

Redes cognitivas: Caracterização do espectro usando redes bayesianas

Rafael de Souza Mendes¹

*Programa de Pós Graduação em Ciência da Computação
Universidade Federal de Santa Catarina
Florianópolis, Brasil*

Carlos Becker Westphall²

*Programa de Pós Graduação em Ciência da Computação
Universidade Federal de Santa Catarina
Florianópolis, Brasil*

Abstract

This article presents the use of Bayesian networks and probabilistic inference in cognitive radios, applied to the characterization of the electromagnetic spectrum, allowing the adaptation of this characterization in function of specific local and temporal characteristics. Unifying data states (zero or one) and the states of the spectrum (presence of primary user, noise, silence etc), Bayesian inference associated with the proposed model of cognition, provides a range of information about the spectrum that serves both for the MAC layer as for the control layer, serving to adjust the cognitive radio parameters according to statistics from the spectrum behavior.

Keywords: cognitive networks, cognitive radio, Bayesian networks, spectrum characterization, spectrum decision

1 Introdução

O ensejo para a busca de um aproveitamento mais hábil do espectro e, por conseguinte, formulação do conceito de redes cognitivas, teve início com o relatório do FCC [FCC 2002] que determinou que o problema de escassez do espectro era na realidade um problema de alocação do espectro, pois, a maior parte do espectro é reservada a usuários que não utilizam na totalidade a

1 Email:rafaeldesouzamendes@gmail.com

2 Email:westphal@inf.ufsc.br

largura de banda alocada. Um exemplo típico é a transmissão de televisão, sistema este que possui uma ampla faixa de Very High Frequency (VHF) e Ultra High Frequency (UHF) licenciada, porém, na maioria dos municípios poucas emissoras de TV atuam, levando a uma subutilização da largura de banda alocada.

Em seguida à emissão do relatório do FCC, o Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) deu início ao incentivo de publicações que estimulassem a utilização mais inteligente do espectro por parte de equipamentos computacionais como o clássico [Akyildiz et al. 2006]. Apesar do conceito de rede cognitiva ser difuso e aplicado a várias tecnologias de rede, como explanado em [Thomas et al. 2005], consideraremos aqui que uma rede cognitiva é uma rede formada por equipamentos dotados de rádios capazes de perceber o meio onde estão atuando e reconfigurar-se afim de não causar interferências a usuários primários (PUs). Em adjacência ao conceito de rede cognitiva, começaram a ser pesquisadas as características necessárias aos equipamentos para que estes pudessem chamar-se “cognitivos”. Grandes contribuições foram feitas pelo Broadband Wireless Networking Lab [Akyildiz] e pela equipe do Dr. Ian F. Akyildiz. Em [Akyildiz et al. 2006], Alkyildiz postula que um rádio cognitivo deve ser capaz de promover:

- sensoriamento do espectro - detectando segmentos de espectro não utilizados e compartilhando espectro sem causar interferência destrutiva a outros usuários;
- gerenciamento do espectro - capturando a melhor faixa de espectro disponível afim de atingir os requisitos de comunicação;
- mobilidade no espectro - mantendo a comunicação mesmo durante a transição da comunicação para outras faixas de espectro;
- compartilhamento do espectro - providenciando um método de organização confiável afim de coexistir em meio a outras redes cognitivas.

Estes conceitos foram consolidando-se ao longo de vários trabalhos da comunidade científica como [Akyildiz et al. 2006], [Akyildiz et al. 2009b] e [Akyildiz et al. 2009a], ficando fortemente associados ao conceito de rádios cognitivos (CR), conceito este que, na maioria dos artigos, acaba por sobressair-se ao conceito de redes cognitivas (CN).

A fim de contribuir para o desenvolvimento das redes cognitivas, atuando na melhoria dos rádios cognitivos, o presente trabalho propõe a aplicação de redes bayesianas (RBs) no sensoriamento do estado do canal de forma a utilizar este modelo tanto como mecanismo de cognição como estrutura de dados contentora do estado do espectro.

Com o objetivo de apresentar um modelo probabilístico de detecção dos estados do canal, o presente trabalho está disposto de forma que: na seção 2 serão apresentados os trabalhos correlatos; na seção 3 será descrito o conceito

de fusão dos dados com o estado do espectro; na seção 4 será estudado o processo que projeta os estados dos sensores de um hardware hipotético, no domínio dos estados do canal; na seção 5 será analisado um possível modelo de RB que sirva para a conversão dos estímulos oriundos dos sensores na respectiva caracterização desejada; na seção 6 serão apresentados os resultados empíricos obtidos através do modelo probabilístico: e, por fim, na seção 7 será feita a conclusão do trabalho.

2 Trabalhos correlatos

Vários trabalhos, principalmente os que abordam a detecção de PUs no espectro, apresentam abordagens probabilísticas para tal efeito. A abordagem bayesiana, contudo, é mais rara nos trabalhos científicos que abordam redes cognitivas e mais rara ainda é a utilização das RBs para fins de caracterização do espectro.

Dentre os trabalhos que se valem de uma abordagem probabilística, é interessante destacar [Atapattu et al. 2011], que apresenta um método de sensoriamento cooperativo do espectro. Outros trabalhos como [Zhou et al. 2010] e [Ganesan and Li 2005], já haviam definido métodos cooperativos de sensoriamento, porém, em [Atapattu et al. 2011] é definida uma classificação para detecção cooperativa de PUs em *fusão de dados e fusão da decisão*. No primeiro caso, cada CR amplifica o sinal recebido e submete a informação para uma central de fusão, onde os dados são então analisados e uma determinada inferência acerca da presença de PUs é realizada. No segundo caso, cada CR decide sobre a presença ou ausência de PU no espectro e então submete o resultado à central de fusão, onde será inferido um resultado por uma das seguintes regras: E, OU ou maioria. Os resultados apresentados em [Atapattu et al. 2011] são sobretudo importantes pois serão utilizados como base para a premissa da existência de um método de detecção cooperativo e, como será visto na seção 5, da possibilidade de ajustar a caracterização do espectro em cada CR, a partir deste método cooperativo.

Ainda, um outro artigo que possui grande influência sobre o presente trabalho é [Lee and Akyildiz 2011], que apresenta um framework para decisão no espectro. Nele, aborda-se a caracterização do espectro e apresenta-se o conceito de *capacidade* $C_i^{CR}(k)$, que define a capacidade esperada de um CR k na faixa i e é demonstrado em 1, em que η_i é a eficiência do sensoriamento, definido em [Lee and Akyildiz 2008]; τ representa o atraso no chaveamento entre faixas de espectro; T_i^{OFF} é o tempo esperado em que a faixa de espectro i permanece sem transmissão de PU. Por fim, $c_i(k)$ é a capacidade do usuário k na faixa i medida em (bits/seg/Hz).

$$(1) \quad C_i^{CR} = \frac{T_i^{OFF}}{T_i^{OFF} + \tau} \cdot \eta_i \cdot c_i(k)$$

Outra importante observação presente em [Lee and Akyildiz 2011] é a respeito da não existência de trabalhos sobre decisão no espectro passíveis de comparação dos resultados obtidos. Esta observação é importante pois justifica a ausência de comparação dos resultados do presente trabalho com os resultados de outros artigos que abordam caracterização do espectro.

Por fim, um outro trabalho que deve ser citado é [Quer et al. 2010], onde é apresentado um mecanismo de aprendizagem da topologia e das probabilidades *a priori* para a configuração de parâmetros das camadas MAC e TCP. Assim, a principal diferença deste artigo e o presente trabalho é o fato de que este trabalho aborda a aplicação de redes bayesianas, sem aprendizagem da topologia, aplicado à camada de rádio (física).

3 Fundindo dados com estados do espectro

O primeiro conceito a ser introduzido é o conceito de estado do canal, que representa um único conjunto de estados para classificação do sinal percebido na banda analisada. Este conjunto de estados é aqui apresentado como a fusão dos estados dos dados e dos estados do espectro, produzindo um conjunto de estados do canal, como é apresentado na figura 1.

Este conceito foi apresentado pela primeira vez em [Mendes et al. 2010], em que era apresentada uma sequência destes estados do canal que permitiria o reconhecimento desta sequência por expressões regulares. Uma vez que a sequência dos estados fosse reconhecida, poderia ser classificada e encaminhada ao mecanismo apropriado para a interpretação da mensagem: o mecanismo de tratamento dos dados ou o mecanismo de análise e estatística do espectro. Contudo, a ideia da utilização deste mecanismo de fusão de dados mostrou-se mais aderente à caracterização do espectro que ao sensoriamento.

Este mecanismo deve ficar na camada de controle responsável por operar o rádio cognitivo. Tal camada pode ser identificada na figura 2, que mostra a arquitetura proposta em [Mendes et al. 2010], na qual existe um controle que recolhe estatísticas e informações de todas as camadas para então ajustá-las conforme a necessidade.

A fusão dos estados de dados e dos estados do espectro apresenta valor ao unificar a aquisição de informação, permitindo desta forma o armazenamento e tratamento dos dados sobre os estados dos canais, afim de obter a caracterização do espectro através de medidas de síntese e estatísticas sobre as mudanças de estado dos canais ao longo do tempo.

Os dados são obtidos através do modem, componente comum a qualquer equipamento de rede que interfaceie com a camada física. Os demais estados do espectro são obtidos através dos demais sensores que compõem um CR, como sensor de SNR, sensor de potência e sensor de PU. Este conjunto pode ser observado na figura 3, apresentado na forma de esquema.

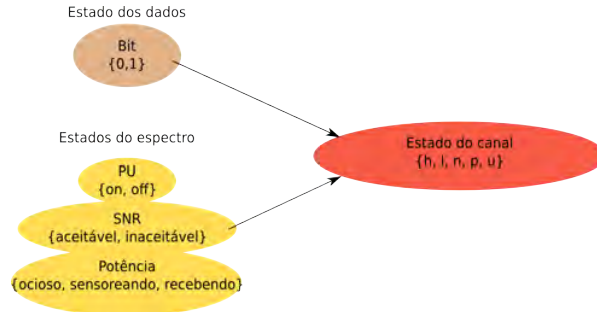


Figure 1. Fusão de dados e estados do canal.

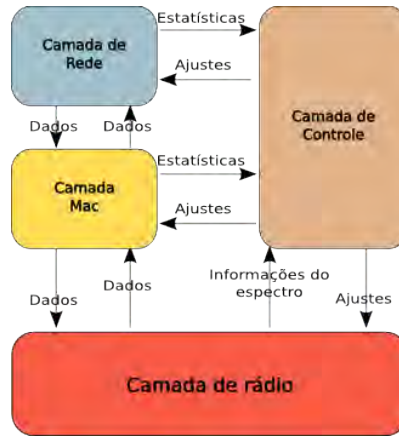


Figure 2. Arquitetura parcial a ser suportada por um framework para operação do rádio.

Formalizando-se então o modelo, cada sensor é representado por uma variável aleatória discreta que pode assumir um conjunto finito de valor, da mesma forma que o estado do canal. Assim, o estado do canal torna-se função dos sensores. A definição completa das variáveis aleatórias e seus possíveis valores pode ser vista nas listagens a seguir:

- estados do sensor de bit = $\{0,1\}$;
- estados do sensor de SNR = $\{\text{aceitável, inaceitável}\}$;
- estados do sensor de potência = $\{\text{ocioso, sensoreando, recebendo}\}$;
- estados do sensor de PU = $\{\text{on, off}\}$;

Com efeito, para descrever os estados do canal é proposto conjunto de estados $EC = \{n, l, h, u, p\}$, onde:

- n - sem sinal, correspondente ao rádio estar ocioso (no signal);
- l - bit baixo, correspondente a um bit 0 (low);
- h - bit alto, correspondente a um bit 1 (high);
- u - sinal desconhecido, correspondente à incapacidade de decidir quanto a

- ruído ou interferência (unknow);
- p - PU, correspondente à detecção de atividade de um PU.




Figure 3. Hardware hipotético para elaboração da RB.

A partir da adição da dimensão temporal aos estados assumidos por cada sensor, obtemos uma série temporal para cada um deles, como demonstrado na figura 4, para então formar a série temporal dos estados do canal. Com base nesta última série temporal, será possível inferir probabilidades e medidas de síntese importantes, como $P(T_i^{ON})$ e $P(T_i^{OFF})$, que descrevem a probabilidade de haver ou não haver atividade de PU em i ; $P(U_i)$ e $P(\neg U_i)$, que descreve a probabilidade do canal estar em um estado desconhecido (interferência ou ruído) ou não, podendo ser utilizado como medida de qualidade de um determinado canal; ou ainda $P(h)$ e $P(l)$, que descreveriam a tendência dos dados e poderiam servir para caracterizar o espectro de acordo com o tipo de tráfego. Este tema será mais bem aprofundado na seção 4.



Figure 4. Fusão das séries temporais dos sensores formando a série temporal de estados do canal.

4 Síntese dos estados do canal, a base para a modelagem probabilística

Uma vez estabelecido o conceito dos estados do canal, surgiu a necessidade de construir um mecanismo que efetivamente convertesse sequências de estímulos dos diversos sensores, em uma sequência única de percepções temporais acerca do canal sensoriado. Para tanto, com base no hardware hipotético descrito na figura 3 e diante dos vários algoritmos possíveis para o mapeamento proposto, foram escolhidas as RBs para tal mapeamento. Por valerem-se de uma base probabilística para realização de suas inferências, compatível com a maioria dos artigos que abordam as CNs, as RBs podem ser ajustadas e reajustadas de

acordo com estatísticas do espectro, tornando-se mais sensíveis às mudanças de contexto que outros modelos como redes neurais artificiais.

No modelo proposto cada sensor do hardware é mapeado como sendo um nó da RB, como pode ser observado na figura 5. E então os estados de cada sensor são lançados como evidências em seus respectivos nós, gerando no nó de saída um vetor de probabilidades sobre cada possível estado do canal. Ainda, como a caracterização se dá especificamente para um determinada faixa de espectro i , a RB modelada apresenta um nó *Canal*, que irá tomar como evidência o canal que está sendo caracterizado.

Com isto, as diferentes combinações dos estados dos quatro sensores, podem ser expressas através de um único conjunto de símbolos, ficando a cargo das probabilidades *a priori* da RB, estabelecer a correlação entre os estados dos sensores e a conclusão a ser tirada acerca do estado do canal.

Uma vez aplicada a inferência bayesiana o canal será considerado no estado *ec*, sendo *ec* aquele que apresentar a maior probabilidade no nó de saída *EstadoDoCanal*, como mostra a figura 5.

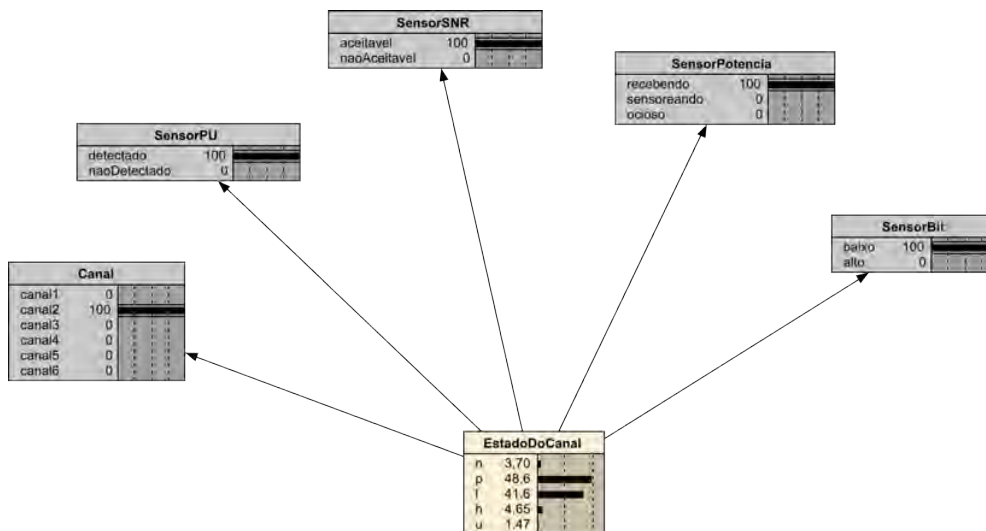


Figure 5. Inferência bayesiana a partir do estado dos sensores.

Desta forma, a cada mudança no estado dos sensores, ocorre uma atualização da RB, podendo produzir uma alteração no estado do nó de saída. Havendo alteração, o novo estado é associado ao registro do tempo instantâneo em que ocorreu a alteração, e então lançado em uma estrutura de dados que armazena o estado inferido acerca do canal e o instante em que este estado teve início, formando uma sequência de intervalos de estados, como demonstrado na figura 6. Uma vez os estados enfileirados e a informação armazenada, é possível após um intervalo de tempo Δt realizar a análise e caracterização do canal, inferindo a presença de PUs, T^{ON} , T^{OFF} etc.




Figure 6. Sequência temporal de estados produzida pela inferência bayesiana.

Um ponto que cabe destacar é a inclusão dos dados na sequência de estados do canal, pois, mesmo os dados sendo codificados em muitas modulações, é possível identificar o início e o fim do recebimento de um frame de dados e então distribuir seus dados em uma sequência temporal.

5 Aprendizagem das probabilidades *a priori* e caracterização do espectro

Uma vez que dispomos de dados históricos acerca das percepções do espectro, de um modelo probabilístico ajustável para a caracterização do espectro e de um método cooperativo - comprovadamente mais confiável que percepções individuais de cada CR ([Atapattu et al. 2011], [Jing and Xu 2009]) -, podemos ajustar nosso modelo probabilístico com base no método cooperativo de sensoreamento do espectro para promover caracterizações individuais mais confiáveis.

Para tal, cada probabilidade *a priori* que compõe a RB, como listado na tabela 5 configurada inicialmente com valores padrão, determinados arbitrariamente, e deve ser atualizada de acordo com as correlações históricas do estado de cada variável aleatória.

Para fins de atualização da RB, o resultado do método cooperativo também será modelado como uma variável aleatória discreta e temporal que pode assumir dois estados distintos: *ON/OFF*.

Assim, apropriando-se das séries temporais *SensorPU*, *EstadoDoCanal* e *ResultadoMetodoCoop*, a atualização da primeira probabilidade *a priori* dar-se-á pelo conjunto de equações 2.

Table 1 : Lista de probabilidades *a priori* que compõem a RB.

| Probabilidade | Descrição |
|--------------------------------------|------------------------------------------------------------------------------------------|
| $P(\text{canal}_i ec_x)$ | probabilidade de um dado canal ser i dado que o canal encontra-se no estado x |
| $P(\text{sensor}PU_p ec_x)$ | probabilidade de o sensor de PU assumir o estado p dado um estado do canal x |
| $P(\text{sensor}SNR_s ec_x)$ | probabilidade de o sensor de SNR assumir o estado s dado um estado do canal x |
| $P(\text{sensor}Potencia_{pw} ec_x)$ | probabilidade do sensor de potência assumir o estado pw dado um estado do canal x |
| $P(\text{sensor}Bit_b ec_x)$ | probabilidade de o sensor de bit assumir o estado b dado o estado do canal x |

$$\begin{aligned}
 (2) \quad & P(\text{sensor}PU_{detec}|ec_p) = \frac{t(\text{detec},ON)}{t(ON)} && \text{detecção correta} \\
 & P(\text{sensor}PU_{detec}|ec_n) = \frac{t(\text{detec},OFF)}{t(OFF) \cdot 3} && \text{falso positivo} \\
 & P(\text{sensor}PU_{detec}|ec_u) = \frac{t(\text{detec},OFF)}{t(OFF) \cdot 3} && \text{falso positivo} \\
 & P(\text{sensor}PU_{detec}|ec_h) = \frac{t(\text{detec},OFF)}{t(OFF) \cdot 6} && \text{falso positivo} \\
 & P(\text{sensor}PU_{detec}|ec_l) = \frac{t(\text{detec},OFF)}{t(OFF) \cdot 6} && \text{falso positivo} \\
 & P(\text{sensor}PU_{-detec}|ec_p) = \frac{t(-\text{detec},ON)}{t(ON)} && \text{falso negativo} \\
 & P(\text{sensor}PU_{-detec}|ec_n) = \frac{t(-\text{detec},OFF)}{t(OFF) \cdot 3} && \text{correto negativo} \\
 & P(\text{sensor}PU_{-detec}|ec_u) = \frac{t(-\text{detec},OFF)}{t(OFF) \cdot 3} && \text{correto negativo} \\
 & P(\text{sensor}PU_{-detec}|ec_h) = \frac{t(-\text{detec},OFF)}{t(OFF) \cdot 6} && \text{correto negativo} \\
 & P(\text{sensor}PU_{-detec}|ec_l) = \frac{t(-\text{detec},OFF)}{t(OFF) \cdot 6} && \text{correto negativo}
 \end{aligned}$$

onde todas as equações valem-se do resultado do método cooperativo para atualizar a probabilidade de o sensor de PU identificar um PU. O aparecimento dos números 3 e 6 no denominador das equações subsequentes deve-se ao fato de que os métodos de detecção cooperativos identificam apenas a presença ou ausência de PU, por isso, no caso de um falso positivo, a probabilidade de ser um determinado estado do canal deve ser dividido por 3 (n , u ou dado) e por 6 no caso de dado (h ou l). As demais probabilidades *a priori* serão atualizadas

da mesma forma, apenas substituindo-se o sensor e os estados de cada sensor.

Deste modo, ao final do processo de avaliação do histórico e refinamento da RB utilizando-se o método cooperativo de detecção como o real estado do espectro no intervalo Δt , obteremos a RB de cada CR que compõe a CN com resultados individuais mais próximos dos resultados do método cooperativo. Ainda, como será aplicada a atualização das probabilidades *a priori* sobre a tabela que correlaciona os canais com os estados do espectro, ao lançarmos uma evidência no nó de saída (*EstadoDoCanal*), obteremos a distribuição das probabilidades de cada canal dado um determinado estado do canal, como mostra a figura 7. Este mecanismo serve como forma de caracterização do espectro, pois podemos descobrir qual canal possui maior ou menor probabilidade de apresentar a presença de um PU, ou ainda a maior ou menor probabilidade de apresentar um estado desconhecido (*u*) que provavelmente implique perda de bits.

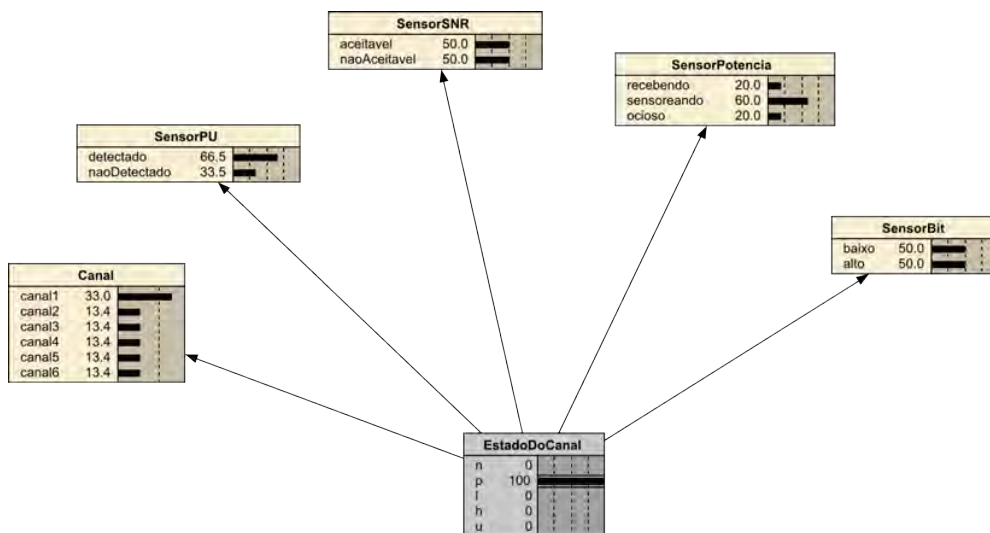


Figure 7. Inferência bayesiana a partir do estado do canal.

6 Simulações

O experimento realizado consiste na comparação de desempenho da porcentagem de detecções corretas e falsos positivos para duas RBs distintas, uma com as probabilidades *a priori* fixas, definidas arbitrariamente, e outra com as probabilidades *a priori* ajustadas dinamicamente, segundo os critérios apresentados na seção 5.

Para a realização das simulações e experimentos, foram gerados dados aleatórios considerando cada nó da RB com uma variável aleatória discreta. Ainda foi acrescido às listas de variáveis a serem geradas o resultado de um

Table 2 : Variáveis aleatórias discretas geradas randomicamente.

| Variável aleatória | valores |
|-----------------------|----------------------------------|
| <i>Canal</i> | {1, 2, 3, 4, 5, 6} |
| <i>SensorPU</i> | {detectado, naoDetectado} |
| <i>SensorSNR</i> | {aceitavel, naoAceitave} |
| <i>SensorPotencia</i> | {recebendo, sensoreando, ocioso} |
| <i>SensorBit</i> | {baixo, alto} |
| <i>DetecaoCoop</i> | {detectado, naoDetectado} |

Table 3 : Fatores controlados pelo experimento.

| Variável Aleatória | Valores |
|----------------------|--------------------|
| % detecções corretas | 99%, 95%, 90%, 80% |
| % falsos positivos | 20%, 10%, 5%, 1% |

método cooperativo que serve como referência para o *SensorPU*. Desta forma a lista de variáveis aleatórias e seus respectivos valores são apresentados na tabela 6.

Ainda, foi considerada para a experimentação a combinação dos fatores apresentados na tabela 6. Desta forma deu-se a experimentação com um montante de 100 testes, de 100 amostras cada, para cada uma das combinações dos possíveis valores dos fatores da tabela 6, resultando em uma amostra total de 160000 para cada uma das RBs testadas.

Foram então executadas as simulações realizando a inferência bayesiana e comparando seu resultado com o resultado do método cooperativo, gerado randomicamente, para a composição de uma nova porcentagem detecções corretas e falsos positivos. No primeiro experimento, a RB não sofreu nenhum tipo de atualização em tempo de execução, apresentando resultados listados na tabela 6.

Como pode-se observar, a RB sem qualquer atualização, apresenta os mesmos resultados que os dados gerados. Isso deve-se ao fato de que suas probabilidades *a priori* foram configuradas de forma a gerar um estado do canal p toda vez que o *SensorPU*.

No segundo experimento, a RB realizou uma primeira inferência e em seguida teve suas probabilidades *a priori* atualizadas de acordo com a série histórica dos dados. Partiu-se então para uma segunda inferência e então comparação para a composição da nova porcentagem de detecções corretas e falsos positivos. Neste segunda inferência porém, adicionadas correlações

Table 4 : Dados gerados vs. inferência bayesiana.

| Dados gerados | | Inferências da bayesiana | |
|--------------------|------------------|--------------------------|------------------|
| detecções corretas | falsos positivos | detecções corretas | falsos positivos |
| 0,990 | 0,207 | 0,990 | 0,207 |
| 0,990 | 0,106 | 0,990 | 0,106 |
| 0,989 | 0,046 | 0,989 | 0,046 |
| 0,993 | 0,009 | 0,993 | 0,009 |
| 0,953 | 0,207 | 0,953 | 0,207 |
| 0,955 | 0,103 | 0,955 | 0,103 |
| 0,952 | 0,053 | 0,952 | 0,053 |
| 0,946 | 0,011 | 0,946 | 0,011 |
| 0,906 | 0,206 | 0,906 | 0,206 |
| 0,898 | 0,108 | 0,898 | 0,108 |
| 0,898 | 0,052 | 0,898 | 0,052 |
| 0,898 | 0,010 | 0,898 | 0,010 |
| 0,802 | 0,194 | 0,802 | 0,194 |
| 0,795 | 0,097 | 0,795 | 0,097 |
| 0,798 | 0,052 | 0,798 | 0,052 |
| 0,804 | 0,009 | 0,804 | 0,009 |

com outros fatores como canal (90% de correlação entre a ocorrência de falso positivo e o canal ser 2), obteve-se um ganho na utilização dos mecanismos de aprendizagem. Os resultados são apresentados na tabela 6.

Correlações com outros parâmetros também foram testadas, porém, quando estas correlações se mantêm altas (acima de 90%), a RB com aprendizagem apresenta ganhos. Quando as correlações caem o modelo com aprendizagem apresenta um desempenho inferior ao modelo sem aprendizagem.

7 Conclusão

A partir do modelo desenvolvido e das simulações realizadas, é possível concluir que o modelo probabilístico adotado serviu tanto para inferência dos estados do canal como para o ajuste cognitivo da caracterização do espectro. A in-

Table 5 : Dados gerados vs. aprendizagem bayesiana.

| Dados gerados | | Inferências da bayesiana c/ aprendizagem | |
|--------------------|------------------|------------------------------------------|------------------|
| detecções corretas | falsos positivos | detecções corretas | falsos positivos |
| 0,990 | 0,202 | 0,990 | 0,194 |
| 0,948 | 0,201 | 0,948 | 0,189 |
| 0,900 | 0,199 | 0,900 | 0,185 |
| 0,797 | 0,205 | 0,797 | 0,190 |
| 0,991 | 0,097 | 0,991 | 0,091 |
| 0,949 | 0,097 | 0,949 | 0,087 |
| 0,900 | 0,104 | 0,900 | 0,084 |
| 0,805 | 0,088 | 0,805 | 0,091 |
| 0,991 | 0,057 | 0,991 | 0,047 |
| 0,942 | 0,050 | 0,942 | 0,044 |
| 0,905 | 0,049 | 0,905 | 0,044 |
| 0,812 | 0,051 | 0,812 | 0,046 |
| 0,989 | 0,011 | 0,989 | 0,009 |
| 0,949 | 0,008 | 0,949 | 0,009 |
| 0,905 | 0,010 | 0,905 | 0,009 |
| 0,796 | 0,010 | 0,796 | 0,009 |

ferência probabilística do estado do espectro atendeu as expectativas, sendo capaz de realizar com sucesso a cognição do espectro a partir do conjunto de sensores propostos. Contudo, os resultados quantitativos decorrentes dos ajustes nas probabilidades *a priori* ainda estão aquém das expectativas de evolução, esperando-se, assim, alcançar um desempenho superior com o refinamento do modelo matemático para atualização das probabilidades *a priori*.

Como trabalhos futuros, cabe-nos refinar o modelo probabilístico de cognição do espectro, bem como as equações e algoritmos de ajuste da RB. O desenvolvimento de modelos de simulação para cada um dos sensores apresentados também pode significar a possibilidade de aplicação do mecanismo de cognição probabilístico a dados de amostragens reais de espectro. É possível, como trabalho futuro, refinar o modelo apresentado em [Lee and Akyildiz 2011],

equação 1, para que este inclua na capacidade da faixa de espectro os períodos de indisponibilidade por interferência ou ruído (T^U). Na mesma linha, pode-se adaptar os métodos cooperativos apresentados em [Atapattu et al. 2011] e [Jing and Xu 2009] para operar com os cinco estados propostos para caracterização do espectro.

Ainda, pretende-se desenvolver um modelo probabilístico de tomada de decisão, com base em teoria da decisão, para que o rádio efetivamente possa disparar ações como: transmitir dados, receber dados ou trocar de canal, baseado em alterações no ambiente.

Referências Bibliográficas

- [FCC 2002] FCC, F. C. C. (2002). Report of the spectrum efficiency working group. et docket no. 02-135.
- [Akyildiz et al. 2006] Akyildiz, I. F., Lee, W. Y., Vuran, M. C., and Mohanty, S. (2006). Next generation/dynamic spectrum access/cognitive radio wireless networks: a survey. *Comput. Netw.*, 50(13):2127–2159.
- [Thomas et al. 2005] Thomas, R. W., Dasilva, L. A., and Mackenzie, A. B. (2005). Cognitive networks. In *Proceedings of IEEE DySPAN 2005*, pages 352–360.
- [Akyildiz] Akyildiz, I. F. Broadband wireless networking lab.
- [Akyildiz et al. 2009b] Akyildiz, I. F., Lee, W.-Y., and Chowdhury, K. R. (2009b). Spectrum management in cognitive radio ad hoc networks. *Netw. Mag. of Global Internetwk.*, 23:6–12.
- [Akyildiz et al. 2009a] Akyildiz, I. F., Lee, W.-Y., and Chowdhury, K. R. (2009a). Crahns: Cognitive radio ad hoc networks. *Ad Hoc Netw.*, 7:810–836.
- [Atapattu et al. 2011] Atapattu, S., Tellambura, C., and Jiang, H. (2011). Energy detection based cooperative spectrum sensing in cognitive radio networks. *Wireless Communications, IEEE Transactions on*.
- [Zhou et al. 2010] Zhou, X., Ma, J., Li, G. Y., Kwon, Y. H., and Soong, A. C. K. (2010). Probability-based combination for cooperative spectrum sensing. *Trans. Comm.*, 58:463–466.
- [Ganesan and Li 2005] Ganesan, G. and Li, Y. (2005). Cooperative spectrum sensing in cognitive radio networks. *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. 2005 First IEEE International Symposium on*, pages 137–143.
- [Lee and Akyildiz 2008] Lee, W.-Y. and Akyildiz, I. (2008). Optimal spectrum sensing framework for cognitive radio networks. *Wireless Communications, IEEE Transactions on*, 7(10):3845–3857.
- [Lee and Akyildiz 2011] Lee, W.-Y. and Akyildiz, I. F. (2011). A spectrum decision framework for cognitive radio networks. *IEEE Transactions on Mobile Computing*, 10:161–174.
- [Quer et al. 2010] Quer, G., Meenakshisundaram, H., Reddy, T. B., Manoj B. S., Rao, R. and Zorzi, M. (2010). Cognitive Network Inference through Bayesian Network Analysis. In *Proceedings of the IEEE GLOMECOM, 2010.*, pages 1–6.
- [Mendes et al. 2010] Mendes, R. d. S., Westphall, C. B., and Garcia, E. R. (2010). A framework to radio layer operation in cognitive networks. In *Proceedings of the 2010 Sixth International Conference on Networking and Services, ICNS '10*, pages 299–304, Washington, DC, USA. IEEE Computer Society.
- [Jing and Xu 2009] Jing, J. and Xu, Y. (2009). Optimization for cooperative spectrum sensing under bayesian criteria. In *Wireless Communications Signal Processing, 2009. WCSP 2009. International Conference on*, pages 1–5.