



Detecção e Classificação de Modulação Baseadas em Redes Neurais Artificiais e Estimação de SNR para Rádio Cognitivo

Andre L. A. Camargo¹, Luis H. A. Lolis¹

¹UFPR, Curitiba, Brasil
almeida.andre@ufpr.br

Resumo—A detecção e classificação de sinais são alguns dos procedimentos mais importantes em um ambiente de rádio cognitivo. A classificação automática de modulação é um passo intermediário entre a detecção do sinal e a demodulação. Este trabalho tem o objetivo de implementar um algoritmo de classificação de modulação baseado em métricas extraídas de um sinal digital modulado e testá-lo em termos da taxa de acerto, falso alarme e não-deteção. Para a tomada de decisão, foi escolhido o método de Redes Neurais Artificiais, motivado nos bons resultados obtidos no estado da arte. As simulações e testes foram realizadas em MATLAB, utilizando as toolboxes Communication Systems e Neural Networks. O algoritmo teve como resultado final uma taxa de acerto de 92,6% para 0 dB, 78,5% para um SNR de -10 dB, e taxa de acerto de 36,6% de acerto para um SNR de -20 dB, com uma taxa de não-deteção de 0,0% para todos os SNRs testados.

I. INTRODUÇÃO

Com a crescente necessidade de gerenciamento do espectro de radiofrequência surgiu a idealização do Rádio Cognitivo [1, 2], que tem como objetivo estabelecer uma comunicação com alta confiabilidade, vistoriando e aprendendo com o espectro de frequências. A partir disso, foram definidas etapas de funcionamento essenciais, sendo uma delas o Sensoriamento Espectral. Dentro da etapa de Sensoriamento Espectral, existem as etapas de Detecção e Classificação de Modulação [3]. A fase de Classificação de Modulação, ou AMC (*Automatic Modulation Classification*), é feita com algoritmos inteligentes, que conseguem reconhecer e classificar modulações digitais e analógicas sem necessidade de operação externa [4]. Existem dois principais métodos utilizados para realizar a tomada de decisão, o método baseado na função de verossimilhança (*Likelihood-based*) e o método baseado em características do sinal (*Feature-based*). O método LB é baseado na função de verossimilhança, ou função de probabilidade do sinal recebido, e a decisão é feita comparando a razão de verossimilhança contra um limiar. Um algoritmo LB apresenta resultados ótimos, mas tem alta complexidade computacional [5, 6]. Por outro lado, nos algoritmos FB são empregados diversos cálculos para extrair características do sinal, e a decisão é feita por algoritmos de tomada de decisão, como redes neurais artificiais (RNAs), máquinas de vetores de suporte (*Support Vector Machines*, SVM), árvores de decisão (*Decision Tree*, DT) entre outros métodos de reconhecimento de padrões [6]. Devido à versatilidade que as redes neurais tem

apresentado, ela tem se tornado uma das ferramentas mais utilizadas em reconhecimento de padrões, inclusive em reconhecimento de modulações [4, 7, 12 e 13], Sensoriamento Espectral e Rádio Cognitivo como um todo. No algoritmo desenvolvido, foi escolhido como tomada de decisão o método de RNAs, motivado nos resultados obtidos inicialmente por [4] e por [13], que conseguiram resultados de 99% para SNR acima de 15 dB, depois por [7], que conseguiram resultados de 95% para SNR = -5 dB, e mais recentemente por [12], que conseguiram resultados acima de 90% para um SNR de -2 dB. Sendo assim, com o grande número de técnicas aplicadas em AMC, foi escolhido fazer o uso das técnicas de AMC baseadas em características com o uso de redes neurais artificiais. Como resultado final, foi obtido uma taxa de acerto 99,0% em SNR de 0 dB e 92,6% para SNR de -5 dB.

II. SINAIS E CARACTERÍSTICAS

A. Sensoriamento espectral

Existem várias técnicas utilizadas na etapa de sensoriamento, sendo as mais comuns Detecção de Energia, Filtro Casado e Detecção de Características. Na detecção de energia, é medida a energia do sinal recebido em uma certa banda de frequência. Devida à sua fácil implementação e baixa complexidade computacional, é a técnica mais usada, embora não consiga diferenciar sinais modulados de ruídos e/ou interferências. No filtro casado, é utilizado um filtro linear projetado para maximizar a relação sinal - ruído da saída dado o sinal de entrada, e é aplicado quando o usuário secundário tem conhecimento a priori do sinal do usuário primário. Na detecção de características, é capturada uma propriedade específica do sinal que consiga reconhecer qual é a modulação presente no sinal. Tem a vantagem de diferenciar a energia do ruído da energia do sinal modulado, mas é necessário um tempo de observação maior e uma alta complexidade computacional.

A etapa de sensoriamento espectral pode ser dividida em duas etapas: Detecção e Classificação de Modulação. A Detecção consiste em verificar o espectro em busca de usuários primários ou sinais que são destinados ao usuário secundário. A Classificação de Modulação, ou AMC, consiste em reconhecer a modulação do sinal recebido, para então passar para a fase de demodulação [6]. Os métodos usados em AMC são geralmente dois: Baseados em função de Verossimilhança (LB) e métodos Baseados em Características (FB). Segundo [6], embora o método

LB possa levar a ótimas soluções, são necessários cálculos mais complexos. Por outro lado um método FB bem projetado pode obter uma performance quase tão boa quando o LB com um custo computacional reduzido.

Nos métodos de classificação automática de modulação baseada em características, as características usadas para o reconhecimento de cada modulação são derivadas de três parâmetros importantes, amplitude, fase e frequência instantâneas do sinal interceptado, além de informações extraídas do espectro de radiofrequência do sinal.

Um sinal digital modulado, visto do receptor, tem a seguinte forma geral:

$$r(t) = [\alpha e^{j\varphi(t)} C(t)] + n(t), \quad (1)$$

onde α é a amplitude do sinal, $C(t)$ é o envelope complexo, $n(t)$ é o ruído aditivo do canal gaussiano e $\varphi(t)$ é a fase do sinal. Para a extração de características, é necessário o cálculo dos parâmetros instantâneos do sinal da equação 1, que seriam a amplitude, a fase e a frequência instantâneas, obtidos pelas equações a seguir:

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

$$\phi(t) = \arg(r(n)), \quad (3)$$

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

onde $A(n)$ é a amplitude instantânea, $\varphi(t)$ é fase instantânea e $f(n)$ é a frequência instantânea. Desses parâmetros são calculados duas medidas que serão utilizadas nas características posteriormente, que são a amplitude normalizada centralizada (A_{cn}) e a frequência normalizada centralizada (f_N):

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

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

onde N é o número de amostras do sinal e f_s é a frequência de amostragem. Após a realização dos cálculos das equações apresentadas, é realizada o cálculo das métricas de características.

B. Extração de características

As métricas que serão descritas a seguir servem para realizar a distinção entre as diferentes modulações, como QAM, PSK e FSK. Para que seja feita uma separação correta, as métricas escolhidas possuem diferentes naturezas instantâneas, como amplitude, fase e frequência. Algumas das métricas podem ser vistas a seguir:

-Valor máximo da Densidade Espectral de Potência da Amplitude normalizada centralizada:

$$Y_{max} = \text{MAX} \left(\left| \text{FFT}(A_{CN}) \right|^2 / N \right), \quad (7)$$

onde $\text{FFT}(\cdot)$ é a Transformada Rápida de Fourier.

- Desvio padrão da fase instantânea direta:

$$\sigma_{dp} = \sqrt{\frac{1}{N} \sum \varphi^2(n) - \left(\frac{1}{N} \sum \varphi(n) \right)^2}, \quad (8)$$

- Desvio padrão da amplitude normalizada centralizada:

$$\sigma_a = \sqrt{\frac{1}{N} \sum A_{cn}^2(n) - \left(\frac{1}{N} \sum A_{cn}(n) \right)^2}, \quad (9)$$

- Desvio padrão do valor absoluto da frequência normalizada centralizada:

$$\sigma_{af} = \sqrt{\frac{1}{N} \sum f_N^2(n) - \left(\frac{1}{N} \sum |f_N(n)| \right)^2}, \quad (10)$$

- Curtose:

$$K = E \frac{(x - \mu)^4}{\sigma^4}, \quad (11)$$

onde x é o sinal recebido normalizado centralizado, μ é a média de x , σ é o desvio-padrão de x , e $E(\cdot)$ representa o valor esperado. Além das cinco métricas citadas anteriormente, também são utilizadas mais quatro, baseadas nos trabalhos de [7] e [12].

As características apresentadas conseguem separar sinais de amplitude constante, fase linear ou frequência linear, sendo assim capaz de diferenciar modulações em amplitude (AM), modulações em fase (PM) e modulações em frequência (FM), algumas até mesmo em SNRs abaixo do 0 dB. Essas características serão extraídas dos sinais modulados na simulação em MATLAB e serão utilizadas para diferenciá-los, com o uso da rede neural MLP.

C. Estimação de SNR

A Estimação do SNR [10] é usada em métodos de sensoriamento espectral, juntamente de técnicas de detecção de energia, para localizar espaços disponíveis no espectro de frequência. A estimação é aplicada aos métodos de sensoriamento espectral visto que esses métodos sofrem de grande incerteza na estimação da variância do ruído. Em [10], foi proposto um método que estima a variância do ruído dado um conjunto de sinais ruidosos ou de ruído puro. Para realizar a estimação da variância do ruído, foi desenvolvido o seguinte método [10]:

Primeiramente, são realizadas múltiplas medidas de um mesmo sinal, e para cada conjunto de medidas são coletadas N amostras. Sendo assim, $S_M(N)$ é a representação de uma medição, onde M é o número da medição e N é o número da amostras por medição, como definido na equação 14,

$$S_M = [S_M(1) \ S_M(2) \ S_M(3) \ \dots \ S_M(N)], \quad (12)$$

onde $S_M(N)$ representa a n -ésima amostra individual para o m -ésimo conjunto de medidas. O conjunto de

vetores de medidas pode ser representada como uma matriz S :

$$S = \begin{bmatrix} S_1(1) & S_1(2) & \cdots & S_1(N) \\ S_2(1) & S_1(2) & \cdots & S_2(N) \\ \vdots & \vdots & \ddots & \vdots \\ S_M(1) & S_M(2) & \cdots & S_M(N) \end{bmatrix}, \quad (13)$$

A partir da matriz S , são criados vetores coluna, C_x onde x é uma coluna de S :

$$C_x = \begin{bmatrix} S_1(x) \\ S_2(x) \\ \vdots \\ S_M(x) \end{bmatrix}, \quad (14)$$

Por fim, a variância do conjunto de sinais é dado pela seguinte equação:

$$\sigma^2 = \frac{\sum_{A=1}^N \left[\sum_{x=1}^M (S_x(A) - \bar{C}_A)^2 \right]}{N(M-1)}, \quad (15)$$

onde \bar{C}_A é a média de C_A .

III. ALGORITMO DE CLASSIFICAÇÃO

Os sinais foram simulados com os seguintes parâmetros: taxa símbolo de 10 kHz, taxa de amostragem de 50 kHz, 4096 símbolos transmitidos. As modulações simuladas foram 16QAM, 2PSK, 4PSK, 2FSK, 4FSK. Juntamente com as modulações, foi gerado um sinal de ruído gaussiano puro de mesmo número de amostras das modulações. Os SNRs utilizados na simulação foram -20, -15, -10, -5, 0, 5, 10 e 15 dB. Após configurados esses parâmetros são gerados os sinais modulados. Para cada sinal é gerada uma mensagem aleatória. A mensagem passa por um modulador e o sinal resultante é adicionado a um ruído WGN proporcional ao SNR da simulação. Tendo o sinal gerado completamente, são realizados os cálculos das características apresentadas anteriormente. Cada característica utiliza todos os 4096 símbolos recebidos. Esse processo de geração do sinal e cálculo de características foi repetido 2000 vezes para cada SNR, tendo como resultado 16000 amostras de cada característica, para cada modulação simulada.

Para o método de decisão foi utilizada uma rede neural artificial com duas camadas, 10 neurônios na camada oculta e 6 neurônios na camada de saída relativos as 5 modulações mais o ruído puro. A função de transferência utilizada na rede é a função Sigmóide. Foi utilizada apenas uma camada oculta com 10 neurônios, pois foi verificado com testes que a rede não tem ganho significativo se aumentado tanto o número de neurônios quanto de camadas. Nesse trabalho, a rede neural funciona como um classificador, que a partir dos dados obtidos das métricas anteriormente citadas, escolhe uma modulação como sendo a recebida. O algoritmo de treinamento foi o *Resilient Backpropagation* (Rprop) [8]. Durante o treinamento da rede, é utilizada metade das amostras geradas, sendo que a outra metade será utilizada durante o teste.

IV. RESULTADOS

Depois de realizado o treinamento da rede, foram obtidas os resultados da rede: Taxa de acerto de 81,5%, taxa de falso-alarmede 18,1% e taxa de não-deteccção de 0,0%. Esse valores foram obtidos da matriz de confusão gerada pelo software MATLAB, disponível na figura 1.

		Confusion Matrix						
		4QAM	16QAM	2PSK	2FSK	4FSK	WGN	
Output Class	4QAM	5545 11.6%	788 1.6%	427 0.9%	218 0.5%	91 0.2%	0 0.0%	78.4% 21.6%
	16QAM	1096 2.3%	5852 12.2%	627 1.3%	497 1.0%	328 0.7%	0 0.0%	69.7% 30.3%
	2PSK	245 0.5%	232 0.5%	6055 12.6%	195 0.4%	146 0.3%	0 0.0%	88.1% 11.9%
	2FSK	588 1.2%	611 1.3%	463 1.0%	6475 13.5%	221 0.5%	0 0.0%	77.5% 22.5%
	4FSK	526 1.1%	517 1.1%	428 0.9%	615 1.3%	7214 15.0%	0 0.0%	77.6% 22.4%
	WGN	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8000 16.7%	100% 0.0%
		69.3% 30.7%	73.2% 26.8%	75.7% 24.3%	80.9% 19.1%	90.2% 9.8%	100% 0.0%	81.5% 18.5%
		Target Class						

Figura 1: Matriz de confusão de treinamento.

Também foram obtidos os resultados para o segundo conjunto de amostras gerado. A taxa de acerto foi de 80,7%, taxa de falso-alarmede 19,1% e não-deteccção de 0,0%. A matriz de confusão do teste está na figura 2. A rede também foi testada para SNRs específicos. Para o teste em -20 dB de SNR, a rede teve uma taxa de acerto de 36,6%. Para o teste com um SNR de -10 dB, a taxa de acerto foi de 78,5%. Todos os SNRs testados tiveram uma taxa de não-deteccção de 0,0%. Os resultados do teste para SNR de 0 dB podem ser vistos na figura 3.

V. CONCLUSÃO

Os objetivos propostos foram alcançados, sendo que foram obtidas as taxas propostas, para SNRs entre 15 e -20 dB. Foi obtido uma taxa de acerto de 99,0% para um SNR de 0 dB, uma taxa de acerto de 92,6% para SNR de -5 dB e uma taxa de acerto de 78,5% para um SNR de -10 dB. O algoritmo implementado utiliza como característica o valor estimado do SNR do canal para classificar uma modulação, algo que não visto em trabalhos consultados na literatura. Foi obtido uma taxa de não-deteccção de 0,0%, ou seja, o algoritmo consegue classificar corretamente quando o sinal recebido é modulado ou somente ruído, para todos os níveis de SNR testados.

		Confusion Matrix						
		4QAM	16QAM	2PSK	2FSK	4FSK	WGN	
Output Class	4QAM	5515 11.5%	808 1.7%	492 1.0%	308 0.6%	309 0.6%	0 0.0%	74.2% 25.8%
	16QAM	1109 2.3%	5852 12.2%	432 0.9%	505 1.1%	234 0.5%	0 0.0%	72.0% 28.0%
	2PSK	378 0.8%	369 0.8%	6254 13.0%	286 0.6%	209 0.4%	0 0.0%	83.4% 16.6%
	2FSK	398 0.8%	404 0.8%	344 0.7%	6216 13.0%	329 0.7%	0 0.0%	80.8% 19.2%
	4FSK	600 1.2%	567 1.2%	478 1.0%	685 1.4%	6919 14.4%	0 0.0%	74.8% 25.2%
	WGN	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8000 16.7%	100% 0.0%
		68.9% 31.1%	73.2% 26.8%	78.2% 21.8%	77.7% 22.3%	86.5% 13.5%	100% 0.0%	80.7% 19.3%
		4QAM	16QAM	2PSK	2FSK	4FSK	WGN	

Figura 2: Matriz de confusão para conjunto de teste

		Confusion Matrix						
		4QAM	16QAM	2PSK	2FSK	4FSK	WGN	
Output Class	4QAM	987 16.4%	0 0.0%	50 0.8%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%
	16QAM	0 0.0%	1000 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2PSK	13 0.2%	0 0.0%	950 15.8%	0 0.0%	0 0.0%	0 0.0%	98.7% 1.3%
	2FSK	0 0.0%	0 0.0%	0 0.0%	1000 16.7%	0 0.0%	0 0.0%	100% 0.0%
	4FSK	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1000 16.7%	0 0.0%	100% 0.0%
	WGN	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1000 16.7%	100% 0.0%
	98.7% 1.3%	100% 0.0%	95.0% 5.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.0% 1.0%	
		4QAM	16QAM	2PSK	2FSK	4FSK	WGN	

Figura 3: Matriz de confusão para teste em SNR de 0 dB.

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.
- [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 featurebased methods for digital modulation classification", First International Conference on Communications, Signal Processing and their Applications, 2013.
- [7] M. L. D. Wong, A. K Nandi. "Automatic digital modulation recognition using artificial neural network and genetic

algorithm". Elsevier Signal Processing Vol. 84, p. 351 – 365, 2004.

- [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.
- [10] A. Ahmed, F. Y. Hu, J. Noras. "Noise variance estimation for spectrum sensing in cognitive radio networks". AASRI Conference on Circuit and Signal Processing (CSP), 2014.
- [11] B. I. Dahap, L. Hongshu. "Advanced algorithm for automatic modulation recognition for analogue and digital signals". International Conference on Computing, Control, Networking, Electronics and Embedded Systems Engineering, p. 32 – 36, 2015.
- [12] G. Mendis, J. Wei and A. Madanayake, "Deep learning-based automated modulation classification for cognitive radio", IEEE International Conference on Communications Systems, 2016.
- [13] G. Arulampalam et al. "Classification of digital modulations schemes using neural networks". Fifth International Symposium on Signal Processing and its Applications (ISSPA), 1999.