universidade Federal do Paraná  
luis.lolis@gmail.com

**Resumo.** *Este trabalho apresenta técnicas aplicadas à classificação automática de modulações em um contexto de rádio cognitivo. Este trabalho propõe realizar a classificação automática de modulações aplicando uma rede neural artificial do tipo Multilayer Perceptron. Foi testado o desempenho do algoritmo desenvolvido, em termo da taxa de falso alarme e não-detecção, utilizando o método de AMC baseado em características, para os sinais do tipo 4QAM, 16QAM, 2PSK, 4PSK, 2FSK e 4FSK, e simulados em um canal com ruído branco gaussiano. Os resultados serão obtidos em Probabilidade de Classificação Correta ( $P_{cc}$ ) e de Não-detecção ( $P_{nd}$ ) para Relações Sinal-Ruído entre -20dB e 15dB, observados por meio da matriz de confusão, obtida da simulação no software MATLAB. O algoritmo final conseguiu uma  $P_{cc}$  de 89,8% e  $P_{nd}$  de 0,0%, para testes em um SNR de -20dB.*

**Palavras-chave:** *Classificação automática de modulação. Rádio cognitivo. Redes neurais artificiais.*

### 1. INTRODUÇÃO

A Classificação Automática de Modulação (AMC) é uma área da atuação intermediária entre a detecção e demodulação do sinal em um sistema de rádio cognitivo. O rádio cognitivo surgiu de uma necessidade de realizar um

gerenciamento mais efetivo do espectro de rádiofrequência, devido à crescente onda de tecnologias na área de comunicação sem fio. Com isso, de acordo com Haykin [1] e Mitola [2], o rádio cognitivo tem como objetivo estabelecer uma comunicação com alta confiabilidade, monitorando e também aprendendo com o espectro de frequências. Segundo Wang [3], foram definidas etapas de funcionamento, sendo elas o sensoriamento espectral, gestão do espectro, compartilhamento espectral e mobilidade espectral. A AMC é uma área dentro do sensoriamento espectral, e tem como objetivo realizar o reconhecimento de diferentes modulações analógicas ou digitais, sem a necessidade de operação externa, fazendo o uso de algoritmos inteligentes, como dito por Zhu *et al.* [4]. Como visto no estado da arte de AMC, diversos algoritmos fazem o uso do método de classificação por características, devido à sua baixa complexidade computacional em comparação à outros métodos da área, de acordo com Dobre *et al.* [5] e Hazza *et al.* [6]. Os resultados vistos no estado da arte mostram que as técnicas que mais se destacam fazem o uso de redes neurais artificiais, sendo o melhor resultado obtido por Mendis *et al.* [7] com uma classificação correta de 90% para SNR de -2 db.



## 2. MODELO E CARACTERÍSTICAS DO SINAL

O sinal modulado recebido tem a seguinte forma geral [6]:

$$r(t) = \{\alpha e^{j(2\pi f_c t + \phi(t))} C(t)\} + n(t) \quad (1)$$

onde  $\alpha$  é a amplitude do sinal modulado,  $C(t)$  é o envelope complexo,  $n(t)$  é o ruído branco com distribuição gaussiana,  $f_c$  é a frequência da portadora e  $\phi(t)$  é a fase. Para realizar a extração de características do sinal, é necessário fazer o cálculo dos parâmetros instantâneos pelas seguintes equações:

$$A(n) = |r(n)| \quad (2)$$

$$\phi(n) = \arg(r(n)) - 2\pi f_c t \quad (3)$$

$$f(n) = \frac{1}{2\pi} \frac{d(\phi(n))}{dt} \quad (4)$$

$$A_{cn}(n) = \left( \frac{A(n)}{N} \sum_{n=1}^N A(n) \right) - 1 \quad (5)$$

$$f_N(n) = \frac{\left( f(n) - \frac{1}{N} \sum_{n=1}^N f(n) \right)}{f_s} \quad (6)$$

onde  $A(t)$  é a amplitude instantânea,  $\phi(t)$  é a fase instantânea,  $f$  é a frequência instantânea,  $A_{cn}$  é a amplitude instantânea normalizada e centralizada,  $f_N$  é a frequência instantânea normalizada e centralizada,  $f_s$  é a frequência de amostragem e  $N$  é o número de amostras do sinal. Dessas características iniciais são retiradas as características que serão utilizadas para a classificação. As características escolhidas foram as seguintes [4-7]:

Valor máximo da densidade espectral de potência da amplitude normalizada e centralizada :

$$\gamma_{max} = \max |FFT(A_{cn})|^2 / N \quad (7)$$

onde  $FFT$  é a Transformada Rápida de Fourier.

Desvio padrão do valor absoluto da fase instantânea:

$$\sigma_{ap} = \sqrt{\frac{1}{N_c} \left( \sum_{A_n(n) > A_t} \phi^2(n) \right) - \left( \frac{1}{N_c} \sum_{A_n(n) > A_t} \phi(n) \right)^2} \quad (8)$$

onde  $N_c$  é o número de amostras que atendem à condição  $A_n(n) > A_t$ .  $A_t$  é um valor limite que filtra as amostras de baixa amplitude do sinal devido a sua alta sensibilidade à ruído.

Desvio padrão da fase instantânea direta:

$$\sigma_{dp} = \sqrt{\frac{1}{N_c} \left( \sum_{A_n(n) > A_t} \phi^2(n) \right) - \left( \frac{1}{N_c} \sum_{A_n(n) > A_t} \phi(n) \right)^2} \quad (9)$$

Desvio padrão do valor absoluto da amplitude instantânea normalizada e centralizada:

$$\sigma_{aa} = \sqrt{\frac{1}{N} \left( \sum_{n=1}^N A_{cn}^2(n) \right) - \left( \frac{1}{N} \sum_{n=1}^N |A_{cn}(n)| \right)^2} \quad (10)$$

Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada:

$$\sigma_{af} = \sqrt{\frac{1}{N_c} \left( \sum_{A_n(n) > A_t} f_N^2(n) \right) - \left( \frac{1}{N_c} \sum_{A_n(n) > A_t} |f_N(n)| \right)^2} \quad (11)$$



Desvio padrão da amplitude instantânea normalizada e centralizada:

$$\sigma_a = \sqrt{\frac{1}{N_c} \left( \sum_{A_n(n) > A_t} A_{cn}^2(n) \right) - \left( \frac{1}{N_c} \sum_{A_n(n) > A_t} A_{cn}(n) \right)^2} \quad (12)$$

Simetria do espectro em torno da frequência da portadora:

$$P = \frac{P_L - P_U}{P_L + P_U} \quad (13)$$

$$P_L = \sum_{k=1}^{f_{cn}} |X_c(k)|^2 \quad (14)$$

$$P_U = \sum_{k=1}^{f_{cn}} |X_c(k + f_{cn} + 1)|^2 \quad (15)$$

onde  $X_c(k)$  é a Transformada de Fourier do sinal recebido e  $(f_{cn} + 1)$  é o número da amostra correspondente à frequência da portadora, onde  $f_{cn}$  é dado por:

$$f_{cn} = \frac{f_c N}{f_s} - 1 \quad (16)$$

Média da amplitude instantânea normalizada centralizada ao quadrado:

$$\mu_{aa} = \frac{1}{N} \sum_{n=1}^N A_{cn}^2 \quad (17)$$

### 3. ALGORITMO DE CLASSIFICAÇÃO

Os sinais simulados têm as seguintes características: taxa símbolo de 10kHz, taxa de amostragem de 50kHz, 4096 amostras do sinal recebido. As modulações simuladas foram 4QAM, 16QAM, 2PSK, 4PSK, 2FSK, 4FSK, juntamente com um sinal de ruído

gaussiano puro. Os SNR utilizados foram -20, -15, -10, -5, 0, 5, 10 e 15dB. Para o método de decisão foi utilizada uma rede neural artificial com duas camadas, com 10 neurônios ocultos e 7 neurônios na camada de saída. Os algoritmos de treinamento foram o Resilient Backpropagation (Rprop) [8] e o Scaled Conjugate Gradient Backpropagation (SCG) [9].

Foram gerados 10000 sinais aleatórios de cada modulação para cada um dos 8 SNRs. O cálculo de cada características utiliza as 4096 amostras do sinal e é realizado para cada sinal e repetido para todos os SNRs. A rede neural foi treinada com todas as 8 características extraídas, para todos os SNRs, juntamente com uma indicação do SNR da amostra que estava sendo utilizada. No total foram simuladas e utilizadas no treinamento 560000 amostras de cada característica.

### 4. RESULTADOS

Os resultados obtidos no treinamento podem ser visualizados na Tabela 1. As variáveis Época e MSE representam o número de iterações que a rede neural foi treinada com todas as amostras e o erro médio quadrático ao fim do treinamento, respectivamente.

Tabela 1. Resultados do treinamento da rede neural

	Rprop	SCG
Época	883	237
MSE	0,00338	0,00321
Pcc	98,4%	97,7%
Pnd	0,0%	0,0%

Para o teste com amostras de -20dB, o resultado pode ser visto na matriz de confusão da Figura 1, onde a probabilidade de classificação correta é de 89,7%, e a probabilidade de não-detecção é 0,0%.



## CONCLUSÕES

Os resultados encontrados durante esse trabalho foram satisfatórios se comparados ao estado da arte, onde o algoritmo apresentado consegue atingir uma probabilidade de classificação correta maior para SNRs abaixo de -5dB [4][7].

[4] Z. Zhu and A.K. Nandi, Automatic Modulation Classification: Principles, Algorithms and Applications, 1ed., Londres: John Wiley and Sons, 2015.

[5] A.O. Dobre et al., “Survey of automatic modulation classification techniques: classical approaches and new trends”, IET Communications Vol. 1, 2007, p. 137 – 156

[6] A. Hazza et al., “An overview of feature-based methods for digital modulation classification”, First International Conference on Communications, Signal Processing and their Applications, 2013.

[7] G. Mendis, J. Wei and A. Madanayake, “Deep learning-based automated modulation classification for cognitive radio”, IEEE International Conference on Communications Systems, 2016.

[8] M. Riedmiller and H. Braun, “A direct adaptive method for faster backpropagation learning: The RPROP algorithm”, Proceedings of the IEEE International Conference on Neural Networks, 1993, p. 586-591.

[9] M. Moller, Neural Networks, Vol. 6, 1993, p. 525-533.

**Confusion Matrix**

Output Class	4QAM	16QAM	2PSK	4PSK	2FSK	4FSK	WGN	
4QAM	6720 9.6%	3911 5.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	63.2% 36.8%
16QAM	3280 4.7%	6089 8.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	65.0% 35.0%
2PSK	0 0.0%	0 0.0%	10000 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4PSK	0 0.0%	0 0.0%	0 0.0%	10000 14.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2FSK	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10000 14.3%	0 0.0%	0 0.0%	100% 0.0%
4FSK	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10000 14.3%	0 0.0%	100% 0.0%
WGN	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10000 14.3%	100% 0.0%
	67.2% 32.8%	60.9% 39.1%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	89.7% 10.3%
	4QAM	16QAM	2PSK	4PSK	2FSK	4FSK	WGN	
	Target Class							

Figura 1: Matriz de confusão do teste com SNR de -20dB

## REFERÊNCIAS

[1] S. Haykin, “Cognitive Radio: Brain-empowered wireless communications”, IEEE Journal on Selected Areas in Communications, 2005, p. 201-220.

[2] J. Mitola and G.Q. Maguire, “Cognitive Radio: Making software radios more personal”, IEEE Personal Communications, 1999, p. 13-18.

[3] W. Wang, “Spectrum Sensing for cognitive radio”, Third International Symposium on Intelligent Information Technology Application Workshops, 2009, p. 410-412.