

Arquitetura Inteligente de Sensoriamento Espectral por Análise de Cicloestacionariedades

Pedro T. V. de Souza, Vinícius S. V. de Souza e Luiz F. Q. Silveira

Resumo—Sistemas de rádio cognitivo devem ser capazes de perceber faixas de frequência desocupadas para transmissões oportunísticas, assim como detectar a presença de usuários primários quando estes ocupam seu espectro licenciado. Portanto, um elemento crucial para a operação desses sistemas é o sensoriamento espectral. Este trabalho apresenta uma arquitetura inteligente de sensoriamento, baseada no cálculo da função de densidade espectral cíclica do canal sensoriado e na utilização de um comitê de máquinas *perceptron* múltiplas camadas, para detectar sinais modulados na presença de ruído Gaussiano branco aditivo. A arquitetura proposta foi avaliada no sensoriamento de modulações QPSK e os resultados obtidos nos experimentos realizados comprovaram a eficiência desta arquitetura mesmo em cenários com baixa relação sinal-ruído.

Palavras-Chave—Sensoriamento Espectral, Rádio Cognitivo, Cicloestacionariedade, Redes Neurais, Comitê de Máquinas.

Abstract—Cognitive radio systems should be able to perceive unoccupied frequency bands for opportunistic transmission, as well as the presence of primary users when they are occupying their licensed spectrum. Therefore, a crucial element in the operation of these systems is the spectral sensing. This paper presents an intelligent sensing architecture, based on the computation of Spectral Correlation Density Function of the sensed channel and the use of a committee machine multilayer perceptron for detecting modulated signals in the presence of additive white Gaussian noise. The proposed architecture was evaluated in sensing of QPSK modulation. Obtained results prove the efficiency of the proposed architecture, even on environments with low signal-to-noise values.

Keywords—Spectrum Sensing, Cognitive Radio, Cyclostationarity, Neural Networks, Committee Machine

I. INTRODUÇÃO

O desenvolvimento das tecnologias de comunicação sem fio tem ocasionado um aumento na demanda do espectro eletromagnético, o que levou a comunidade científica e os órgãos reguladores a estudarem uma política de uso mais flexível do espectro, denominada DSA (*Dynamic Spectrum Access*) [1], [2].

No DSA, o sistema de rádio, denominado rádio cognitivo [8], deve realizar o sensoriamento espectral do ambiente em que se encontra, atividade esta que consiste na detecção de porções livres do espectro eletromagnético [3]. Desse modo, dentre os métodos definidos na literatura para realizar esse sensoriamento, três merecem destaque: sensoriamento por energia; por filtros casados; e por cicloestacionariedade.

Pedro Thiago Valério de Souza Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Norte, Natal-RN, Brasil, E-mail: pedrothiag@gmail.com. Vinícius Samuel Valério de Souza, Universidade Federal Rural do Semi-Árido, Pau dos Ferros-RN, Brasil, E-Mail: vini-ciussamuel@ufersa.edu.br Luiz Felipe Queiroz Silveira Departamento de Engenharia de Computação e Automação, Universidade Federal do Rio Grande do Norte, Natal-RN, Brasil, E-mail: Ifelipe@dca.ufrn.br.

O sensoriamento por energia verifica porções livres do espectro mediante estimação da energia dos sinais recebidos [4]. Embora seja bastante difundida em virtude da sua simplicidade de implementação, esta técnica de sensoriamento não é eficaz em ambientes com baixa SNR (*Signal Noise Ratio*) ou com presença de ruído não estacionário [5], [6].

No sensoriamento por filtros casados, a detecção de uma porção livre do espectro é feita mediante a correlação entre um sinal piloto, previamente conhecido, e o sinal recebido [7]. Apesar deste método de sensoriamento conseguir um resultado ótimo, a implementação é inviável em virtude de requerer conhecimento acerca de várias características dos sinais a serem sensoriados [8].

O sensoriamento por cicloestacionariedade identifica padrões nos sinais recebidos baseando-se em momentos estatísticos dos mesmos [9]. Nesse ponto, dentre os métodos de sensoriamento citados, este se configura como sendo o mais interessante para detectar sinais em ambientes com baixa SNR, além de não requerer nenhum conhecimento prévio desses sinais e conseguir detectar características dos mesmos que não são identificadas pelo sensoriamento por energia [10].

Diversos trabalhos presentes na literatura descrevem métodos e sistemas que utilizam cicloestacionariedade para realizar sensoriamento espectral. Em [11], por exemplo, os autores utilizam Cadeias de Markov para classificar características levantadas a partir de medidas de cicloestacionariedade realizadas sobre sinais modulados. Em [3], por sua vez, é proposta uma técnica de sensoriamento realizada a partir de um limiar calculado por meio de funções resultantes de um processo de análise cicloestacionária efetuada sobre sinais monitorados. Além desses trabalhos, a arquitetura descrita em [12] utiliza uma Rede Neural Artificial (RNA) para, a partir de características cicloestacionárias verificadas, classificar a modulação de sinais monitorados. Por fim, em [13], os autores propõem um sistema que inicialmente estima valores de funções cicloestacionárias sobre uma região de R^2 e utiliza tais valores para efetuar o sensoriamento de sinais transmitidos sobre porções do espectro eletromagnético.

Em todos os trabalhos citados, os piores resultados obtidos foram verificados para cenários em que a modulação QPSK (*Quadrature Phase Shift Keying*) foi utilizada. Deste modo, tendo em vista que tal modulação é largamente usada em sistemas de comunicação sem fio [27], o presente trabalho descreve uma arquitetura inteligente de sensoriamento espectral por análise de cicloestacionariedades e avalia, por simulações computacionais, o desempenho desta arquitetura quanto a sua capacidade de detectar sinais em ambientes de comunicação com modulação QPSK.

O restante deste artigo está organizado como segue: a Seção

II apresenta os principais conceitos sobre sensoriamento por cicloestacionariedade; a Seção III apresenta a arquitetura de classificação proposta; na Seção IV, tal arquitetura é avaliada por simulação computacional; e, por fim, na Seção V são apresentadas as conclusões do trabalho.

II. CICLOESTACIONARIEDADE

Um sinal $x(t)$ é cicloestacionário de ordem n (no sentido amplo) se houver uma transformação não-linear $f(\cdot)$ de ordem n , tal que o sinal $y(t) = f(x(t))$ apresente componentes senoidais de amplitude finita [10]. Nesse contexto, em grande parte dos casos práticos, os sinais de comunicação são cicloestacionários de segunda ordem [7], ou seja, existe uma transformação quadrática que, uma vez aplicada a tais sinais, produz componentes senoidais de amplitude finita. Os sinais com essas características apresentam Função de Autocorrelação periódica expressa na Equação (1):

$$R_x(t+T, \tau) = R_x(t, \tau), \quad (1)$$

em que T é o período de repetição e $R_x(t, \tau)$ é a Função de Autocorrelação descrita na Equação (2) [10]:

$$R_x(t, \tau) = \left\langle x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) \right\rangle. \quad (2)$$

em que o símbolo $\langle \cdot \rangle$ representa o operador média temporal:

$$\langle \cdot \rangle = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} (\cdot) dt. \quad (3)$$

Considerando que a Função de Autocorrelação de um processo cicloestacionário de segunda ordem é periódica, a mesma pode ser representada através de uma expansão em série de Fourier. Define-se a Função de Autocorrelação Cíclica - *Cyclic Autocorrelation Function* (CAF) - como sendo os coeficientes resultantes dessa expansão, i.e.:

$$R_x^\alpha(\tau) = \left\langle x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\alpha t} \right\rangle, \quad (4)$$

em que α é denominado *frequência cíclica* e representa um conjunto de harmônicas da frequência fundamental, sendo portanto discreto [14].

Na Equação (4) é perceptível que, para $\alpha = 0$, a Função de Autocorrelação Cíclica torna-se simplesmente a Função de Autocorrelação tradicional descrita na Equação (2) [15]. Dessa forma, o sinal possui cicloestacionariedade de segunda ordem se, para algum $\alpha \neq 0$, a Função de Autocorrelação Cíclica é diferente de zero. O conjunto de frequências cíclicas no qual a CAF é diferente de zero é chamado de ciclo-espectro [16].

A partir da Relação Cíclica de Wiener [11], pode-se definir a Função de Densidade de Correlação Espectral (*Spectral Correlation Density Function* - SCD), denotada por $S_x^\alpha(f)$, como sendo a transformada de Fourier da CAF, ou seja:

$$S_x^\alpha(f) = \mathcal{F}[R_x^\alpha(\tau)] = \int_{-\infty}^{\infty} R_x^\alpha(\tau) e^{-j2\pi f\tau} d\tau, \quad (5)$$

em que f é a frequência do sinal expressa em Hz [17]. A SCD pode também ser entendida como a correlação estatística entre componentes espectrais $f + \alpha/2$ e $f - \alpha/2$ de um sinal $x(t)$ e pode ser determinada a partir do periodograma cíclico variante

no tempo [14]:

$$S_x^\alpha(f) = \left\langle X\left(t, f + \frac{\alpha}{2}\right) X^*\left(t, f - \frac{\alpha}{2}\right) \right\rangle, \quad (6)$$

em que $X(t, \nu)$ é uma STFT (*Short-Time Fourier Transform*) deslizante de tamanho T .

A avaliação da SCD, conforme definido na Equação (6), gera uma superfície sobre o plano (f, α) , simétrica tanto em f quanto em α , como exemplificado na Figura 1 para um sinal com modulação BPSK (*Binary Phase Shift Keying*).

O sensoriamento espectral usando cicloestacionariedade fundamenta-se no princípio de que o ruído estacionário não possui qualquer correlação espectral para uma frequência cíclica diferente de zero ($\alpha \neq 0$), conforme ilustrado na Figura 2 [17].




Fig. 1. Função de Densidade de Correlação Espectral (SCD) Estimada para um Sinal Modulado BPSK

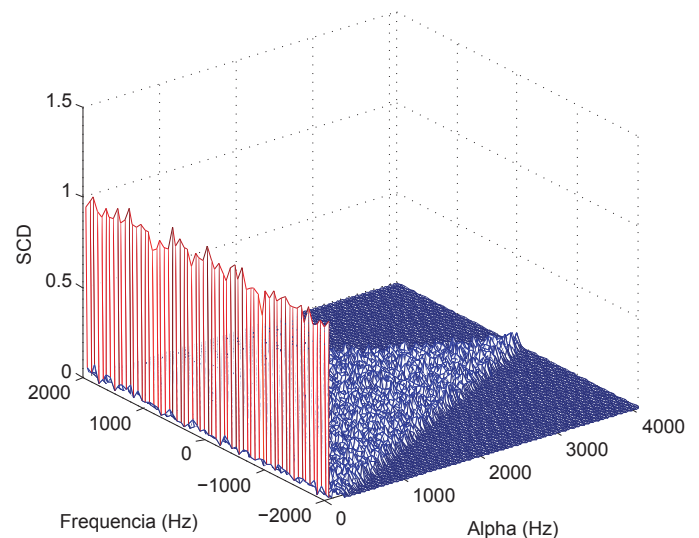


Fig. 2. Função de Densidade de Correlação Espectral (SCD) Estimada para um Ruído Gaussiano com Média Zero e Variância Unitária.

III. ARQUITETURA INTELIGENTE DE SENSORIAMENTO ESPECTRAL POR ANÁLISE DE CICLOESTACIONARIEDADES

A arquitetura proposta neste trabalho utiliza a análise de características cicloestacionárias dos sinais de comunicações para realizar o sensoriamento espectral. Essa arquitetura, ilustrada na Figura 3, é constituída por três partes, detalhadas nas próximas subseções: o Extrator de Características; o Comitê de Máquinas Especialistas; e o Algoritmo de Seleção.




Fig. 3. Arquitetura Inteligente de Sensoriamento Espectral usando a Cicloestacionariedade

A. Extrator de Características

O Extrator de Características implementado neste trabalho foi concebido para um cenário em que se conhece o conjunto de possíveis modulações que podem ocorrer na faixa de espectro analisada.

A função deste bloco, dentro da arquitetura ilustrada na Figura 3, é calcular o valor da SCD de um sinal $y(n)$ transmitido sobre uma faixa do espectro, e que foi corrompido por ruído aditivo Gaussiano branco (AWGN) $\beta(n)$, por meio do algoritmo descrito em [18]. Neste cálculo, considerou-se apenas o ponto do cicloespectro localizado em $\alpha = f_s/8$, em que f_s corresponde à frequência de amostragem do transmissor, já que este artigo investiga o sensoriamento para sinais transmitidos com modulação QPSK.¹

Como o ruído Gaussiano branco apresenta valores de correlação espectral apenas em $\alpha = 0$, pode-se distinguir entre a ausência e a presença de um sinal QPSK analisando a SCD em $\alpha = f_s/8$. Essa ideia é ilustrada na Figura 4, na qual são apresentadas a SCD de um sinal QPSK em $\alpha = f_s/8$ (item “a”) e a SCD de um ruído Gaussiano branco (item “b”).




Fig. 4. Função Densidade de Correlação Espectral calculada em $\alpha = f_s/8$ para (a) Sinal QPSK e (b) Ruído Gaussiano Branco.

¹É sabido que sinais QPSK possuem apenas um pequeno pico na SCD, localizado exatamente em $\alpha = f_s/8$ [19].

B. Comitê de Máquinas Especialistas

O Comitê de Máquinas recebe a SCD calculada pelo Extrator de Características e decide acerca da ocupação ou não da porção monitorada do espectro eletromagnético. Segundo ilustrado na Figura 3, este comitê é composto por um conjunto de n máquinas especialistas, em que a estrutura de cada uma dessas máquinas é apresentada na Figura 5.

Conforme apresentado na Figura 5, cada especialista é composto por uma Rede Neural Artificial *Perceptron* de Múltiplas Camadas, cujos neurônios fazem uso de uma função de ativação definida por uma tangente hiperbólica [20]. A rede de cada especialista é treinada para se adaptar às diversas condições possíveis às quais o canal de comunicação sem fio monitorado pode estar submetido, e possui três camadas: uma camada de entrada com 16 portas (quantidade necessária para receber os valores da SCD calculada pelo Extrator de Características); uma oculta com 20 neurônios; e uma de saída com 1 neurônio, o qual gera valores iguais a +1 ou -1 que correspondem, respectivamente, a indicação de presença ou ausência de sinal transmitido sobre a porção analisada do espectro eletromagnético.




Fig. 5. Arquitetura de cada especialista do comitê de máquinas.

Na estrutura adotada para o Comitê de Máquinas, a decisão tomada por cada um dos n especialistas é feita de forma independente, sendo que tais decisões são enviadas ao bloco subsequente da arquitetura, o qual as combina e produz a decisão final acerca da ocupação ou não da porção monitorada do espectro. Essa estratégia foi adotada por considerar que a divisão de tarefas entre sistemas especialistas, seguida da combinação das respostas fornecidas por esses sistemas, é teoricamente mais precisa que os resultados gerados individualmente por cada um dos especialistas considerados [20], [21], [22], [23].

C. Algoritmo de Seleção

O Algoritmo de Seleção é responsável por combinar as saídas de cada um dos n especialistas do Comitê de Máquinas para determinar a resposta final da arquitetura. Na realização desta tarefa, o Algoritmo de Seleção requer o conhecimento prévio da SNR do canal monitorado valor este que pode ser obtido por um estimador de SNR.

IV. RESULTADOS E DISCUSSÕES

Os resultados levantados neste trabalho foram obtidos por simulação computacional da arquitetura de sensoriamento proposta no MATLAB. Nessas simulações, procurou-se avaliar dois pontos: 1) a eficiência do processo de aprendizagem das Redes Neurais que compõem cada um dos n especialistas existentes no Comitê de Máquinas; e 2) a eficiência da

arquitetura proposta em relação à detecção de sinais em uma dada porção sensorizada do espectro. Desse modo, as próximas subseções descrevem esses resultados e realizam a análise dos mesmos.

A. Processo de Treinamento

O canal de comunicação adotado neste trabalho foi modelado através de um processo Gaussiano branco aditivo, o qual foi definido por meio de variáveis aleatórias complexas com média nula e variância $N_0/2$ por dimensão. O Comitê de Máquinas implementado foi composto por 20 especialistas, cujas Redes Neurais foram treinadas por meio do algoritmo LMA (*Levenberg-Marquardt Algorithm*) [24], [25].

Durante o treinamento, a Rede Neural de cada especialista foi submetida a um conjunto de 200 funções de Densidade de Correlação Espectral distribuídas da seguinte forma: 100 delas retratavam situações em que um sinal QPSK era transmitido sobre a porção monitorada do espectro; e 100 delas retratavam situações em que tal porção estava livre. Neste cenário, é interessante ressaltar que a Rede Neural de cada um desses 20 especialistas foi treinada para um valor de SNR distinto, inteiro e situado entre 5 dB e -14 dB.

Em relação ao cálculo das SCD presentes em cada um dos 20 conjuntos usados no treinamento dos especialistas, vale salientar que tais funções foram estimadas por meio de uma modificação do algoritmo CPD (*Cyclic Periodogram Detection*), conforme processo descrito em [26], na qual utilizou-se os seguintes parâmetros:

- Frequência da Portadora (f_c): 1024 Hz;
- Frequência de Amostragem (f_s): 4096 Hz;
- Tempo de simulação (T): 0,0625 s;
- Número de amostras por símbolo (n_{samp}): 16;
- Tamanho de Bloco (N): 512;
- Quantidade de Blocos (L): 8.

Diante do processo de treinamento descrito, a aprendizagem dos neurônios que compõem as Redes Neurais dos especialistas foi realizada através de um processo supervisionado regido pelo Algoritmo de Retropropagação [20], que foi executado até atingir-se um erro médio quadrático de 1×10^{-5} . A Tabela I retrata o desempenho do processo de aprendizagem de cada especialista em termos da SNR adotada pelo mesmo, da quantidade de épocas necessárias para se concluir o processo de aprendizagem de sua Rede Neural e do erro médio quadrático obtido no fim desse processo.

Os resultados descritos na Tabela I tornam evidente o bom desempenho do processo de aprendizagem realizado, uma vez que este sempre convergiu para o erro médio quadrático desejado numa quantidade pequena de épocas, independente da SNR considerada para cada especialista. Esse comportamento deve-se ao fato da informação descrita na função de Densidade de Correlação Espectral não ser distorcida mesmo em ambientes com baixa SNR [3], o que incorporou robustez ao processo de treinamento das Redes Neurais.

B. Processo de Validação

A validação da arquitetura proposta neste trabalho foi realizada através de um conjunto de Funções de Densidade de

TABELA I
VALORES RELATIVOS AO PROCESSO DE APRENDIZAGEM DOS ESPECIALISTAS

Especialista	SNR (dB)	Épocas	Erro (10^{-6})
1	5	6	6,74
2	4	6	8,76
3	3	8	1,42
4	2	7	5,23
5	1	6	5,74
6	0	6	6,67
7	-1	8	5,54
8	-2	8	5,24
9	-3	6	2,65
10	-4	6	3,28
11	-5	6	6,13
12	-6	6	2,60
13	-7	7	5,92
14	-8	7	4,51
15	-9	9	7,22
16	-10	7	1,81
17	-11	6	7,82
18	-12	7	1,80
19	-13	7	6,31
20	-14	8	6,34

Correlação Espectral, calculadas segundo o processo descrito em [18] para uma faixa de valores de SNR entre -15dB e 5dB. Esse conjunto foi composto por 600 funções, nas quais adotou-se probabilidades iguais de presença e de ausência de sinais QPSK. Somado a estes aspectos, durante as simulações realizadas, considerou-se também que as condições do canal sensorizado eram completamente conhecidas pela arquitetura, de forma que o Estimador de SNR não foi implementado.

Visando permitir uma análise mais robusta da arquitetura proposta, foram realizadas simulações do cenário de teste descrito para a arquitetura apresentada em [18], a qual também utiliza medidas cicloestacionárias na etapa de extração de características, mas que, durante a classificação, faz uso de detecção por limiar sub-ótimo. Nesse contexto, as Figuras 6 e 7 ilustram, respectivamente, a probabilidade de detecção e de falso alarme obtidas nas simulações das arquiteturas avaliadas.

A partir da análise das curvas da Figura 6, nota-se que, acima de -11dB, o desempenho da arquitetura de sensoramento proposta neste artigo apresenta taxas de acerto de 100%, o que evidencia a eficiência desta arquitetura quanto a sua capacidade de detectar sinais QPSK mesmo em ambientes com baixa SNR. Além disso, nota-se também nesta Figura que o desempenho da arquitetura descrita neste artigo foi consideravelmente melhor que o observado para a arquitetura descrita em [18].

Analisando os gráficos expressos na Figura 7, percebe-se que, além de sempre obter um desempenho superior ao da arquitetura descrita em [18], a arquitetura proposta neste trabalho não gerou falsos alarmes para transmissões efetuadas

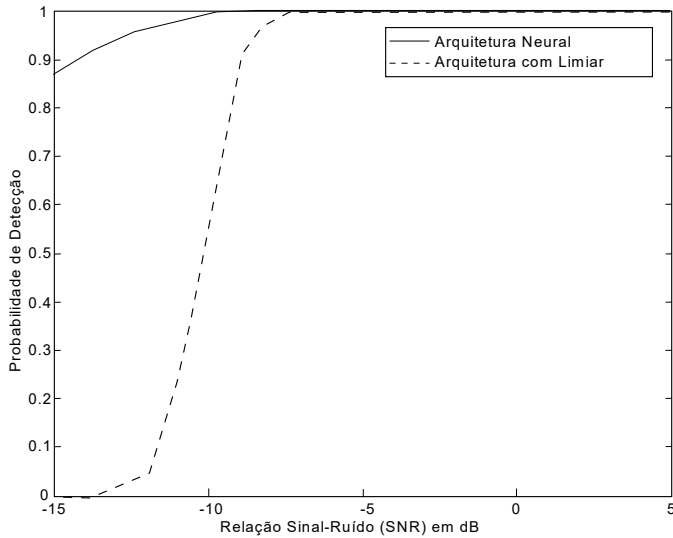


Fig. 6. Probabilidade de Detecção da Arquitetura Proposta e da Arquitetura com Limiar.

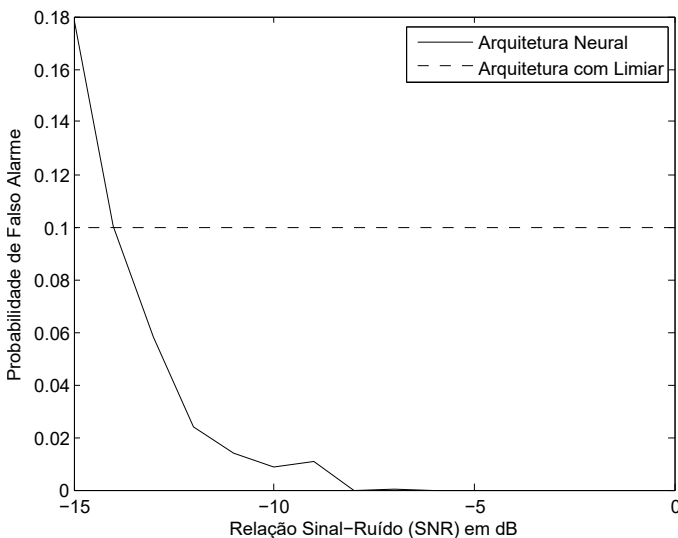


Fig. 7. Probabilidade de Falso Alarme da Arquitetura Proposta e da Arquitetura com Limiar.

em canais com SNR de até -8dB, enquanto que, para canais com SNR situadas entre -9dB e -13dB, o percentual de falsos alarmes verificados nesta arquitetura foi sempre menor que 10%, o qual consiste num valor aceitável para cenários de comunicações sem fio [2].

V. CONCLUSÕES

Diante dos resultados obtidos, nota-se que a arquitetura de sensoriamento proposta conseguiu obter um bom desempenho mesmo em cenários com baixos valores de SNR, além de mostrar-se mais eficiente que a arquitetura apresentada pelos mesmos autores em um trabalho anterior. Na continuação desse trabalho, pretende-se avaliar o efeito do desvanecimento sobre a arquitetura de sensoriamento proposta, expandir o conjunto de modulações consideradas e implementar a arquitetura proposta em plataformas de rádio definido por *software*.

REFERÊNCIAS

- [1] R.W. Brodersen - *A cognitive radio approach for usage of virtual unlicensed spectrum*. [S.l.], Julho 2004.
- [2] P.S. Coutinho - *Detecção de Energia para Rádios Cognitivos usando GNU Radio e USRP2* - Universidade Federal do Rio de Janeiro, 2011.
- [3] P.T.V. Souza e L.F.Q. Silveira - *Detecção de Sinais Modulados usando Medida de Cicloestacionariedade* - 31 o Simpósio Brasileiro de Telecomunicações - SBt 2013.
- [4] O.S. Vaiday, V.M. Kulkarni - *Analysis of Energy Detection based Spectrum Sensing over Wireless Fading Channels in Cognitive Radio Network* - International Journal of Emerging Technology and Advanced Engineering, Volume 3, Issue 3, March 2013.
- [5] E.P.L. Almeida - *Desenvolvimento de Técnica de Sensoriamento do Espectro Embasada em Detecção de Energia para Aplicações em Sistemas Rádio-Cognitivos. Dissertação (Mestrado)* - UNB, Fevereiro 2010.
- [6] D. Bhargavi e C.R. Murthy - *Performance Comparison of Energy, Matched-Filter and Cyclostationarity-Based Spectrum Sensing* IEEE Eleventh International Workshop on Signal Processing Advances in Wireless Communications (SPAWC 10), pp. 1-5, Jun. 2010.
- [7] S. Haykin e M. Moher - *Sistemas de Comunicação* - 5ª Edição, Bookman, 2011.
- [8] J. Mitola III e G.Q. Maguire Jr. - *Cognitive Radio: Making Software Radio More Personal* IEEE Personal Communications, vol.6, no. 4, pp. 13-18, Aug, 1999.
- [9] A. Farias, C.E.N. Melo e R.V. Dias - *Uma Abordagem a Métodos de Sensoriamento do Espectro Aplicados a Rádio Cognitivo* - UNB, Brasília, 2010.
- [10] E.L. Costa - *Detection and Identification of Cyclostationary Signals* - Naval Postgraduate School, 1996.
- [11] K. Kim (et al) - *Cyclostationary Approaches to Signal Detection and Classification in Cognitive Radio*, 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks (DySPAN-07), pp.212-215, Apr. 2007.
- [12] S. Kandeepan, G. Baldini e R. Piesiewicz - *Experimentally detecting ieee 802.11n wi-fi based on cyclostationarity features for ultra-wide band cognitive radios* in IEEE 20th International Symposium on Personal, Indoor and Mobile Radio Communications, pp. 2315-2319, 2009.
- [13] S.R.Q. Thai e G.M.M. Kandeepan - *Energy-Efficient Spectrum Sensing Using Cyclostationarity* - IEEE, 2011.
- [14] W.A. Gardner - *Cyclostationarity in Communications and Signal Processing* - IEEE Press, 1994.
- [15] D.A. Streigh - *Application of Cyclostationary Signal Selective to the Carry-on Multi-Platform GPS Assisted Time Difference of Arrival System* - Naval Postgraduate School, 1997.
- [16] W.A. Gardner - *Statistical Spectral Analysis: A Nonprobabilistic Theory*. New Jersey: Prentice-Hall, 1988.
- [17] W.A. Gardner - *Exploitation of Spectral Redundancy in Cyclostationary Signals*, IEEE Signal Processing, vol. 8, no. 2, pp. 14-36, Apr. 1991.
- [18] P.T.V. Souza e L.F.Q. Silveira - *Arquitetura de Sensoriamento Espectral de Sinais Modulados usando uma Medida de Cicloestacionariedade* - Congresso Brasileiro de Inteligência Computacional 2013 - CBIC 2013.
- [19] W.A. Gardner e W.A. Sponner - *Measurement of Spectral Correlation*, IEEE Transactions on Acoustics, Speech, and Signal Processing, vol. 34, no. 5, pp. 1111-1123, Oct, 1986.
- [20] S. Haykin - *Redes Neurais - Princípios e Prática* - 2. ed. São Paulo: Bookman, 2001.
- [21] V.K. Tumiluru, P. Wang e D. Niyato - *A Neural Network Based Spectrum Prediction Scheme for Cognitive Radio* - IEEE International Conference, 2010.
- [22] Y. Tang, Q. Zhang e W. Lin - *Artificial Neural Network Based Spectrum Sensing Method for Cognitive Radio* - Wireless Communications Networking and Mobile Computing (WiCOM), 2010.
- [23] T.A.S. Sippert - *Desenvolvimento de uma Máquina de Comitê Estática para a tarefa de Classificação na Ferramenta YADMT* - Universidade Estadual do Oeste do Paraná, 2012.
- [24] K. Levenberg - *A Method for the Solution of Certain Non-Linear Problems in Least Squares*, Quarterly of Applied Mathematics 2: 164-168, 1944.
- [25] D. Marquardt - *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*, SIAM Journal on Applied Mathematics 11 (2): 431-441, 1963.
- [26] Z. Zhang e X. Xur - *Implementation of cyclic periodogram detection on VEE for cognitives* - [S.l.], 2007.
- [27] J. Proakis - *Digital Communications*, Mc-Graw Hill, New York, 1989.