

# Classificadores de Modulação Digital em Sensoriamento Espectral de Rádio Cognitivo

Lilian C. Freitas, Aldebaro Klautau e João C. W. A. Costa

**Abstract**—Este trabalho apresenta uma avaliação de classificadores de modulação digital em sensoriamento espectral de rádio cognitivo. Para extração das características da modulação digital é utilizada análise de correlação espectral cíclica, a qual tem apresentado bons resultados, mesmo em ambientes com baixa RSR. Com base nessas características são avaliados os desempenhos de cinco técnicas de reconhecimento de padrão: naïve Bayes, árvore de decisão, KNN, SVM e redes neurais. Outra contribuição deste trabalho é a disponibilização na web de um “benchmark” para classificadores de modulação, o qual inclui as modulações AM, BPSK, BFSK, QPSK e 16-QAM, considerando a influência de um canal com ruído AWGN e com desvanecimento por multipercursos.

**Index Terms**—Rádio cognitivo, sensoriamento espectral, classificação de modulação.

## I. INTRODUÇÃO

A tecnologia de rádio cognitivo (RC) tem recebido grande interesse de pesquisas nos últimos anos, pois permite o uso do espectro de frequência de forma dinâmica, permitindo que espectros vazios sejam utilizados, sem interferir nos chamados *usuários primários*, ou seja nos usuários licenciados para operar em determinado espectro de frequência. Dessa forma, quando um usuário primário é detectado, o RC move-se para outro espectro vazio ou permanece no mesmo, alterando sua potência de transmissão ou esquema de modulação para evitar interferências. Assim sendo, o RC proporciona uma maior eficiência espectral, bem como a otimização da qualidade de serviço.

A tecnologia de RC pode ser formalmente definida como dispositivos de comunicação inteligentes capazes de modificar seus parâmetros de transmissão, tais como: frequência de operação, tipo de modulação, potência de transmissão, protocolos de comunicação e outros, baseados em interações com o ambiente em que operam [1].

Para suportar tais capacidades, o RC apresenta cinco principais módulos, os quais são: sensoriamento, gerenciamento, mobilidade e compartilhamento espectral, apresentados na Fig. 1.

Cada módulo possui funcionalidades específicas, por exemplo: o *sensoriamento espectral* tem por responsabilidade detectar espectros vazios e compartilhá-los, sem causar interferências em outros usuários. O *gerenciamento espectral*



Fig. 1. Módulos de um sistema de rádio cognitivo.

provê o meio para determinar, em tempo real, a melhor banda e a melhor frequência para fornecer os serviços desejados pelos usuários. A *mobilidade espectral* é responsável por manter a comunicação do usuário durante a transição para o melhor espectro. Enquanto que o *compartilhamento espectral* busca prover um método de escalonamento de espectro justo entre os usuários co-existent.

Neste trabalho, concentrou-se no módulo de sensoriamento espectral, mais especificamente na tarefa de classificação de modulação, que fornece uma importante informação relacionada ao ambiente de operação do rádio. Uma das aplicações da classificação de modulação é identificar e evitar interferências. Por exemplo, um sistema de RC pode configurar seus parâmetros de transmissão de acordo com a informação de modulação de um outro sistema de RC operando em um canal adjacente, tal que a interferência não alcance um nível prejudicial.

Este problema de classificação de modulação tem sido estudado desde a década de 90, cujas principais aplicações eram vigilância e atividades de inteligência, voltadas, principalmente, para área militar. Com o advento da tecnologia de RC, tais estudos ganham um novo interesse.

Nesse contexto, este trabalho apresenta uma avaliação de distintos algoritmos para classificação do tipo de modulação digital. As características utilizadas para classificação são baseadas em análise de correlação espectral cíclica, a qual apresenta bons resultados, mesmo em ambientes de baixa relação sinal ruído (RSR). Com base nessas características são avaliados os desempenhos de cinco técnicas de reconhecimento de padrão: naïve Bayes, árvore de decisão, KNN (*k-nearest neighbor*), SVM (*support vector machine*) e redes neurais. Além disso, buscou-se, neste trabalho, uniformizar a nomenclatura e estabelecer um processo de avaliação para os classificadores utilizados em sensoriamento espectral. Assim sendo, uma segunda contribuição do presente trabalho é a disponibilização de um *benchmark*, o qual inclui as modulações AM, BPSK, BFSK, QPSK e 16-QAM, considerando a influência de um canal com ruído AWGN e

Lilian Freitas e João Costa, Universidade Federal do Pará (UFPA), Laboratório de Eletromagnetismo Aplicado (www.lea.ufpa.br), Belém-PA. E-mail: {liliancf, jweyl}@ufpa.br

Aldebaro Klautau, UFPA, Laboratório de Processamento Digital de Sinais (www.laps.ufpa.br). E-mail: aldebaro@ufpa.br

Este artigo foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Pará (FAPESPA - PA).

com desvanecimento por multipercurso.

O restante deste trabalho está organizado da seguinte forma: a Seção II apresenta uma breve contextualização acerca dos classificadores de modulação digital disponíveis na literatura. A Seção III apresenta uma proposta de *benchmark* para o processo de classificação de modulação e descreve o repositório criado. A Seção IV mostra os principais conceitos referentes à análise de correlação espectral cíclica para extração de característica e sua implementação. A Seção V, discute os reconhecedores de padrões avaliados neste trabalho. A Seção VI mostra os resultados, e a Seção VII apresenta as conclusões obtidas.

## II. CLASSIFICAÇÃO DE MODULAÇÃO DIGITAL

O classificador de modulação digital é um sistema que automaticamente identifica o tipo de modulação do sinal recebido, sem o conhecimento de alguns parâmetros prévios, tais como frequência da portadora, taxa de amostragem, nível de ruído, etc. A informação do tipo de modulação pode ser utilizada em sistemas de vigilância, comunicações militares, interceptação de emissor, verificação de sinal e identificação de interferência. Em sensoriamento espectral o objetivo da classificação de modulação é basicamente, identificar e evitar a interferência com usuários primários.

O processo de classificação de modulação é constituído por dois blocos, conforme mostrado na Fig. 2: um bloco de *extração de características* e um de *reconhecedor de padrões*. O primeiro bloco (*front end*) seleciona a informação relevante para a decisão, transformando os sinais recebidos (após passar pelo canal) em um conjunto chamado de características. As características são utilizadas pelo reconhecedor de padrões (*back end*) para escolher a classe que melhor descreve a modulação do sinal.




Fig. 2. Processo de classificação de modulação.

### A. Front end: Extração de Características

A escolha das características é um passo fundamental para um bom desempenho do classificador. Esta escolha depende de fatores como *tipo de modulação* que se deseja classificar, por exemplo AM, BPSK, FSK, PSK, QAM, OFDM entre outras; e das distorções e ruídos contidos na modelagem do canal: da relação sinal ruído (RSR), da presença ou não de desvanecimento por multipercurso, de frequência de offset, etc.

Na literatura existem inúmeras publicações sobre técnicas de extração de características em classificação de modulação, tais como transformada linear da amplitude e fase do sinal recebido [2], espectrograma tempo-frequência [3],

transformada wavelet das amplitudes do sinal [4], cumulantes de alta ordem [5], algoritmos genéticos [6], análise de correlação espectral cíclica [7], entre outras. Todas estas apresentaram bons desempenhos no *setup* experimental em que foram avaliadas.

### B. Back end: Reconhecedor de Padrões

Os reconhecedores de padrões constituem uma área de estudo bastante desenvolvida. A concepção do reconhecedor de padrões para classificação de modulação pode ser formulada de forma abstrata e independente da natureza do sinal recebido.

Há inúmeras publicações sobre técnicas de reconhecimento de padrões aplicadas em classificação de modulação. Dentre as quais, pode-se citar os trabalhos que utilizam momento conjunto [2], classificador baseado em regras [3], limiar de decisão [4] e [5], SVM [8], ARBF (*Adaptive Radial-Basis Function Networks*) [9], Classificador Bayes [6], Rede Neurais [7], etc.

A Tabela I mostra exemplos de trabalhos na literatura que utilizam diferentes técnicas para extrair características e reconhecer padrões de modulação. No entanto, conforme se pode observar, todos esses são avaliados sobre diferentes condições de operação (diversas RSR, ruídos e distorções) e utilizam diferentes parâmetros de configuração do sinal modulado. Dessa forma, mostra-se difícil comparar diretamente os resultados, ou mesmo reproduzi-los.

## III. PROPOSTA DE BENCHMARK

O *benchmark* proposto consiste em padronizar os parâmetros de configuração dos sinais a serem classificados, uniformizando a forma de criação das modulações e as características do canal, sem restringir a técnica de extração de características e de reconhecimento de padrões. Dessa forma, foi criado um repositório de sinais para ser utilizado na avaliação dos classificadores de modulação chamado de *UFPAModulation*, o qual está disponível para *download* em [10].

Este repositório é composto por conjuntos de 150, 300, 750 e 1500 exemplos de cada modulação. Sendo que na construção dos sinais, adotou-se as modulações: AM, BPSK, BFSK, QPSK e 16-QAM. Configurou-se a frequência da portadora ( $f_c$ ) em 900 MHz, frequência de amostragem ( $f_s$ ) em 1.8 GHz, tempo de símbolo ( $T$ ) em 1.13  $\mu$ s. Na modelagem do canal, considerou-se o nível de RSR de -10 dB a 10 dB, com variação de 5 dB. Dois cenários foram simulados, o primeiro sendo o canal corrompido com ruído AWGN e o segundo um canal com desvanecimento por multipercurso, de acordo com o modelo COST 207 [11], com seis percursos com desvanecimento Rayleigh. As potências e atrasos dos sinais de cada percurso são mostradas na Tabela II. Além disso, a máxima frequência Doppler (FD) de 50, 150 e 300 Hz foram especificadas, representando velocidades de movimento de até 100 m/s.

As seções IV e V descrevem, respectivamente, as técnicas de extração de características e de reconhecimento de padrões

TABLE I  
EXEMPLOS DE *front end* E *back end* UTILIZADOS NA LITERATURA.

Ref.	Extração de Características	Reconhecedor Padrões	Distorção/Ruído	RSR (dB) (min:Δ:max)	Classes	treino teste
[2]	Transformada linear da amplitude e fase do sinal	momento conjunto	AWGN e freq. de offset na portadora	0:1:5	BPSK, QPSK	?/100
[3]	Espectrograma tempo-frequência	classificador baseado em regras	AWGN	0:2:12	ASK, FSK, PSK	?/400
[4]	Transformada Wavelet da amplitude dos sinais	limiar de decisão	AWGN	0:5:15	FSK, PSK, QAM	?/1000
[5]	Cumulantes de alta ordem	limiar de decisão	AWGN, freq. de offset, erro de timing	0:5:20	BPSK, QPSK 8PSK e pi/4 DQPSK	?/100
[8]	Entropia de Renyi, freq. skewness e entropia relativa	SVM	AWGN	10 dB	AM, FM AM-FM e QPSK	200/200
[9]	cumulantes de quarta e sexta ordem	ARBF	não faz referência	0:5:20	4ASK 2ASK/2PSK 4PSK e 16-QAM.	50/50
[6]	Algoritmo genético	Classificador Bayes	não faz referência	7:x:12	CW, AM, FM, SSB FSK2, FSK4, PSK4 OOK, QAM16, QAM32	400/1024
[7]	Correlação correlação espectral cíclica	Rede Neural	AWGN freq. offset	10 e 15	BPSK, QPSK FSK, MSK, AM	?/1000

TABLE II  
MODELO DE CANAL COST 207.

Nº do Percurso	Atraso(μs)	Potência(dB)
1	0.0	-2.5
2	0.3	0
3	1.0	-3.0
4	1.6	-5.0
5	5.0	-2.0
6	6.6	-4.0

que foram adotadas nos testes de validação do *benchmark* proposto.

#### IV. ANÁLISE DE CORRELAÇÃO ESPECTRAL CÍCLICA

##### A. Conceitos

Análise de correlação espectral cíclica é uma técnica para extração de características, baseada na cicloestacionariedade contida nos sinais modulados. Esta cicloestacionariedade surge devido à junção de mensagens de sinais estacionários com portadoras senoidais, trem de pulsos, códigos de repetição, ou pode ocorrer, também, como resultado de outros processos usados na geração de sinais, tais como: amostragem e multiplexação [12]. Uma importante característica desta cicloestacionariedade é que, em geral, ela não se reflete na função densidade espectral de potência, a qual é uma média quadrada do conteúdo espectral. Contudo, importantes características são refletidas na função de correlação espectral.

Assim, um sinal  $x(t)$  é definido como cicloestacionário de segunda ordem (no sentido amplo) se sua função de autocorrelação,

$$R_x(t, \tau) = E \{x(t + \tau/2)x(t - \tau/2)\} \quad (1)$$

for periódica no tempo  $t$  para cada atraso no tempo  $\Delta t$ . Esta cicloestacionariedade é examinada usando a função de autocorrelação cíclica (FAC) [13],

$$R_x^\alpha(\tau) = \lim_{\Delta t \rightarrow \infty} \frac{1}{\Delta t} \int_{-\Delta t/2}^{\Delta t/2} x(t + \tau/2)x(t - \tau/2)e^{-i2\pi\alpha t} dt \quad (2)$$

Onde  $\alpha$  é a frequência cíclica e  $\Delta t$  o intervalo de tempo.

A cicloestacionariedade de segunda ordem especifica o padrão de correlação que ocorre no espectro do sinal. Este padrão pode ser usado, equivalentemente, para examinar a cicloestacionariedade do sinal e pode ser analisado usando a função de correlação espectral (FCE) [13].

$$S_x^\alpha(f) = \lim_{\Delta f \rightarrow \infty} \lim_{\Delta t \rightarrow \infty} \frac{1}{\Delta t} \int_{-\Delta t/2}^{\Delta t/2} \Delta f X_{1/\Delta f}(t, f + \frac{\alpha}{2}) X_{1/\Delta f}^*(t, f - \frac{\alpha}{2}) dt$$

Onde,

$$X_{1/\Delta f}(t, v) = \int_{t-1/2\Delta f}^{t+1/2\Delta f} x(u)e^{-i2\pi v u} du \quad (3)$$

Representa a envoltória complexa da componente *narrow-band-pass* do sinal  $x(t)$  com frequência central  $v$  e largura de faixa  $\Delta f$ . Juntas a FAC e FCE permitem examinar a cicloestacionariedade de segunda ordem de um sinal.

Gardner [12] foi um dos pioneiros a demonstrar o poder da análise de sinais cicloestacionários quando aplicados em sistemas de comunicação sem fio. Após seus trabalhos, a análise cicloestacionária tem sido extensivamente analisada

como técnica para alcançar um enorme leque de aplicações, incluindo detecção de sinais [13], [14], classificação [15], [7], sincronização e equalização [16]. Em [14], Gardner identifica as inúmeras vantagens provenientes da análise de sinais cicloestacionários em relação as abordagens radiométricas (as quais se baseiam na medida de energia do sinal recebido). Dentre estas vantagens estão a reduzida sensibilidade a ruído e sinais interferentes, bem como a habilidade para extrair parâmetros de sinais únicos, tais como frequência da portadora e taxa de símbolos.

### B. Implementação do Algoritmo

Para extração de características por análise de correlação espectral cíclica, implementou-se, neste trabalho, o algoritmo definido em [17], de acordo com os seguintes passos:

- 1) Divide-se a sequência de amostras de entradas em  $L$  blocos, com cada bloco contendo  $N$  amostras;
- 2) Calcula-se a Transformada Discreta de Fourier das  $N$  amostras em cada bloco  $l$ ,

$$x_l[n] = 0, 1, \dots, N-1, l = 0, 1, \dots, L-1 :$$

$$X_l[k] = \sum_{n=0}^{N-1} x_l[n] \exp(-j2\pi \frac{kn}{N}), k = 0, 1, \dots, N-1;$$

- 3) Calcula-se

$$T_l^\alpha[k] = \frac{1}{N} X_l[k + \frac{\alpha}{2}] X_l^*[k - \frac{\alpha}{2}],$$

$$k = 0, 1, \dots, N-1, l = 0, 1, \dots, L-1;$$

- 4) Suaviza-se no domínio da frequência para obter a função de correlação espectral

$$S^\alpha[k] = \sum_{m=0}^{M-1} T^\alpha[kM + m] \quad (4)$$

A estimação da função de correlação espectral tem uma resolução de frequência de  $\Delta f = \frac{M}{NT_s}$ , e uma resolução de frequência cíclica de  $\Delta\alpha = \frac{1}{NT_s}$ , onde  $T_s$  é intervalo de amostragem.

Neste trabalho utilizou-se  $f_c=900$  MHz,  $f_s=1,8$  GHz,  $N=512$  e  $L=200$ .

### V. RECONHECEDORES DE PADRÃO

Neste trabalho, cinco técnicas de reconhecimento de padrões foram avaliadas: naïve Bayes, KNN, árvore de decisão, SVM linear (a qual corresponde a um perceptron) e Redes Neurais. A Fig. 3 mostra como este esquema foi implementado e as subseções seguintes apresentam uma breve descrição de tais técnicas.

#### A. Naïve Bayes

O reconhecedor de padrões Naïve Bayes pode ser visto como uma rede Bayesiana simples, na qual todos os atributos são condicionalmente independentes, dado o valor da classe. Essa suposição de independência condicional reduz a complexidade da aprendizagem, mas pode se tornar restritiva. Embora considerado um método simplista de classificação, em muitas aplicações o Naïve Bayes apresenta um bom desempenho [18] e o mesmo é útil para fins de comparações [19].

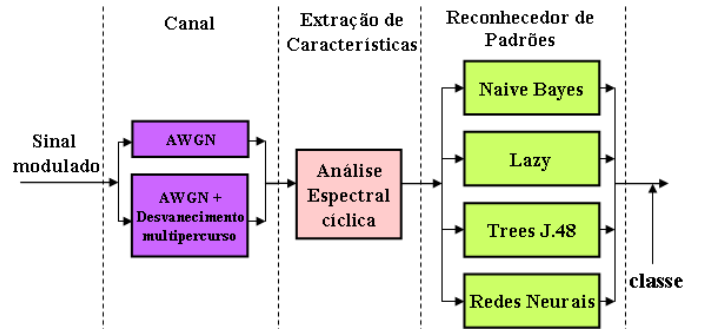


Fig. 3. Esquema do classificador de modulação implementado.

#### B. KNN

Os reconhecedores de padrões que simplesmente armazenam o conjunto de treino são chamados de “lazy” ou IBL (*instance based learning*). O KNN (*k-nearest neighbor*) [20] é um método dessa família e armazena exemplos na memória como pontos no espaço  $n$ -dimensional definido pelos  $n$  atributos que descrevem os exemplos. Para tais métodos, uma das decisões importantes é qual métrica adotar para medir a similaridade entre os exemplos. Nesse trabalho foi usada a distância Euclidiana. Baseado nessa métrica, o KNN busca os “vizinhos mais próximos” ou “nearest neighbor” para classificar novos exemplos.

#### C. Árvore de Decisão

Uma árvore de decisão é um modelo de aprendizagem de máquina preditivo, que realiza a decisão de uma nova amostra baseado no valor de seus vários atributos. Consiste em uma estrutura onde os nós não-terminais representam testes de um ou mais atributos. As ramificações desses nós são os possíveis valores que esses atributos podem assumir nas amostras observadas e os nós terminais refletem o resultado da classificação. Para classificar um novo item, é criada uma árvore de decisão baseada nos valores dos atributos do conjunto de treino. Procura-se um atributo que separe as várias amostras claramente [20]. Por exemplo, o atributo considerado como o que melhor distingue uma amostra pode ser o de maior ganho de informação. O processo é repetido iterativamente. Nesse trabalho foi utilizada a implementação de árvore de decisão do *software* Weka [21], chamada de árvore J4.8.

#### D. SVM

O SVM (*support vector machine*) engloba uma classe de algoritmos de aprendizado baseado na teoria de aprendizado estatístico, a qual implementa o princípio de minimização do risco estrutural (MRS) [22]. A idéia básica do SVM é mapear um espaço de entrada em um espaço de características. Este mapeamento pode ser feito linearmente ou não, de acordo com a função de kernel usada para mapeamento. No espaço de características, o SVM constrói hiperplanos ótimos através dos quais as classes são separadas com o objetivo de estabelecer uma margem maior entre cada classe e um erro mínimo na classificação. O hiperplano ótimo pode ser escrito como uma

combinação de poucos pontos de características, os quais são chamados de *vetores de suporte* do hiperplano ótimo. A literatura apresenta várias possibilidades de kernels para o SVM em aplicações envolvendo o reconhecimento de padrões, tais como kernel linear [23], polinomial [24], rede de função de base radial [23] e perceptron de duas camadas [22]. Nesse trabalho foi utilizado o kernel linear.

### E. Rede Neural

Uma rede neural [25] é uma estrutura de processamento de informação distribuída paralelamente na forma de um grafo direcionado. Consiste de um sistema de neurônios ligados por conexões sinápticas e dividido em: *neurônios de entrada*, que recebem estímulos do meio externo, *neurônios internos ou escondidos* e *neurônios de saída*, que se comunicam com o exterior. Possui uma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados.

## VI. RESULTADOS

Diversas simulações foram realizadas com o intuito de validar o repositório UFPAModulation; avaliar o desempenho da análise de correlação espectral cíclica como técnica para extração de características de sinais modulados; e avaliar o desempenho dos reconhecedores de padrões naïve Bayes, KNN, árvore de decisão, SVM e redes neurais.

Nesse contexto, foram gerados gráficos de complexidade da amostra (*sample complexity*) [26] para se analisar o desempenho dos classificadores com a variação do tamanho do conjunto de treino, permitindo obter o número adequado de exemplos de treino considerando a porcentagem de acertos. Na construção destes gráficos, fixou-se o conjunto de teste com 1000 exemplos de cada modulação, para uma dada RSR. Enquanto que o número de exemplos do conjunto de treino foi variado entre [50, 150, 300, 450, 750 e 1000] exemplos de cada modulação. As Figs. 4 até 7 mostram os resultados obtidos.




Fig. 4. Complexidade da amostra para RSR = -10 dB.




Fig. 5. Complexidade da amostra para RSR = -5 dB.




Fig. 6. Complexidade da amostra para RSR = 5 dB.

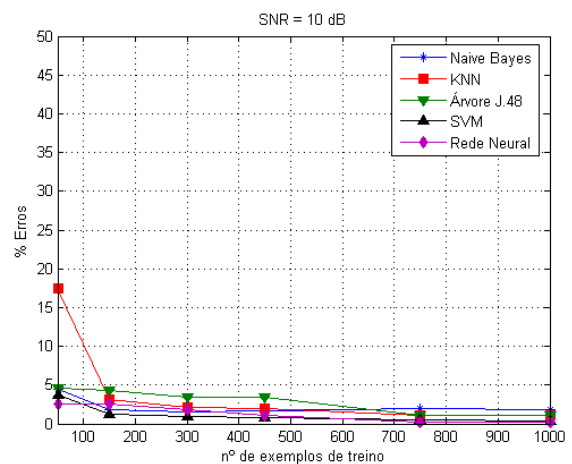


Fig. 7. Complexidade da amostra para RSR = 10 dB.

Através da análise dos gráficos de complexidade da amostra, optou-se por trabalhar com 750 exemplos de treino de cada modulação, pois este número apresentou um bom compromisso entre desempenho e recurso computacional.

Dessa forma, seguindo com a avaliação dos classificadores de modulação, dois cenários foram configurados. O Cenário I, sendo um canal corrompido com ruído AWGN e o Cenário II, um canal com desvanecimento por multipercurso.

Na configuração do Cenário I, todos os classificadores apresentaram 100% de acerto em todos os níveis de RSR que foram submetidos, mostrando a validade do repositório UFPAModulation e o bom desempenho da análise de correlação espectral cíclica para extração de características de sinais modulados.

Na configuração do Cenário II, considerou-se a transmissão dos sinais por um canal com desvanecimento por multipercurso Rayleigh, conforme descrito na Seção III. Nessas simulações, adotou-se as seguintes configurações: *naïve Bayes* com modelo de distribuição normal para os atributos numéricos; *KNN* com algoritmo de busca de vizinhos baseado na distância euclidiana; *árvore de decisão J4.8* com fator de confiança de 0.25; *SVM* com kernel linear; e *rede neural* do tipo Perceptron multicamadas, com algoritmo de aprendizagem *backpropagation*, número de neurônios na camada escondida variando entre [60, 110, 130 e 160] neurônios, taxa de aprendizagem variando entre [0.1, 0.5 e 0.9] e taxa de momento variando entre [0.1, 0.2 e 0.4]. A seleção dos parâmetros dos modelos foi feita de forma rigorosa, sem que tal seleção fizesse uso dos exemplos de teste.

As Tabelas III, IV e V apresentam os resultados obtidos para RSR de [-10, -5, 5 e 10] dB e FD de [50, 150 e 300] Hz.

TABLE III

CLASSIFICAÇÃO DE SINAIS: CANAL COM DESVANECIMENTO RAYLEIGH, FD=50 HZ, EXEM=750.

Reconhecedor de Padrões	-10dB	-5dB	5dB	10dB
NaïveBayes	94.8	83.8	87.5	97.3
KNN	73.4	75.3	88.7	98.5
Árvore J4.8	92.9	85.5	94.1	98.3
SVM	94.8	85.1	97.1	98.9
Rede Neural	89.5	84.7	95.8	99.5

TABLE IV

CLASSIFICAÇÃO DE SINAIS: CANAL COM DESVANECIMENTO RAYLEIGH, FD=150 HZ, EXEM=750.

Reconhecedor de Padrões	-10dB	-5dB	5dB	10dB
NaïveBayes	85.4	91.7	92.6	95.6
KNN	81.7	100	91.4	100
Árvore J4.8	88.9	99.0	93.1	99.7
SVM	87.3	85.2	96.2	97.8
Rede Neural	87.7	81.8	95.6	99.6

Os resultados mostram que o desempenho dos classificadores difere mais significativamente para baixas

TABLE V

CLASSIFICAÇÃO DE SINAIS: CANAL COM DESVANECIMENTO RAYLEIGH, FD=300 HZ, EXEM=750.

Reconhecedor de Padrões	-10dB	-5dB	5dB	10dB
NaïveBayes	84.9	94.6	96.2	96.1
KNN	73.5	100	100	100
Árvore J4.8	87.4	99.4	99.7	99.7
SVM	83.7	86.3	97.4	98.4
Rede Neural	82.9	92.7	99.2	99.6

RSR. O KNN mostrou-se bastante suscetível ao nível de ruído no canal em FD=50 Hz, por exemplo. No entanto, obteve um dos melhores resultados na configuração de FD= 300Hz. O naïve Bayes por ser um classificador de implementação simples, apresentou baixo custo computacional, mas seu desempenho foi limitado. A árvore de decisão J4.8 obteve um dos melhores desempenho para FD=150 Hz e 300 Hz. Para fins de visualização, a Fig. 8 mostra uma árvore J4.8 de tamanho reduzido, a qual, com o uso de apenas 4 atributos e 4 testes condicionais, a rede alcança uma taxa de erro de 98% para RSR = 10 dB e canal com FD=50 Hz. A interpretabilidade de tais árvores é bem maior do que a de SVMs, redes neurais, etc. Em algumas situações tal interpretabilidade é uma característica interessante.

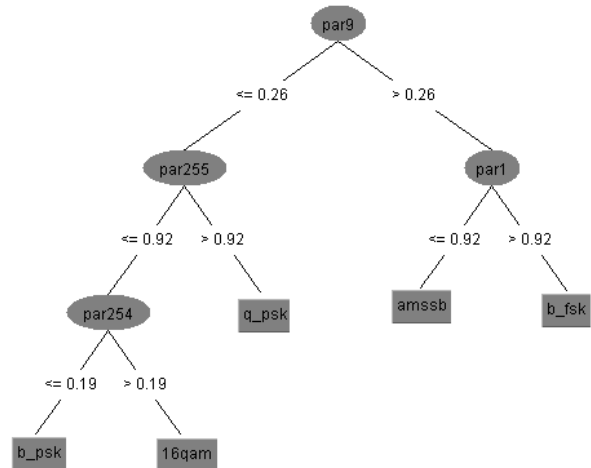


Fig. 8. Exemplo de uma árvore de decisão simples e eficiente que ilustra o alto grau de interpretabilidade das árvores.

A SVM é potencialmente um classificador de alto desempenho, mas os parâmetros do modelo devem ser obtidos com razoável precisão, o mesmo acontece com a rede neural. Nos testes realizados, onde se buscou usar um procedimento uniforme para seleção do modelo (ou seja, não investir em demasia na sintonia de um classificador específico), a SVM e a rede neural apresentaram desempenho variável conforme o valor de FD, sendo que a SVM obteve o melhor resultado para FD=50 Hz e a rede neural esteve entre os classificadores de melhor desempenho em FD=150 Hz.

## VII. CONCLUSÕES

Neste trabalho foi apresentada uma avaliação de algoritmos para a classificação de modulação digital para sensoriamento espectral de rádio cognitivo. Como estudo de caso foi implementado um classificador com base na análise de correlação espectral cíclica e em cinco técnicas de reconhecimento de padrão: naïve Bayes, árvore de decisão, KNN, SVM e redes neurais. Sendo classificadas as modulações AM, BPSK, BFSK, QPSK e 16-QAM, sob a influência de duas configurações de canal: uma com ruído AWGN e outra com desvanecimento por multipercurso.

A análise de correlação espectral cíclica implementada se mostrou uma técnica eficiente para extração de características, pois em um canal com ruído AWGN, os resultados mostraram 100% de acerto. No entanto, em uma configuração com desvanecimento por multipercurso os classificadores avaliados se mostraram suscetíveis à influência de FD, mas ainda mantiveram bons desempenhos.

Assim sendo, espera-se que o *benchmark* proposto sirva como ponto de partida para pesquisadores e profissionais da área que queiram comparar resultados de forma sistemática. O mesmo está disponibilizado na web, em [10] e será continuamente aperfeiçoado para torná-lo o mais próximo possível das condições práticas nas quais o sensoriamento espectral é utilizado em rádio cognitivo.

## REFERENCES

- [1] I.F. Akyildiz, W. Lee, M. C. Vuran, and S. Mohanty, "Next generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer Networks: The International Journal of Computer and Telecommunications Networking*, vol. 50, pp. 2127–2159, Sep 2006.
- [2] D. Shimbo; I. Oka; S. Ata., "An improved algorithm of modulation classification for digital communication signals based on wavelet transform," *Radio and Wireless Symposium, 2007 IEEE*, vol. 03, pp. 567–570, Jan 2007.
- [3] Tan Jo Lynn and A.Z. Sha'amerr, "Automatic analysis and classification of digital modulation signals using spectrogram time frequency analysis," *International Symposium on Communications and Information Technologies, 2007. ISCIT '07.*, pp. 916–920, Oct. 2007.
- [4] Ling-Ling Meng; Xiu-Jie Si, "An improved algorithm of modulation classification for digital communication signals based on wavelet transform," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 03, pp. 1226–1231, Nov 2007.
- [5] C. Song F. Chen L. Shen, S. Li, "Automatic modulation classification of mpsk signals using high order cumulants," *8th International Conference on Signal Processing, 2006*, vol. 01.
- [6] S. Brown T. McKinney N. Kim, N.Kehtarnavaz, "Hierarchical classification of modulation signals," *Proceedings of the 5th Biannual World Automation Congress*, vol. 14, pp. 243– 248, Dez. 2002.
- [7] J.H. Reed A. Fehske, J. Gaeddert, "A new approach to signal classification using spectral correlation and neural networks," *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005*, pp. 144–150, Nov 2005.
- [8] S. Kadambe; Q. Jiang, "Classification of modulation of signals of interest," *Digital Signal Processing Workshop, 2004 and the 3rd IEEE Signal Processing Education Workshop. 2004 IEEE 11th*, pp. 226–230, Aug 2004.
- [9] He Tao; Jing Xiaorong, "Modulation classification using arbf networks," *7th International Conference on Signal Processing, ICSP 2004.*, vol. 03, pp. 1809 – 1812, Aug. 2004.
- [10] João C. W. A. Costa Lilian C. Freitas, Aldebaro B. R. Klautau, "Repositório para classificação de sinais modulados," <http://www.lea.ufpa.br/lilian/cognitiveradio/datasets/ciclostationary/>, 2008.
- [11] M. Failli (chairman) and COST 207 Management Committee, "Digital land mobile radio communications : Final report," Tech. Rep., Luxembourg: Commission of the European Communities, 1989.
- [12] W. A. Gardner and C. M. Spooner, "Measurement of spectral correlation," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. ASSP-34, NO. 5, pp. 1111– 1123, Oct 1986.
- [13] W.A.Gardner, "Signal interception: a unifying theoretical framework for feature detection," *IEEE Transactions on Communications*, vol. 36, Issue 8, pp. 897 – 906, Aug 1988.
- [14] W. A. Gardner and C. M. Spooner, "Signal interception: Performance advantages of cyclic-feature detectors," *IEEE Transactions on Communications*, vol. 40, pp. 149–159, Aug 1992.
- [15] W. A. Gardner, "Spectral correlation of modulated signals: Part ii-digital modulation," *IEEE Transactions on Communications*, vol. 35, n°6, pp. 595–601, Jun 1987.
- [16] W. A. Gardner, "Exploitation of spectral redundancy in cyclostationary signals," pp. 14–36, Apr 1991.
- [17] Z. Zhang and X. Xu, "Implementation of cyclic periodogram detection on vee for cognitive radio," *Global Mobile Congress (GMC'2007)*, pp. 1–5, Oct 2007.
- [18] H. Zhang, "The optimality of naïve bayes," in *Proceedings of the 17th International FLAIRS conference (FLAIRS2004)*.
- [19] B. Zadrozny and C. Elkan, "Obtaining calibrated probability estimates from decision trees and naïve bayesian classifiers," in *ICML*, 2001, pp. 609–616.
- [20] I. Witten and E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*, Morgan Kaufmann, 2nd Edition, 2005.
- [21] The University of Waikato, "Weka 3 - data mining with open source machine learning software in java," <http://www.cs.waikato.ac.nz/ml/weka/>, 2008.
- [22] S. Haykin, *Support vector machines, Em Neural Networks: A Comprehensive Foundation*, cap. 6, Prentice Hall, 1999.
- [23] G. Rätsch K. Tsuda K. Müller, S. Mika and B. Schölkopf, "An introduction to kernel-based learning algorithms," *IEEE Transactions on Neural Networks*, vol. 12, n° 2, pp. 181–202, March 2001.
- [24] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," in *Data Mining and Knowledge Discovery 2*, 1998, pp. 121–167.
- [25] C. Bishop, *Neural networks for pattern recognition*, Oxford Univerisy Press, 1995.
- [26] T. Hastie, R. Tibshirani, and J. Friedman, *The elements of statistical learning*, Springer Verlag, 2001.