

Uso do Coeficiente de Correlação para Classificação de Sinais Cicloestacionários por meio do Perfil-Alfa Reduzido

Lima, A. D. L.; Barros, C. A.; Silveira, L. F. Q.

Departamento de Engenharia de Computação e Automação
Universidade Federal do Rio Grande do Norte, Natal/RN, Brasil
{arthurl, avelino, lfelipe}@dca.ufrn.br

Resumo—Técnicas que exploram as características cicloestacionárias dos sinais de rádio têm sido largamente investigadas nos últimos anos para aplicações em sensoriamento espectral, sobretudo em ambientes de comunicação com baixa relação sinal-ruído, ou com ruído não-estacionário. Entretanto, as assinaturas cicloestacionárias de sinais modulados também têm sido investigadas, em trabalhos recentes, como medidas de classificação de formatos de modulações. Em particular, uma assinatura cicloestacionária denominada *perfil-alfa*, obtida como uma projeção da função *Spectral Correlation Density*, tem se mostrado promissora na classificação automática de modulações (AMC). Neste trabalho, propomos o uso do *perfil-alfa reduzido*, obtido por uma aproximação do perfil-alfa de sinais modulados, como medida para uma estratégia de classificação de modulações por correlação. Adicionalmente, utilizamos uma Rede Neural Artificial do tipo Multilayer Perceptron para avaliar a qualidade do classificador. O desempenho da técnica de classificação baseada em perfil-alfa reduzido e correlação foi avaliado por simulação computacional em um ambiente de comunicação caracterizado pelo ruído aditivo gaussiano branco (AWGN). Os resultados numéricos de desempenho obtidos neste trabalho demonstram a eficiência da técnica proposta.

I. INTRODUÇÃO

O avanço tecnológico dos Rádios Definidos por Software (SDR), aliado à disseminação dos sistemas de comunicação sem fio, têm motivado o desenvolvimento de técnicas inteligentes que permitam a reconfiguração automática de sistemas sem fio, de acordo com o seu ambiente de operação.

Neste contexto de comunicação inteligente, uma das tarefas desempenhadas pelo transmissor pode ser a seleção automática de um esquema de modulação em função da qualidade do canal de comunicação, com o objetivo de melhorar a sua eficiência. Essa flexibilidade na escolha do formato de modulação pode requerer do receptor do sistema a habilidade de identificar a presença de sinais na faixa de frequência de interesse e reconhecer, de forma cega, o formato da modulação digital empregado pelo sinal detectado. Essa habilidade permitiria ao receptor suportar uma grande variedade de esquemas de modulação de forma dinâmica, o que potencialmente aumentaria o desempenho do sistema.

Várias técnicas de processamento de sinais podem ser utilizadas com o objetivo de detectar a presença de sinais de comunicação em canais sem fio [1]. Adicionalmente, estudos recentes demonstram que uma dessas técnicas de processamento, baseada na extração de características cicloestacionárias é capaz tanto de detectar a presença de sinais

de comunicação com bastante precisão [2], [3], quanto de classificar o formato da modulação utilizada por esses sinais [4]–[6].

A extração de características cicloestacionárias pode ser realizada por meio do cálculo da função denominada *Spectral Correlation Density* (SCD). Essas características podem ser utilizadas na classificação de sinais modulados, após o sensoriamento, pois variam conforme o esquema de modulação. Entretanto, o uso direto dessa função como base para a tarefa de *classificação automática de modulações* (AMC) pode ser inviável, principalmente devido à grande quantidade de informação que precisaria ser manipulada pela arquitetura de classificação.

Com o objetivo de diminuir a complexidade computacional envolvida na classificação de modulações por medidas cicloestacionárias, pode-se utilizar em vez da função SCD, um sinal calculado a partir desta e que representa uma assinatura das características cicloestacionárias da portadora investigada. Esse sinal, denominado *perfil-alfa*, é obtido a partir das projeções dos valores máximos da SCD sobre um plano ortogonal ao eixo das frequências [4], [5].

Neste trabalho propomos uma assinatura cicloestacionária alternativa, denominada *perfil-alfa reduzido*, calculada como uma aproximação do perfil-alfa original, para ser utilizada como medida de classificação de formatos de modulação. Essa assinatura é utilizada por uma arquitetura de classificação simples, baseada em casamento de padrões cicloestacionários.

Apresentamos ainda uma investigação a respeito da influência do ruído e do tempo de observação do sinal sensoriado sobre o comportamento do classificador. Além disso, utilizamos uma Rede Neural Artificial (RNA) do tipo Multilayer Perceptron (MLP) para avaliar a qualidade da nossa proposta.

Os resultados obtidos foram promissores, apontando no sentido de um classificador simples e robusto, conforme sua parametrização seja realizada adequadamente.

O restante deste trabalho encontra-se organizado como segue. Na Seção II serão apresentados os principais conceitos relacionados ao sensoriamento por cicloestacionariedade. A Seção III trata de estratégias de classificação de sinais, inclusive a estratégia proposta neste artigo, que toma por base o perfil-alfa reduzido. Em seguida, os experimentos e resultados obtidos são discutidos na Seção IV e, por último, apresentamos uma síntese deste trabalho na Seção V, apontando novos caminhos de investigação.

II. CICLOESTACIONARIEDADE

Um sinal é dito cicloestacionário caso apresente parâmetros estatísticos de segunda ordem que variam periodicamente com o tempo¹. Nos sinais de comunicação, a modulação é uma transformação tipicamente geradora de características cicloestacionárias. Essas características podem ser utilizadas como uma assinatura do tipo de modulação que foi empregada no sinal. A extração dessas características pode ser conseguida por meio do cálculo das funções CAF (*Cyclic Autocorrelation Function*) ou SCD (*Spectral Correlation Density*).

Para calcular a CAF, avaliamos a correlação do sinal com uma versão deslocada dele mesmo, o que pode ser obtido pela seguinte equação [3]:

$$R_x^\alpha(\tau) \triangleq \langle x(t)x^*(t-\tau)e^{-j2\pi\alpha t} \rangle e^{j\pi\alpha\tau}. \quad (1)$$

Nessa relação, o operador $\langle \cdot \rangle$ refere-se à média temporal, o operador $*$ denota o conjugado complexo, τ corresponde ao deslocamento dado no tempo para efeito de cálculo da autocorrelação e α é a frequência de periodicidade do processo, denominada *frequência cíclica*. Observa-se que para $\alpha = 0$ a CAF é equivalente à função de autocorrelação convencional, $R_x(\tau)$.

Podemos partir inicialmente do teorema de Wiener-Khinchin, que estabelece que a Densidade Espectral de Potência $S_x(f)$ pode ser obtida por meio da transformada de Fourier da função de autocorrelação [2], como expresso por

$$S_x(f) = \int_{-\infty}^{\infty} R_x(\tau)e^{-j2\pi f\tau} d\tau. \quad (2)$$

Uma generalização dessa propriedade, denominada de Relação Cíclica de Wiener [2], permite definir a SCD como sendo a transformada de Fourier da CAF, ou seja,

$$S_x^\alpha(f) = \int_{-\infty}^{\infty} R_x^\alpha(\tau)e^{-j2\pi f\tau} d\tau. \quad (3)$$

Na próxima seção explicamos como a SCD pode ser aplicada na classificação de sinais, destacando nossa contribuição no conceito de perfil-alfa reduzido.

III. CLASSIFICAÇÃO DE SINAIS CICLOESTACIONÁRIOS USANDO PERFIL-ALFA REDUZIDO

O sensoriamento ou detecção consiste na investigação da presença de sinais em um certo canal de comunicação. Uma vez detectada a presença de algum sinal no meio, em seguida ocorre a sua classificação. Neste artigo lidamos com a classificação automática de sinais modulados.

A AMC é uma área de grande interesse nas comunicações [6], [8], podendo ser compreendida como a etapa intermediária entre a detecção de um sinal e a sua demodulação. Em geral,

¹A cicloestacionariedade pode ser generalizada para várias ordens, como descrito em [7]. Em geral, não se costuma utilizar uma cicloestacionariedade de ordem mais elevada, principalmente pelo aumento substancial da complexidade que isso representaria.

os métodos de AMC são úteis em um contexto de comunicação caracterizado pela ausência de informações *a priori* de parâmetros do sistema, tais como potência, frequência de portadora, taxa de sinalização, taxa de dados, parâmetros de temporização, dentre outros.

A função SCD pode ser aplicada nesse contexto, devido à sua habilidade em extrair informações estatísticas das amostras dos sinais analisados. As características cicloestacionárias extraídas de sinais modulados variam conforme o esquema de modulação utilizado pelo sinal, o que permite a utilização dessas características na classificação do formato de modulação do sinal sensoriado.

Além disso, a avaliação da função SCD resulta em uma superfície sobre o plano (f, α) , simétrica em f , conforme exemplificado na Figura 1 para um sinal BPSK. Devido ao custo computacional de se analisar os dados correspondentes a essa superfície, e considerando as simetrias presentes na função, em geral calcula-se uma projeção dos valores máximos da SCD sobre um plano ortogonal a f , para valores de $\alpha \geq 0$. Assim, consegue-se reduzir a complexidade da representação de três dimensões da função SCD, para apenas duas dimensões, sem que se percam informações úteis para a etapa posterior de classificação. A essa projeção dá-se o nome de *perfil-alfa* [4], [5], exemplificada na Figura 2 para um sinal BPSK.

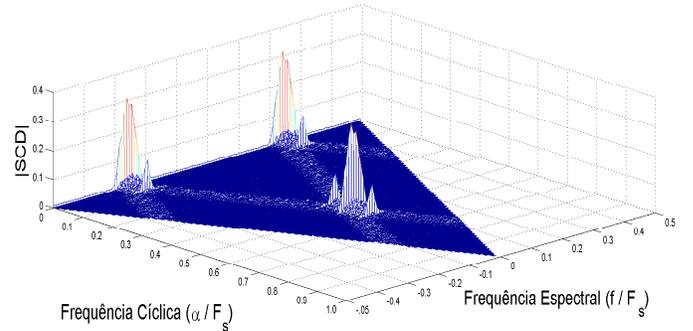


Figura 1. Assinatura da modulação BPSK obtida por meio da função SCD.

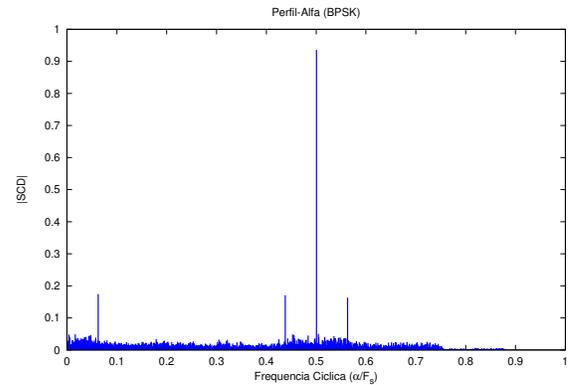


Figura 2. Perfil-alfa da modulação BPSK.

Este trabalho propõe como assinatura de formato de modulação o perfil-alfa reduzido, obtido a partir do perfil-alfa por

meio de uma operação de limiarização de seus valores. Essa operação possibilita a redução de dados indesejados no perfil-alfa original, mantendo-se, porém, no perfil-alfa reduzido, suas características principais para a tarefa de classificação de modulação.

Especificamente, o perfil-alfa reduzido, definido para $\alpha > 0$, é formado pelos valores do perfil-alfa maiores que um certo limiar λ , mantendo-se assim os picos relevantes da assinatura cicloestacionária do sinal. Os demais valores de amplitude em α são zerados, com o objetivo de eliminar variações pequenas da SCD que poderiam levar a erros em uma etapa posterior de classificação da modulação do sinal.

A Figura 3 ilustra como exemplo, o perfil-alfa reduzido de um sinal BPSK, obtido a partir do perfil-alfa ilustrado na Figura 2, após a limiarização por $\lambda = 0.05$.

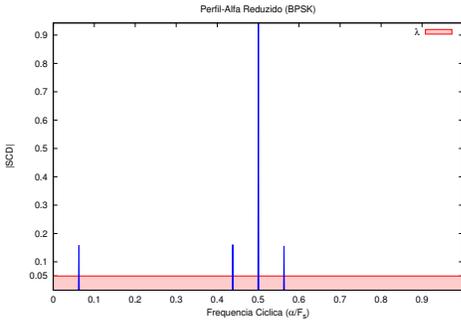


Figura 3. Perfil-alfa reduzido da modulação BPSK, com $\lambda = 0.05$.

O perfil-alfa reduzido é, então, empregado na classificação automática de modulações por um processo composto de duas etapas: pré-processamento e classificação.

Inicialmente, na etapa de pré-processamento, ilustrada na Figura 4, o perfil-alfa reduzido é calculado a partir do sinal de entrada. Na etapa seguinte, representada na Figura 5, esse perfil-alfa reduzido é utilizado para classificar o tipo de modulação empregada por meio de um casamento de padrões baseado em correlação.

O classificador dispõe de um banco de perfis-alfa reduzidos de referência, denominados *templates*, obtidos a partir de sinais modulados sem ruído. A arquitetura proposta calcula a similaridade entre o perfil-alfa reduzido do sinal de entrada e cada um dos *templates* por meio do coeficiente de correlação de Pearson, isto é,

$$\text{Corr}(X, Y^{(k)}) = \frac{\sum_n (X_n - \bar{X})(Y_n^{(k)} - \bar{Y}^{(k)})}{\sqrt{\sum_n (X_n - \bar{X})^2} \sqrt{\sum_n (Y_n^{(k)} - \bar{Y}^{(k)})^2}}, \quad (4)$$

em que X representa o perfil-alfa reduzido do sinal analisado e $Y^{(k)}$ denota o k -ésimo *template* do banco de modulações investigadas. Após calculados os coeficientes de correlação entre o perfil-alfa reduzido do sinal recebido (X) e cada um dos *templates* ($Y^{(k)}$), o *bloco decisor* verifica qual *template* produziu o maior coeficiente de correlação, decidindo, assim, pelo tipo de modulação do sinal investigado.

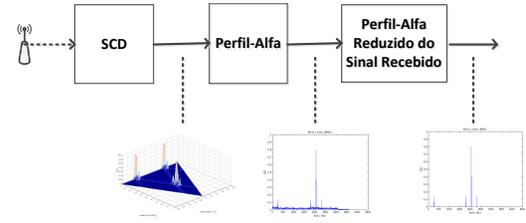


Figura 4. Etapa de pré-processamento da arquitetura do classificador por correlação.

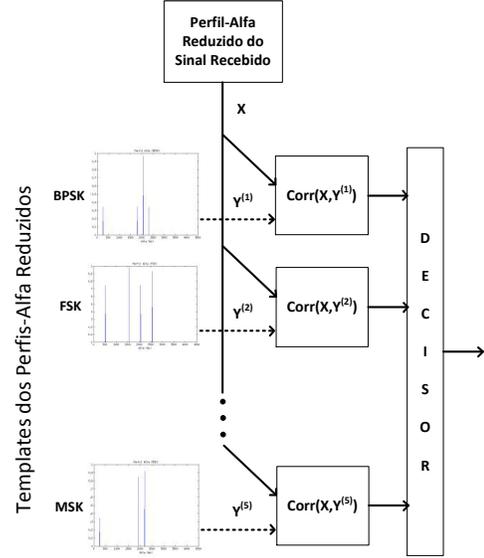


Figura 5. Etapa de classificação da arquitetura proposta.

Os parâmetros envolvidos com a classificação realizada, a influência do ruído nessa tarefa, bem como os detalhes sobre a escolha do valor do limiar λ são apresentados na próxima seção, na qual também avaliamos a qualidade do nosso classificador.

IV. EXPERIMENTOS E DISCUSSÃO DOS RESULTADOS

Para avaliar o emprego do perfil-alfa reduzido em AMC, foram realizadas simulações computacionais com cinco esquemas de modulação distintos: AM DSB-SC, BPSK, QPSK, FSK e MSK. Nas modulações digitais, utilizou-se taxa de subamostragem igual a 16, frequência de amostragem quatro vezes a frequência da portadora e filtro de formatação de pulsos do tipo raiz quadrada do cosseno elevado, com fator de rolamento (*roll-off*) $r = 0.5$. Além disso, o canal de comunicação foi modelado por um ruído aditivo gaussiano branco (AWGN), com média nula e densidade espectral de potência igual a $N_0/2$ por dimensão. Foram obtidos resultados de desempenho de classificação para uma faixa de relação sinal-ruído (SNR) entre -24 dB e 3 dB.

A estimação da função $S_x^\alpha(f)$, necessária para o cálculo do perfil-alfa reduzido, foi realizada por meio do algoritmo CPD (Cyclic Periodogram Detection), desenvolvido em [9]. O algoritmo CPD tem como entrada um sinal amostrado subdividido em L blocos, cada um deles contendo N amostras. Indiretamente, o valor de L representa o tempo de observação do sinal. Nas simulações realizadas, o tamanho dos blocos

é fixado em $N = 512$ e o número de blocos utilizados nos cálculos varia para $L = 8, 16, 32$ e 64 .

A partir dos perfis-alfa originais, calculados como uma projeção da função $S_x^\alpha(f)$ sobre um plano ortogonal a f , foram obtidos os perfis-alfa reduzidos por limiarização, com valores de limiar, variando entre $\lambda = 0.06$ e $\lambda = 0.17$. Cada perfil-alfa reduzido empregado nas simulações possui um total de 127 amostras, já descartada a amostra correspondente a $\alpha = 0$.

A classificação dos sinais foi obtida neste trabalho por similaridade entre a assinatura do sinal avaliado e os *templates* dos cinco formatos de modulação investigados. Nesse caso, o classificador calcula o coeficiente de correlação entre a assinatura do sinal avaliada e cada um dos *templates*, definindo o formato do sinal de entrada como sendo aquele associado ao maior valor de coeficiente de correlação calculado.

Este trabalho apresenta ainda como referência de desempenho um classificador baseado em RNA, do tipo MLP. Essa arquitetura foi originalmente apresentada em [4], sendo composta por 4 neurônios na camada oculta, função de ativação $\tanh(x)$ e algoritmo de treinamento do tipo *backpropagation*. Dentre os conjuntos de treinamento investigados, o que apresentou melhor resultado foi o composto por 100 exemplares de perfis-alfa originais para cada formato de modulação, obtidos em diferentes valores de SNR e de L , conforme descrito na Tabela I. O conjunto de treinamento possui $100 \times 5 \times (19 + 22 + 19 + 25) = 42500$ elementos. Neste cálculo, o valor 25 corresponde, por exemplo, ao número de valores discretos de SNR na faixa -21 dB a 3 dB investigados para o valor $L = 64$.

Tabela I

INTERVALOS DE SNR, DE ACORDO COM L , UTILIZADOS NO CONJUNTO DE TREINAMENTO DA REDE NEURAL.

L	Min. SNR (dB)	Max. SNR (dB)	Total
8	-15	3	19
16	-18	3	22
32	-18	0	19
64	-21	3	25

O cenário de avaliação foi composto por 200 exemplares de cada uma das cinco modulações investigadas, em intervalos de SNR de -24 dB a 3 dB, para 4 valores do parâmetro L ($L = 8, 16, 32$ e 64), i.e., a avaliação ocorreu com um total de $200 \times 5 \times 28 \times 4 = 112000$ exemplares de perfis-alfa reduzidos.

O desempenho dos classificadores foi avaliado para várias combinações de λ e L , parâmetro do algoritmo CPD. Esses experimentos indicam que o valor de λ a ser utilizado pela arquitetura de classificação pode influenciar significativamente o desempenho do classificador. A partir dos experimentos realizados, encontramos valores sub-ótimos para λ como uma função do tempo de observação do sinal, L , conforme descrito na Tabela II.

As Figuras 6 – 8 ilustram as taxas de classificação correta da arquitetura baseada em coeficiente de correlação para cada valor do parâmetro L avaliado. Conforme esperado, quanto maiores os valores de L e SNR, maior é a taxa de acerto do classificador proposto. Porém, é importante ressaltar que o classificador também é eficiente em baixos valores de SNR. No melhor caso investigado, que corresponde à escolha de

Tabela II

VALORES DE LIMIAR, λ , DEFINIDOS DE ACORDO COM A QUANTIDADE DE BLOCOS E TIPO DE CLASSIFICADOR.

L	$\lambda_{\text{correlação}}$	λ_{MLP}
8	0.11	0.17
16	0.09	0.12
32	0.08	0.09
64	0.06	0.07

$L = 64$, o classificador por correlação manteve 100% de acerto em todas as cinco modulações, mesmo para valores de SNRs de até -6 dB. Além disso, para os formatos de modulação AM, FSK e MSK, o classificador manteve 100% de acerto para valores de SNR de até -15 dB. Por outro lado, quanto menor for o valor do parâmetro L , relacionado ao tempo de observação do sinal a ser classificado, menor será o custo computacional da arquitetura proposta. Porém, também a sua eficiência de classificação será menor.

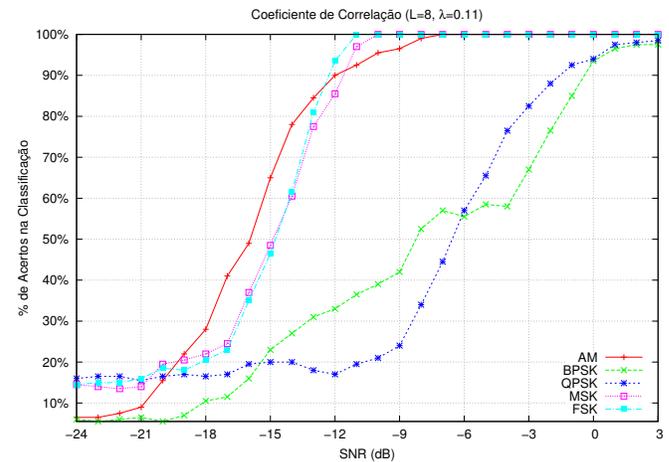


Figura 6. Resultado da classificação utilizando o coeficiente de correlação com perfil-alfa reduzido, com os parâmetros $L = 8$ e $\lambda = 0.11$.

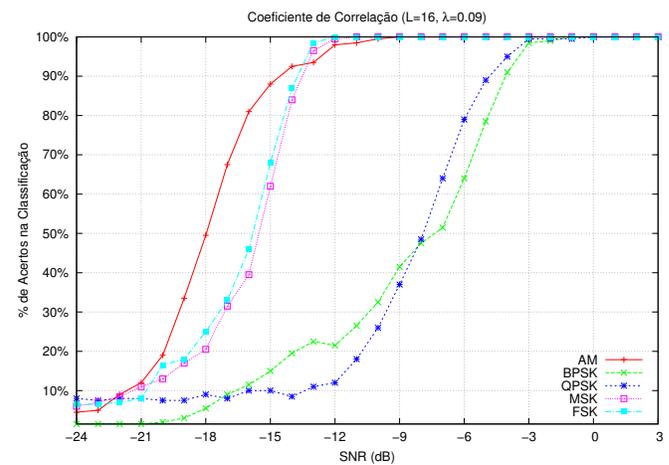


Figura 7. Resultado da classificação utilizando o coeficiente de correlação com perfil-alfa reduzido, com os parâmetros $L = 16$ e $\lambda = 0.09$.

Para uma melhor avaliação de desempenho da técnica de classificação proposta, a Tabela III apresenta as taxas de acerto

Tabela III
TAXAS DE CLASSIFICAÇÃO PARA AS ARQUITETURAS BASEADAS EM COEFICIENTE DE CORRELAÇÃO E MLP.

SNR (dB)	L	AM		BPSK		QPSK		MSK		FSK	
		Correlação	MLP								
-18	8	28	3.5	10.5	3.5	16.5	6.5	22	5.5	20.5	1.5
	16	49.5	8	5.5	6.5	9	7.5	20.5	7.5	25	4.5
	32	71	23.5	0.5	5.5	1	4	8.5	6.5	12.5	7.5
	64	95	38	1.5	21.5	1	2.5	32	13	38.5	13.5
-15	8	65	19.5	23	7.5	20	6	48.5	9.5	46.5	10
	16	88	40.5	15	33	10	6	62	21	68	30.5
	32	99	50.5	2	64.5	0.5	3.5	72.5	49.5	84	67
	64	100	76	3	68	1.5	1	98	90.5	98.5	97
-12	8	90	61	33	54	17	3	85.5	47.5	93.5	66
	16	98	80.5	21.5	65	12	5	99.5	92	100	97.5
	32	100	96	10	68.5	4.5	3	100	100	100	100
	64	100	98	28.5	79	15.5	4.5	100	100	100	100
-9	8	96.5	89.5	42	63.5	24	1	100	99	100	100
	16	100	99	41.5	73	37	6.5	100	100	100	100
	32	100	99.5	39	87.5	33	14.5	100	100	100	100
	64	100	100	76	97	84.5	48	100	100	100	100
-6	8	100	98	55.5	83.5	57	3.5	100	100	100	100
	16	100	100	64	91.5	79	25.5	100	100	100	100
	32	100	100	85	98	89	75	100	100	100	100
	64	100	100	100	100	100	99.5	100	100	100	100
-3	8	100	100	67	91	82.5	14	100	100	100	100
	16	100	100	98.5	100	99.5	70	100	100	100	100
	32	100	100	100	100	100	100	100	100	100	100
	64	100	100	100	100	100	100	100	100	100	100

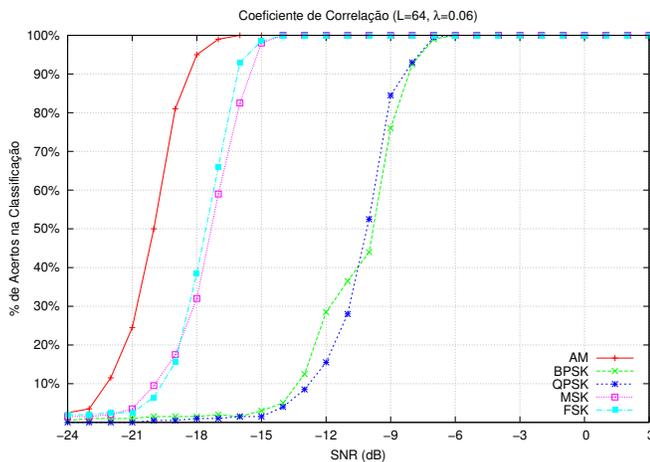


Figura 8. Resultado da classificação utilizando o coeficiente de correlação com perfil-alfa reduzido, com os parâmetros $L = 64$ e $\lambda = 0.06$.

do classificador baseado em RNA definido em [4], obtidas para o mesmo cenário de experimentos utilizado com o classificador por correlação. As células hachuradas correspondem às situações em que o classificador por correlação apresentou um desempenho igual ou superior ao classificador por RNA.

Pode-se verificar que o classificador por correlação mostra-se bastante superior ao classificador por RNA em quatro das cinco modulações, apresentando boas características de desempenho que, combinadas à sua simplicidade de implementação, posiciona-o como uma estratégia viável para a tarefa de AMC.

V. CONCLUSÕES

Neste artigo propomos a utilização de uma medida de cicloestacionariedade, denominada perfil-alfa reduzido, combinada a uma arquitetura de classificação por correlação, para

o reconhecimento automático de formatos de modulação.

Essa estratégia de classificação foi avaliada com as modulações AM DSB-SC, BPSK, QPSK, FSK e MSK em canais com ruído AWGN. Por meio de simulações computacionais, pôde-se selecionar valores sub-ótimos para o parâmetro λ da arquitetura, como função do número de amostras do sinal classificado. Os resultados numéricos de desempenho obtidos nas simulações demonstram a eficiência de classificação da técnica proposta.

Investigações adicionais de complexidade computacional serão realizadas com a evolução deste trabalho, assim como testes experimentais de desempenho em plataformas de rádio definido por software.

REFERÊNCIAS

- [1] T. Yucek and H. Arslan. A survey of spectrum sensing algorithms for cognitive radio applications. *Communications Surveys Tutorials, IEEE*, 11(1):116–130, 2009.
- [2] W. A. Gardner. Exploitation of spectral redundancy in cyclostationary signals. *Signal Processing Magazine, IEEE*, 8(2):14–36, 1991.
- [3] W. A. Gardner. *An Introduction to Cyclostationary Signals*, chapter 1. IEEE Press, New York, 1994.
- [4] A. Fehske, J. Gaeddert, and J. Reed. A new approach to signal classification using spectral correlation and neural networks. In *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. 2005 First IEEE International Symposium on*, pages 144–150, 2005.
- [5] W. C. Headley, J. D. Reed, and C. R. C. M. da Silva. Distributed cyclic spectrum feature-based modulation classification. In *Wireless Communications and Networking Conference, 2008. WCNC 2008. IEEE*, pages 1200–1204, 2008.
- [6] B. Ramkumar. Automatic modulation classification for cognitive radios using cyclic feature detection. *Circuits and Systems Magazine, IEEE*, 9(2):27–45, 2009.
- [7] W. A. Gardner. Spectral characterization of N-th order cyclostationarity. In *Spectrum Estimation and Modeling, 1990, Fifth ASSP Workshop on*, pages 251–255, 1990.
- [8] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su. Survey of automatic modulation classification techniques: classical approaches and new trends. *Communications, IET*, 1(2):137–156, 2007.
- [9] Z. Zhang and X. Xu. Implementation of cyclic periodogram detection on VEE for cognitive radio. In *Global Mobile Congress, Mobile World Congress Shanghai*, pages 1–5, 2007.