

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**

Rafael de Souza Mendes

**ABORDAGEM BAYESIANA PARA REDES SEM FIO
COGNITIVAS**

Florianópolis(SC)

2010

Rafael de Souza Mendes

**ABORDAGEM BAYESIANA PARA REDES SEM FIO
COGNITIVAS**

Dissertação submetida ao Programa
de Pós-Graduação em Ciência da Com-
putação para a obtenção do Grau de
Mestre em Ciência da Computação.
Orientador: Carlos Becker Westphall,
Dr.Eng.
Coorientadora: Silvia Modesto Nassar,
Dr.Eng.

Florianópolis(SC)

2010

Catálogo na fonte elaborada pela biblioteca da
Universidade Federal de Santa Catarina

A ficha catalográfica é confeccionada pela Biblioteca Central.

Tamanho: 7cm x 12 cm

Fonte: Times New Roman 9,5

Maiores informações em:

<http://www.bu.ufsc.br/design/Catalogacao.html>

Dissertação submetida ao Programa de Pós-Graduação em Ciência da

Computação para a obtenção do Grau de Mestre em Ciência da Computação.

À Deus e a minha família.

AGRADECIMENTOS

A minha avó Amélia, que sempre será um exemplo de conduta, justiça, resignação e principalmente: amor.

Às minhas tias Neli e Mara, que sempre primaram pela minha educação.

À minha esposa, Andréia, pela paciência e resignação nos decisivos momentos cotidianos que viabilizaram a realização de um estudo de mais de dois anos.

Aos meus pais, pelo apoio e reiterada insistência em me lembrar do meu, por vezes esquecido, gosto pela vida acadêmica.

Ao meu orientador, pelo conhecimento, motivação e envolvimento pessoal, sem os quais não seria viável a realização do mestrado.

Aos colegas do Sinergia, Sindicato dos Eletricitários de Florianópolis e Região, por terem contribuído com o máximo de sua capacidade para que eu conseguisse me dedicar ao mestrado, no período em que trabalhamos juntos.

Aos amigos da Eletrosul: Davi, Leomar, Diego, Carlinhos, Dinivaldo, Antônio Rogério e Nelson, que foram na medida do possível sempre compreensíveis, e contribuíram para deixar um pouco menos duros esses dois anos de vida laboral e mestrado.

*Porque toda a lei se cumpre numa só palavra,
nesta: Amarás ao teu próximo como a ti
mesmo.*

Gálatas 5:14

RESUMO

Esta dissertação aborda a aplicação de inferência e decisão probabilística ao campo de pesquisa das redes sem fio cognitivas. Na busca pela autoconfiguração e reconfiguração dos equipamentos de rede sem fio, a aplicação de redes bayesianas e teoria da decisão mostraram-se promissoras no sentido de extrapolar os limites das redes cognitivas, permitindo a tomada de decisão a fim de possibilitar não apenas o compartilhamento do espectro com usuários primários, como também compartilhar os próprios recursos computacionais (equipamentos e conexão com a internet) com usuários circunvizinhos. Neste sentido, a presente dissertação apresenta dois modelos bayesianos, o primeiro dedicado ao sensoriamento do espectro e o segundo dedicado à caracterização e decisão no espectro, com o objetivo de, respectivamente, aumentar a acurácia na detecção de usuários primários e gerenciar a conectividade da rede entre usuários primários, secundários proprietários dos equipamentos e secundários não proprietários. Por fim, o objetivo último deste trabalho é fornecer bases tecnológicas para o compartilhamento altruísta da conectividade à internet, esperando sua aplicação para fins sociais.

Palavras-chave: redes cognitivas, rádio cognitivo, inclusão digital, wireless, bayesianas, probabilística, teoria da decisão, autoconfiguração, reconfiguração, altruísmo, compartilhamento de recursos

ABSTRACT

This thesis addresses the application of probabilistic inference and decision to the research field of cognitive wireless networks. In the search for autoconfiguration and reconfiguration of wireless network equipment, application of Bayesian networks and decision theory have shown promise in order to transcend the limits of cognitive networks, enabling decision-making in order to enable not only the sharing of spectrum with primary users as well as share their own computing resources (equipment and Internet connection) with surrounding users. In this sense, this paper presents two Bayesian models, the first devoted to sensing the spectrum and the second devoted to the characterization and determination in the spectrum, with the purpose of, respectively, to increase accuracy in detecting primary users and manage the network connectivity between primary users, secondary users owners of the equipment and not owners. Finally, the ultimate goal of this work is to provide technological basis for the unselfish sharing of connectivity to the Internet waiting for your application for social ends.

Keywords: cognitive network, cognitive radio, digital inclusion, wireless, bayesian, probabilistic, decision theory, autoconfiguration, reconfiguration, altruism, resource sharing

LISTA DE FIGURAS

Figura 1	Hardware hipotético para elaboração da rede bayesiana.	42
Figura 2	Sequência temporal de estados produzida pela inferência bayesiana.....	43
Figura 3	Arquitetura parcial a ser suportada por um <i>framework</i> para operação do rádio.	44
Figura 4	Inferência bayesiana a partir do estado dos sensores. ...	47
Figura 5	Estratificação dos tempos de cada estado do canal pelos fatores temporais para composição da evidência no sensor de histórico.....	47
Figura 6	Hardware hipotético apresentando o sensor de histórico “virtual”.....	49
Figura 7	Cruzamento dos estados do canal com os sensores para obtenção das frequências estratificadas.....	50
Figura 8	Inferência bayesiana da probabilidade de cada canal dada a evidência de um PU.....	52
Figura 9	Série de estados do canal convertida em ocupação do canal.....	53
Figura 10	Rede com o modelo completo de decisão.	57
Figura 11	Máquina de estados de apoio ao sistema de tomada de decisão.....	61

LISTA DE TABELAS

Tabela 1	Tabela de mapeamento estático de estados dos sensores para estado do canal.	45
Tabela 2	Loterias simples e seus respectivos significados.	54
Tabela 3	Consequências e suas respectivas utilidades.	55
Tabela 4	Consequências e suas respectivas utilidades.	55
Tabela 5	Tabela de probabilidades <i>a priori</i> do sensor de potência.	64
Tabela 6	Tabela de probabilidades <i>a priori</i> do sensor de SNR. ...	65
Tabela 7	Tabela de probabilidades <i>a priori</i> do sensor de PU.	65
Tabela 8	Tabela de probabilidades <i>a priori</i> do sensor de histórico.	65
Tabela 9	Tabela de probabilidades <i>a priori</i> do sensor de bit.	65
Tabela 10	Estatísticas referentes à inferência bayesiana.	66
Tabela 11	Estatísticas referentes à aprendizagem das probabilidades <i>a priori</i>	67

LISTA DE ABREVIATURAS E SIGLAS

- AP. Ponto de acesso (*access point*)
- CN. Rede sem fio cognitiva (*cognitive network*)
- CR. Rádio cognitivo (*cognitive radio*)
- EU. Utilidade esperada (*expected utility*)
- FCC. Comissão Federal de Comunicação (*Federal Communication Commission*) - USA
- IEEE. Instituto de Engenheiros Eletricistas e Eletrônicos
- PDA. Assistente Digital Pessoal (*Personal Digital Assistant*)
- PB. Usuário público
- PU. Usuário primário
- PV. Usuário privado
- QoS. Qualidade do serviço (*Quality of Service*)
- SNR. Relação sinal-ruído (*signal-to-noise ratio*)
- TI. Tecnologia da informação
- UHF. *Ultra High Frequency*
- VHF. *Very High Frequency*

SUMÁRIO

1 INTRODUÇÃO	21
1.1 DEFINIÇÃO DO PROBLEMA E PROPOSTA	21
1.2 OBJETIVOS GERAIS E ESPECÍFICOS	26
1.2.1 Objetivo geral	26
1.2.2 Objetivos específicos	26
1.3 ORGANIZAÇÃO DO TRABALHO	26
2 REVISÃO DA LITERATURA	29
2.1 REDES COGNITIVAS	29
2.1.1 Sensoriamento do espectro	30
2.1.2 Decisão no espectro	32
2.2 TEORIA DA DECISÃO	33
2.3 TRABALHOS CORRELATOS	37
3 SENSORIAMENTO PROBABILÍSTICO E CARAC- TERIZAÇÃO DO ESPECTRO	41
3.1 UNIFICANDO DADOS COM ESTADOS DO ESPECTRO .	41
3.1.1 Síntese dos estados do canal, a base para a mode- lagem probabilística	46
3.2 CORRELAÇÕES E APRENDIZAGEM	48
3.3 CARACTERIZAÇÃO DO ESPECTRO	50
4 DECISÃO PROBABILÍSTICA NO ESPECTRO	53
4.1 VARRER O ESPECTRO OU OPERAR NO ESPECTRO ..	58
4.2 ABANDONAR O CANAL OU CONTINUAR OPERANDO	60
4.3 ADMITIR OU DEMITIR USUÁRIOS PÚBLICOS	62
5 EXPERIMENTOS	63
5.1 AMBIENTE DE SIMULAÇÃO	63
5.2 MÉTODO DE EXPERIMENTAÇÃO	63
5.3 DADOS DO EXPERIMENTO	64
6 CONCLUSÃO	69
6.1 PRINCIPAIS CONTRIBUIÇÕES	69
6.2 TRABALHOS FUTUROS	70
Referências Bibliográficas	71
APÊNDICE A – Experimentos realizados - testes t-Student	77

1 INTRODUÇÃO

1.1 DEFINIÇÃO DO PROBLEMA E PROPOSTA

A motivação para a busca de um aproveitamento mais hábil do espectro e, por conseguinte, a formulação do conceito de redes cognitivas, teve início com o relatório da Comissão Federal de Comunicação estadunidense (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 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 pesquisas que estimulasse a utilização mais inteligente do espectro por parte dos equipamentos computacionais como o clássico (AKYILDIZ et al., 2006). Apesar de o conceito de rede cognitiva (CN) ser difuso e aplicado a várias tecnologias de rede, como explanado em (THOMAS; DASILVA; MACKENZIE, 2005), consideraremos aqui que uma CN é uma rede formada por equipamentos dotados de rádios capazes de perceber o meio onde estão atuando e reconfigurar-se a fim de não causar interferências a usuários primários (PUs). Adjacentemente ao conceito de CNs, 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 (CR) deve ser capaz de promover:

- sensoriamento do espectro - detectando segmentos de espectro não utilizados e compartilhando espectro sem causar interferência destrutiva com outros usuários;
- gerenciamento do espectro - capturando a melhor faixa de espectro disponível a fim de atingir os requisitos de comunicação;
- mobilidade no espectro - mantendo a comunicação mesmo durante a transição para outras faixas de espectro;

- compartilhamento do espectro - providenciando um método de organização confiável que viabilize a coexistência 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; LEE; CHOWDHURY, 2009b) e (AKYILDIZ; LEE; CHOWDHURY, 2009a), ficando fortemente associados ao conceito de CRs — conceito este que, na grande maioria dos artigos, acaba por sobressair-se ao de CNs.

Assim, ao longo de artigos como (AKYILDIZ et al., 2006) e (AKYILDIZ et al., 2008), os objetivos de um CR foram sendo consolidados em duas macrofuncionalidades: capacidade cognitiva e reconfiguração. Estas duas funcionalidades, por sua vez, são antigas necessidades dos sistemas especialistas, principalmente dos formados por agentes cognitivos, que buscam, através da aprendizagem de máquina, adquirir e refinar o conhecimento e as ações sobre o problema para o qual foram desenvolvidos. Para isto, os sistemas especialistas são equipados de uma base de conhecimento, um mecanismo de inferência e mecanismos de interface com o meio. Este último, na maioria das vezes, representa uma interface com os usuários, entretanto, no contexto das CNs, deve ser composto pelo CR e pela interface com as camadas superiores.

As CNs, por sua vez, no que se refere a *gerenciamento do espectro*, necessitam lançar mão de teorias desenvolvidas no campo da inteligência artificial e outras áreas do conhecimento que abordam a tomada de decisão. No contexto desta dissertação, foram escolhidos como instrumento teórico para abordar o gerenciamento do espectro os fundamentos de *teoria da decisão*.

Incluindo-se então o tema “Acesso participativo e universal do cidadão brasileiro ao conhecimento” — o terceiro item dos “Grandes Desafios da Computação 2006-2016” (SBC, Última visita em 21 de maio de 2011.), proposto pela Sociedade Brasileira de Computação — à proposta de unir CNs e teoria da decisão, pretende-se posicionar o presente trabalho de forma que não somente represente um estudo no estado da arte sobre redes cognitivas, como também esteja alinhado às necessidades de desenvolvimento científico tipicamente brasileiras.

Combinar CNs e teoria da decisão visando a capacidade de liberação do acesso a usuários circunvizinhos proporciona uma base tecnológica para trabalhos futuros que abordem o uso de tais tecnologias para fins de inclusão digital, tornando então tal aplicação das CNs convergente para os seguintes itens descritos nos desafios da computação 2006-2016, que versam sobre o acesso do cidadão brasileiro ao conhe-

imento:

“Várias áreas da Computação precisam contribuir para a solução deste problema. O acesso ao conhecimento começa com vencer os desafios das interfaces, em particular a interface de sistemas computacionais com o cidadão. Outros tópicos de pesquisa relacionados e em aberto envolvem o projeto e desenvolvimento de ambientes com mobilidade e consciência de contexto, com hardware de baixo custo e software abertos e adaptáveis a necessidades locais. A produção de conhecimento passa pela produção de conteúdo e mecanismos eficientes de armazená-lo e recuperá-lo, pela criação e disponibilização de bibliotecas digitais. Questões afetivas, sociais e culturais em computação são novas áreas que precisam também ser envolvidas nesta tarefa.

[...]

- Projeto e desenvolvimento apropriado de novas infraestruturas de hardware e de comunicação;”

Propor a utilização de tecnologia da informação (TI) para estimular o altruísmo no seio da sociedade civil não é prática comum na área de redes de computadores, em que, tradicionalmente, os pesquisadores focam seus esforços na melhoria de indicadores como largura de banda, atraso, perda de pacotes, qualidade de serviço (QoS), protocolos etc. Contudo, da dialética entre pragmatismo tecnológico e a subjetividade social, surge o questionamento para submeter à prova o tema de pesquisa, “redes cognitivas para quem e para quem?”, sendo a resposta proposta pelo presente estudo:

- para permitir um nível de controle dos equipamentos de rede capaz de viabilizar o compartilhamento da conectividade sem risco de prejuízo para o proprietário;
- para pessoas desprovidas de recursos para contratar serviços de conexão a internet.

Neste contexto, o presente trabalho necessita desenvolver alguns conceitos que servirão de base para as ideias posteriormente apresentadas. O primeiro conceito a ser apresentado e desenvolvido aqui é o da diferenciação entre equipamentos pertencentes ao usuário proprietário da infraestrutura de acesso a internet (aqui tratados como “recursos de internet”), e os equipamentos pertencentes a usuários não proprietários da rede. Para definir o primeiro grupo de equipamentos, foi utilizado

o termo “usuário privado” e para o segundo, o termo “usuário público”. Ainda, todo o modelo é fundamentado em uma topologia centralizada, baseada em *access point* (AP). Desta forma pode-se entender o espectro como um recurso natural finito que pode ser ocupado por PUs, detentores do licenciamento da banda em questão, e os usuários secundários (SUs), que povoarão a banda de forma oportunista. Dentro do conjunto dos SUs, a partir dos conceitos propostos e do ponto de vista do AP, pode-se identificar então os usuários privados (PVs), os usuários públicos (PBs) e outros SUs adjacentes. Cada grupo de usuário afetará a tomada de decisão do AP, que centralizará a decisão no espectro de uma forma diferente, cabendo ao AP decidir sobre:

- varrer o espectro;
- ocupar um canal;
- abandonar um canal;
- liberar o acesso a PBs.

Cada decisão destas, dependendo do contexto em que o AP está inserido, possui uma consequência, e cada consequência, uma utilidade para o sistema.

Contudo, mesmo a viabilidade técnica para o compartilhamento de recursos de internet sendo o foco deste trabalho, não é prudente afirmar que a existência de tal tecnologia resultará efetivamente no comportamento humano desejado; porém, cabe aqui citar (BARROS, 1995), que define que os grupamentos humanos, em geral, têm por objetivo aumentar o bem-estar total de seus membros. Isto pode ser lido no trecho:

“o fato dos seres humanos organizarem-se em grupos com o objetivos bem definidos é o mais básico de todos os fenômenos e a motivação para todas as ciências sociais. Embora, de maneira geral, o objetivo básico seja sempre elevar o nível de bem estar de seus membros, nem todos estes agrupamentos têm organização e objetivos idênticos. Alguns destes grupamentos têm duas propriedades marcantes que influenciam sobremaneira o nível de pobreza vigente numa dada sociedade: a) cada membro cede ao grupo seus recursos privados, que, então passam a ser tratados como recursos comuns ao grupo e b) todas as transações entre os membros do grupo têm natureza unilateral, no sentido de que não se espera necessariamente nenhuma forma de reciprocidade imediata, nem qualquer forma de contabilidade é mantida.”

Considerando-se que: ao lançar mão do espectro, que é um recurso natural finito, seres humanos interagem através de seus equipamentos de rede de forma a obter a satisfação de uma necessidade que, em geral, é a conectividade com a internet; podemos considerar que, havendo mais de um usuário ocupando o espectro, existe uma interação humana indireta nesta ocupação.

Apesar de o objeto desta dissertação ser tecnológico, pode-se observar que há interação entre pessoas usuárias do espectro. Esta comunicação se dá não pelo contato direto, mas pela degradação da comunicação, decorrente da interferência entre as redes sem fio. Esta interferência, segundo (TEIXEIRA, 2010), pode ocasionar perdas de desempenho de até dez vezes no *throughput* das redes sem fio baseadas em IEEE 802.11. Ainda em (TEIXEIRA, 2010), é apontada a autoconfiguração do canal como sendo um fator significativo de melhoria no desempenho das redes 802.11. Logo, pode-se afirmar que um CR capaz de se autoconfigurar, a fim de obter o menor grau de interferência tanto em PUs como em SUs adjacentes, conduziria a um maior grau de bem-estar entre os usuários do espectro.

Ainda, com a possibilidade de tomada de decisão acerca de restringir ou liberar o uso público da rede, o CR poderia proporcionar um segundo nível de interação entre os ocupantes do espectro: uma relação baseada no altruísmo. O membro possuidor dos recursos de internet estaria habilitado a liberar acesso a qualquer membro circunvizinho, de forma unilateral e sem esperar reciprocidade imediata, em intervalos de tempo em que seus recursos estejam ociosos. Tudo isto gerenciado pelo CR sem acréscimo de complexidade para o usuário final.

Uma vez que um proprietário decida doar o tempo ocioso de seus recursos de internet, podemos supor consequências distintas em dois cenários diferentes. Em um cenário de baixa densidade espectral, os PBs acessariam a internet de forma restrita, apenas nos horários em que os PVs não a estivessem utilizando. Já em um cenário de alta densidade espectral, é provável que sempre haja um AP ocioso capaz de fornecer acesso para os PBs, levando a que mesmo usuários com condições de adquirir recursos de internet optem por utilizar os recursos disponíveis de seus vizinhos. Isto conduziria, além de um melhor aproveitamento total dos recursos, a uma redução da densidade espectral, causando uma melhora no *throughput* das redes sem fio.

Em ambos os cenários, os ocupantes do espectro experimentaríamos um aumento do bem-estar total, seja pela oportunidade de acesso a internet, seja pela redução dos custos de contratação dos serviços de acesso, ou ainda pela melhora na qualidade devido à redução da

interferência.

Este trabalho sugere então um método de sensoriamento do espectro e um método de tomada de decisão que, unidos, são capazes de fornecer qualidade no sensoriamento do canal a fim de permitir a implementação de uma CN — que opere em meio a PUs — bem como um esquema de tomada de decisão, baseado em teoria da decisão, que permita a implementação de compartilhamento dos recursos de internet com PBs. Desta forma, o presente trabalho mantém seu foco tecnológico, porém norteado por um objetivo social, mesmo que este último não seja aprofundado, ficando no campo da expectativa de trabalhos futuros.

1.2 OBJETIVOS GERAIS E ESPECÍFICOS

1.2.1 Objetivo geral

Desenvolver um método de sensoriamento do espectro e um método de tomada de decisão capazes de, respectivamente, promover um sensoriamento apto a qualificar a rede como cognitiva e permitir o compartilhamento da conectividade com usuários públicos.

1.2.2 Objetivos específicos

Os objetivos específicos deste trabalho são:

- avaliar a adequação de um modelo probabilístico para evitar interferência em usuários primários;
- garantir a primazia dos usuários primários através da troca de canais, a partir de um modelo probabilístico;
- admitir ou demitir usuários públicos de acordo com a probabilidade de uso dos usuários privados.

1.3 ORGANIZAÇÃO DO TRABALHO

O trabalho está organizado da seguinte forma:

No capítulo 1 — são abordados o problema, a proposta, a justificativa, a motivação, o objetivo geral, os objetivos específicos e a

organização do trabalho.

No capítulo 2 — são apresentadas as bases tecnológicas que dão sustentação aos métodos expostos neste trabalho. Também são apresentados os trabalhos correlatos mais importantes.

No capítulo 3 — é demonstrada a aplicação de redes bayesianas para o sensoriamento do espectro, sendo apresentado um modelo probabilístico capaz de expressar os estados do espectro e caracterizá-lo.

No capítulo 4 — apresenta-se a tomada de decisão, baseada também em um modelo probabilístico, necessária à mobilidade no espectro e ao compartilhamento do espectro.

No capítulo 5 — são demonstrados os experimentos realizados e a validação das ideias apresentadas mediante simulações computacionais.

No capítulo 6 — são descritas a conclusão, as principais contribuições e os trabalhos futuros.

Por último são apresentadas as referências bibliográficas.

2 REVISÃO DA LITERATURA

2.1 REDES COGNITIVAS

O conceito de CN começou a ser constituído a partir do estudo de tecnologias que levassem à solução do problema de escassez no espectro. Contudo, como expresso no relatório do FCC (FCC, 2002), o problema de escassez do espectro é na realidade um problema de alocação do espectro. Ainda, como observado por (THOMAS; DASILVA; MACKENZIE, 2005), as redes atuais são impedidas de atingir uma performance ótima, pois os elementos da rede (constituídos de nodos, camadas de protocolos, políticas e comportamentos) estão limitados em estado, escopo e mecanismos de resposta. Sendo assim, podemos concluir que as tecnologias de CNs estão sendo desenvolvidas com o principal objetivo de solucionar um problema causado pelo esgotamento da política de alocação do espectro, valendo-se, para isso, de técnicas de sensoriamento e tomada de decisão (muitas delas oriundas da inteligência artificial) a fim de levar os nodos e protocolos a um comportamento dinâmico, dependente do contexto encontrado.

À medida que o conceito de CNs consolida-se e avança em completude, novas possibilidades de uso são criadas, bem como mais teorias são aplicadas ao conceito. Dentro deste avanço das CNs, surgem desde técnicas adaptativas para o sensoriamento do espectro, como em (CHOI, 2010), até técnicas de compartilhamento do espectro baseadas em teorias dos jogos (FIANI, 2009).

Contudo, as definições de comportamento necessárias a uma rede dita cognitiva: *sensoriamento do espectro*, *gerenciamento do espectro*, *mobilidade no espectro* e *compartilhamento do espectro*, apresentadas pelos precursores do estudo de CNs, têm se mostrado sólidas. Em meio ao conceito de CNs, consolida-se também o conceito de CR, que é identificado como a tecnologia chave para a obtenção de redes que possam ser ditas cognitivas.

Mitola, em sua tese de doutorado (MITOLA, 2000), define o termo “rádio cognitivo” como sendo o ponto onde os *wireless personal digital assistants* (PDAs) e a rede relacionada com eles são suficientemente inteligentes, sobre os recursos do rádio e a comunicação computador-computador, de forma a:

- (a) detectar as necessidades de comunicação do usuário como função do contexto de uso, e

- (b) prover recursos de rádio e serviços de redes sem fio mais apropriados para essas necessidades.

Observando-se que (MITOLA, 2000) foi escrito antes do relatório do FCC (FCC, 2002), o conceito de CR definido por Mitola, ainda aparece atrelado ao termo “PDAs”, vínculo este que foi sendo desfeito pela comunidade científica nos anos posteriores ao propor tecnologias cognitivas para os mais variados tipos de dispositivos de rede. Porém, a ideia de que um CR é um exemplo de agente aplicado a telecomunicações, desenvolvida na tese de Mitola, tem-se consolidado e cada vez mais ideias oriundas dos agentes cognitivos e da inteligência artificial têm sido aplicadas aos dispositivos sem fio.

Para o presente trabalho, será definido o conceito de CN como sendo uma rede de computadores, composta por CRs capazes de perceber o ambiente em que estão operando e coordenar a reconfiguração de seus parâmetros de operação, a fim de atender a um requisito operacional ou melhoria em níveis de serviço. Contudo, cabe lembrar que o principal requisito operacional de uma CN é não causar interferências aos PUs, sendo um PU o usuário do espectro eletromagnético que possui licença de operação para operar em uma determinada banda e local, autorizado pelo órgão regulamentador competente. Um exemplo clássico deste tipo de usuário são as emissoras de TV.

Neste contexto, muitas tecnologias e concepções são combinadas para compor as CNs, contudo, para os fins aos quais este trabalho se destina, cabe revisar principalmente as noções gerais sobre sensoriamiento do espectro e decisão no espectro.

2.1.1 Sensoriamento do espectro

O sensoriamento do espectro é a tecnologia chave que permite a criação de redes de CRs, podendo ser descrito como a capacidade de identificar usuários primários. Apesar de seu destaque nas CNs, é um tema há muito tempo abordado pelos estudiosos de processamento de sinais de rádio. Ademais, a caracterização e reconhecimento de um sinal de rádio específico, como acontece com os usuários primários, compõe uma das necessidades básicas dos sistemas de radar, profundamente estudados desde a descoberta desta aplicação para as radiofrequências.

Provavelmente por isso o sensoriamento do espectro tem sido, até o momento, o tema mais explorado nos artigos que abordam as CNs e, do ponto de vista das CNs, tem sido abordado não apenas como o método para a detecção do PU, mas também tem incluído a

decisão de sensorear ou não o espectro. Os métodos físicos de detecção de PUs podem ser classificados como *energy detection*, *matched filter* e *cyclostationary-based*, classificação esta recorrente nos trabalhos de referência.

O método *energy detection* consiste na medição da potência total do sinal recebido em sobreposição às hipóteses de presença ou ausência de um PU, tal qual definido em (ATAPATTU; TELLAMBURA; JIANG, 2011). Quando o sinal primário, $x(t)$, é transmitido através de uma faixa de espectro com ganho h , o sinal recebido no receptor, $y(t)$, seguido da hipótese binária H_0 (sinal ausente) e H_1 (sinal presente), pode ser dado como 2.1, em que $w(t)$ é o ruído gaussiano branco aditivo (*additive white Gaussian noise* - AWGN).

$$y(t) = \begin{cases} w(t) & H_0, \\ hx(t) + w(t) & H_1, \end{cases} \quad (2.1)$$

O método *matched filter* ((TURIN, 1960)) é obtido pela correlação do sinal detectado com um sinal conhecido ou modelo de sinal. Já o método *cyclostationary-based* é um processo mais complexo, baseado na repetição de padrões que variam ciclicamente com o tempo, como pode ser visto em (ENSERINK; COCHRAN, 1994). Estes dois métodos não serão detalhados, pois a relevância de seus detalhes matemáticos não é significativa para os objetivos deste trabalho, cabendo apenas destacar que, tal qual o método *energy detection*, suportarão duas hipóteses distintas: presença ou ausência de sinal.

Na maioria dos trabalhos estudados o método de detecção escolhido é o método *energy detection*, apesar de o método de detecção de PUs ser a tecnologia chave para a implementação das CNs. Para fins de simulação é importante isolar o comportamento do sensor e estabelecer uma interface onde os elementos de interesses são: o resultado da detecção, o tempo de detecção, a probabilidade de detecção e a probabilidade de falso positivo; sendo estes elementos funções já matematicamente modeladas nas referências citadas.

Desta forma, o sensoriamento do espectro em CNs assume o papel de adicionar adaptabilidade à detecção de PUs e/ou outras CNs, de forma a diminuir o tempo de detecção, aumentar a acurácia da detecção, adicionar colaboração à detecção etc. Apesar de serem variadas as definições sobre o objetivo do sensoriamento no espectro, a definição postulada por (LEE; AKYILDIZ, 2008) de que: *o principal objetivo do sensoriamento do espectro é prover mais oportunidades de acesso do CR ao espectro sem interferência às redes primárias*; parece ser a definição mais própria para os objetivos deste trabalho e, por isso, a

que será adotada para fins de desenvolvimento dos modelos.

A modelagem matemática formal que define o sensoriamento do espectro (baseado em *energy detection*) pode ser observada em (HU; WANG, 2009), (LEE; AKYILDIZ, 2008) e (ZHOU et al., 2010) como sendo um problema de teste de uma hipótese binária expressa por 2.2:

$$y(t) = \begin{cases} n(t) & H_0, \\ s(t) + n(t) & H_1, \end{cases} \quad (2.2)$$

onde, $y(t)$, $s(t)$ e $n(t)$ denotam o sinal recebido pelo CR, o sinal emitido por um PU e o ruído, respectivamente; H_0 e H_1 denotam as hipóteses correspondentes à ausência e à presença de um PU, respectivamente. Este formalismo matemático é muito semelhante ao apresentado em 2.1, porém aqui já em termos de presença ou ausência de PU.

A partir desta definição foi criado o modelo mais aceito até então para representar o comportamento dos PUs em relação à sua ocupação do espectro, que consiste no modelo *ON/OFF*, no qual o estado *ON* representa a presença de um PU no espectro selecionado pelo CR e *OFF* representa a ausência de quaisquer PUs.

Boa parte dos esforços dos pesquisadores têm sido em torno de diminuir o tempo de sensoriamento e aumentar a acurácia da detecção, de forma a prevenir interferências a PUs e maximizar o acesso ao espectro por parte do CR.

2.1.2 Decisão no espectro

A decisão no espectro, como definido em (AKYILDIZ et al., 2008), refere-se à necessidade de a CN possuir a capacidade de decidir qual a melhor faixa de espectro, dentro das faixas disponíveis, possui a maior capacidade de satisfazer os requisitos de QoS demandados pela aplicação.

Para tanto, é necessário que primeiramente as faixas de espectro sejam caracterizadas, não somente por observações locais, mas pela utilização de tantas informações espaciais e temporais quanto possíveis (dentro das relevantes ao modelo de decisão escolhido), valendo-se de estatísticas e medidas de síntese para a caracterização destas faixas de espectro. Após o sensoriamento e a caracterização do espectro, é necessário escolher a banda a ser utilizada e efetivamente realizar a ação de operar nesta banda.

Com relação à primeira operação que compõe a decisão no es-

pectro, a caracterização do espectro, muitos fatores podem ser considerados. O principal dentre estes fatores, para as CNs, é a atividade de PUs, contudo, outros fatores podem ser adicionados à caracterização do espectro, como proposto em (KAPLAN; BUZLUCA, 2009), em que, para a composição do esquema de decisão no espectro, são considerados: largura de banda, atraso e frequência de aparição de PUs. Para a caracterização do espectro poderiam ser considerados não só fatores da camada de rádio, como também das camadas superiores, como perda de pacotes, erros de CRC, etc.

No tocante à segunda operação que compõe a decisão no espectro, a maioria dos trabalhos a trata apenas como a escolha do canal para a operação, contudo é importante ressaltar que qualquer decisão deve ser tomada com base em um conjunto de *decisões possíveis*. Em (CHOI, 2010) são apresentadas três possíveis decisões: transmissão de dados, sensoriamento ou troca de canal. Após definido o conjunto de decisões, deve-se prever as consequências que cada ação pode ocasionar. Independentemente do modelo de decisão escolhido, as consequências são, inevitavelmente, tratadas. Um exemplo disto é quando o sistema de controle de um CR define que não pode haver transmissão de dados quando for detectado um PU no canal. Esta programação e, consequentemente, a decisão de não transmitir consistem em uma previsão da consequência de *causar interferência no PU detectado*. Desta forma, a decisão sobre qual ação tomar pode ultrapassar a simples seleção da faixa de espectro a ser utilizada para a operação do rádio, podendo ser incluídas ações de ajuste de parâmetros e limiares de funcionamento do CR, a fim de atingir um determinado grau de QoS.

Embora a decisão no espectro seja a característica dos CRs menos explorada até o momento, e não haja um modelo de decisão que predomine, o método de otimização matemática, denominado programação linear, tem se destacado como modelo de tomada de decisão, sendo utilizado em muitos artigos, como em (LIU; KRISHNAMACHARI; LIU, 2010), em que a programação linear serve para a seleção do canal para operação.

2.2 TEORIA DA DECISÃO

O renascimento, no século XV, foi marcado pelo drástico incremento do interesse humano pelo conhecimento. Porém, nesta época ainda era controversa a aplicabilidade da matemática no mundo real. Contudo, devido aos avanços estabelecidos por Nicolau Copérnico (1473-

1543), Johannes Kepler (1571-1630) e Galileu Galilei (1564-1642), tornaram-se raros os que afirmassem que a matemática teria pouco a contribuir para o entendimento do mundo material. Galileu, considerado o pai da física matemática, teve a iniciativa de aplicar a matemática ao estudo da física, pondo então fim à discussão.

Entretanto, a aplicabilidade da matemática ao estudo do comportamento humano é algo ainda controverso e teve início nos primeiros estudos do que hoje é associado ao campo da economia. Até então o entendimento que se tinha é que o comportamento humano era algo fundamentalmente diferente do mundo físico. Mesmo o mundo físico podendo ser tratado com equações matemáticas, o comportamento humano não o poderia, devido à presença do elemento humano e à natureza do fenômeno psicológico. Desta forma, acreditava-se que seria impossível modelar quaisquer comportamentos humanos através da matemática.

Os estudos de Blaise Pascal (1623-1662) e Pierre de Fermat (1601-1665) sobre a probabilidade permitiram que a matemática fosse aplicada pela primeira vez ao comportamento humano. A aplicação dada pelo próprio Pascal foi a decisão de levar ou não uma vida devotada a Deus. Como relatado em (CUSINATO, 2003): “*A incógnita quanto à existência divina foi a motivação responsável pelo surgimento da primeira teoria da decisão: o princípio da expectância matemática, que levou Pascal a defender a fé em Deus em termos pragmáticos.*”.

Pascal usou para resolver esse problema o conceito de expectância matemática, que multiplica o valor monetário associado à decisão com a probabilidade de ganho. Desta forma Pascal atribuiu uma probabilidade $\alpha \neq 0$ para a existência de Deus e uma probabilidade $(1 - \alpha)$ para a não-existência de Deus. Consequente a isto, a expectância matemática para uma vida devotada a Deus (vida pia), seria:

$$E(\text{vidapia}) = \alpha \cdot \infty + (1 - \alpha) \cdot 0 = \infty,$$

enquanto que o valor esperado para uma vida mundana, dado que o máximo que se poderia adquirir em uma vida toda poderia ser expresso por uma constante k , seria:

$$E(\text{vidamundana}) = \alpha \cdot k + (1 - \alpha) \cdot k = k.$$

Desta forma Pascal observou que $E(\text{vidapia}) > E(\text{vidamundana})$ para qualquer probabilidade de Deus existir, concluindo ele que uma vida pia seria a decisão a ser tomada.

Generalizando-se o problema para quaisquer escolhas, dado um

vetor de possíveis resultados $X = (x_1, x_1, \dots, x_n)$ e um conjunto de vetores de probabilidades (loteria) $L_k = (p_1^k, p_2^k, \dots, p_n^k)$ contendo probabilidades para cada valor x_i ; então, uma dada loteria e deve ser escolhida se e somente se:

$$\sum_{i=1}^n x_i p_i^e \geq \sum_{i=1}^n x_i p_i^k \quad \text{para todo } k = 1, 2, \dots, K.$$

Apesar de o modelo não levar em consideração a variância dos possíveis retornos, limitação hoje bastante clara, podia ser aplicado a vários tipos de problemas e tornou-se o primeiro modelo matemático capaz de lidar com decisões em condições de incerteza.

Embora o princípio da expectância matemática seja de simples compreensão e aplicação, o modelo não é suficientemente expressivo para representar algumas categorias de problemas de decisão. Assim, com o avanço dos estudos em torno da expectância matemática, vários questionamentos começaram a surgir. Daniel Bernoulli, em 1738, confrontou o princípio da expectância matemática com o comportamento dos mercadores que costumavam fazer seguros. Bernoulli alegava que, se um mercador se baseasse apenas no princípio da expectância matemática, fazer um seguro seria como jogar dinheiro fora; entretanto, todos concordariam que fazer um seguro não consiste em uma insanidade, desta forma o comportamento dos mercadores seria uma clara quebra do princípio da expectância matemática.

Bernoulli utilizou o hoje famoso paradoxo de São Petersburgo para confrontar matematicamente o princípio da expectância matemática, paradoxo que em (CUSINATO, 2003) é descrito como:

“suponha que uma moeda é jogada repetidamente até que a primeira cara apareça. O jogo paga 2^{n-1} dólares se a primeira cara aparecer na n ésima jogada. Qual o preço que um indivíduo pagaria para entrar neste jogo? Se o indivíduo se baseasse no princípio da expectância matemática, ele estaria disposto a pagar, no máximo, o valor da esperança matemática. Como o valor da esperança matemática é:

$$E(L) = \sum_{n=1}^{\infty} \left(\frac{1}{2}\right)^n \cdot 2^{n-1}$$

$$E(L) = \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 2 + \frac{1}{8} \cdot 4 + \dots = \frac{1}{2} + \frac{1}{2} + \frac{1}{2} + \dots = +\infty,$$

ele estaria disposto a pagar qualquer preço para entrar neste jogo. Não importa o quão rico fosse o indivíduo, ele estaria disposto a entregar toda a sua riqueza para poder participar deste jogo. O que certamente

destoaria do comportamento observável no mundo real, onde a maioria das pessoas não estariam dispostas a pagar mais do que uns poucos dólares para participar deste jogo. ”

Bernoulli propôs então, como solução ao paradoxo de São Petersburgo, a relativização do valor esperado, a avaliação do valor através de uma utilidade que pode variar de acordo com o contexto do indivíduo que realiza a estimativa. Diferentemente do valor monetário, que é fixo para cada item e igual para todas as pessoas, a utilidade pode variar em função de diversos outros fatores. Assim, a proposição de Bernoulli serviu como marco inicial da teoria da utilidade esperada (EU).

O cálculo da utilidade esperada é semelhante ao cálculo do valor esperado, porém, no lugar do valor utiliza-se a função utilidade de um determinado item x_i do conjunto de itens X . Sendo assim a utilidade esperada para uma dada loteria pode ser calculada por:

$$U(L) = \sum_i p_i \cdot u(x_i)$$

Bernoulli ainda postulou que, à medida que a riqueza aumenta, decresce a utilidade adicional devido a este aumento. Esta lei mais tarde ficaria conhecida como *lei da utilidade marginal decrescente*. Bernoulli ainda supôs que a utilidade é igual ao logaritmo (em qualquer base) do resultado em termos monetários, de forma que $u(x) = \log_B x$ para qualquer base $B > 0$ e $B \neq 1$.

Desta forma, o paradoxo de São Petersburgo, analisado sob a óptica da EU, seria modelado da seguinte forma:

$$U(X) = \sum_{n=1}^{\infty} \left(\frac{1}{2}\right)^n \cdot \log_{10} (2^{n-1}) = 0,30103$$

Sendo X o preço máximo que uma pessoa estaria disposta a pagar para entrar no jogo e sendo $U(X) = \log_{10} X = 0,30103$, temos que o valor de $X = 10^{0,30103} = 2$, ou seja, o valor máximo que um indivíduo estaria disposto a pagar para participar de um jogo como o proposto no problema de São Petersburgo é 2 dólares.

Contudo, como apresentado em (CUSINATO, 2003), inserindo-se algumas modificações no problema, o paradoxo de São Petersburgo ressurgue. Porém a EU constitui a base para os formalismos apresentados em (PEARL, 1988), desta forma, mesmo a EU não sendo suficientemente expressiva para modelar todos os problemas de decisão que permeiam o mundo humano, pode-se considerá-la suficientemente expressiva para a modelagem dos problemas de decisão que este trabalho

se propõe a tratar, sob o escopo dos CRs.

2.3 TRABALHOS CORRELATOS

O desenvolvimento de estudos na área de CNs tem levado ao desenvolvimento de diversos métodos de cognição do espectro e otimização de fatores que influenciam no desempenho das redes de computadores. Exemplos de trabalhos que dissertaram sobre sensoriamento do espectro e que influenciaram o presente trabalho são:

- (CHOI, 2010) - apresenta um método de análise adaptativo do espectro baseado em *energy detection* que tem como principais características de distinção dos métodos convencionais de sensoriamento: adotar uma estrutura de sensoriamento adaptativo, prevenindo períodos de sensoriamentos desnecessários; combinar resultados estatísticos do método de sensoriamento a fim de melhorar a adaptabilidade; realizar a tomada de decisão com base no processo de decisão de Markov parcialmente observável;
- (HOSSEINI; TEIMOURI, 2010) - apresenta modelos matemáticos para o cálculo de diversos fatores relacionados com a interferência de CRs em PUs. O artigo divide o regime de transmissão dos CRs junto aos PUs em dois tipos: transmissão simultânea e transmissão não-simultânea. No primeiro regime o CR pode transmitir no mesmo canal que um PU, porém desde que a potência percebida no receptor do PU não seja maior que um dado limiar. No segundo regime o CR transmite apenas em canais não utilizados por um PU;
- (ZHOU et al., 2010) - trata de um esquema de combinação dos resultados, baseado em probabilidade, para sensoriamento cooperativo do espectro. O artigo apresenta uma regra de decisão usando a regra de decisão Bayesiana, calculando a verossimilhança ¹ entre a hipótese de existência de PU e de não-existência de PU. Tal trabalho teve grande influência para esta dissertação e, juntamente com (HU; WANG, 2009), compõe a premissa da existência de um método cooperativo de sensoriamento que sirva de referência para os ajustes individuais dos CRs que compõem a CN, como será apresentado no capítulo 3;

¹O conceito de verossimilhança (*likelihood*) é definido como o atributo daquilo que parece intuitivamente verdadeiro. Em estatística é calculado por $L(e|H) = \frac{P(e|H)}{P(e|-H)}$ (PEARL, 1988).

- (HU; WANG, 2009) - propõe um método de detecção cooperativo para redes de sensores utilizando *energy detection*. A detecção é feita a partir do somatório das medidas de um dado sensor com os sensores vizinhos. O artigo faz uma análise da probabilidade de detecção e probabilidade de falso positivo para o método cooperativo proposto para avaliar sua performance sobre atenuação Rayleigh, atenuação Nakagami-m e sombreadimento Log-normal ²;
- (LEE; AKYILDIZ, 2008) - apresenta um *framework* para otimização dos parâmetros de sensoriamento, a fim de maximizar a eficiência do método de sensoriamento. Utiliza programação linear para obter a otimização dos parâmetros de duração da transmissão e duração do sensoriamento. Também apresenta um método de sensoriamento adaptativo e cooperativo, tendo grande influência no capítulo 3 desta dissertação;
- (CABRIC; TKACHENKO; BRODERSEN, 2006) - trata do experimento de sensoriamento do espectro em ambientes reais e apresenta modelos matemáticos para o cálculo das probabilidades de detecção e falso positivo. O artigo também apresenta um método colaborativo para o ajuste do sensoriamento do espectro.

Ainda, exemplos de trabalhos que tratam a tomada de decisão no espectro e que tiveram influência sobre esta dissertação são:

- (LEE; AKYILDIZ, 2011) - apresenta um *framework* para decisão no espectro baseado em programação linear que toma decisões de acordo com os eventos: aparição de um CR, aparição de um PU e degradação da qualidade do canal. Contudo, prevê que o AP seja equipado com vários transceptores ³ a fim de monitorar vários segmentos de banda simultaneamente;
- (LIU; KRISHNAMACHARI; LIU, 2010) - utiliza programação linear para escolher o melhor canal para a operação do CR, buscando maximizar a performance do CR, considerando como restrição a probabilidade de colisão com um PU. Tem como premissa que o sensoriamento é perfeito e desconsidera o tempo de sensoriamento;
- (KAPLAN; BUZLUCA, 2009) - propõe um esquema dinâmico de decisão no espectro, baseado em função de utilidade, sendo

²Rayleigh, Nakagami-m e Log-normal, são distribuições probabilísticas utilizadas para modelar e simular o comportamento de variáveis como potência ou ruído.

³Dispositivo que combina transmissão e recepção.

a caracterização do espectro realizada sobre largura de banda, atraso e frequência de aparecimento de PUs;

- (LEE; LEE, 2010) - sugere um esquema que abrange o sensoriamento do espectro, a decisão no espectro e a transição de canais de forma a otimizar o gerenciamento do espectro partir de reconhecimento de padrões levantados a partir do sensoriamento.

Por fim, mesmo este trabalho não apresentando um capítulo específico sobre experiências sociais das tecnologias da informação e comunicação (TICs) junto a seres humanos, nem aprofundando sobre possíveis consequências da adoção das tecnologias propostas, dois trabalhos subsidiaram a visão hipotética sobre o comportamento humano que modelou o arranjo de tecnologias aqui proposto:

- (BRANDÃO; TRÓCCOLI, 2006) - propõe um modelo de avaliação para o projeto Casa Brasil, contribuindo principalmente por definir os conceitos de *dívida digital*, *inclusão digital* e *cidadania digital*;
- (BARROS, 1995) - descreve as relações sociais e os princípios que subsidiam o altruísmo no âmbito do mais elementar grupo social humano, a família. Propõe a noção de que a formação de agrupamentos humanos deve-se ao intuito geral de proporcionar um aumento no bem-estar total do grupo. Este conceito foi fundamental para a compreensão das possíveis motivações que levariam um proprietário de recursos de internet a compartilhá-los com usuários circunvizinhos.

3 SENSORIAMENTO PROBABILÍSTICO E CARACTERIZAÇÃO DO ESPECTRO

Como descrito no capítulo 1, das funcionalidades necessárias a um CR, a fundamental para garantir seu comportamento cognitivo é o sensoriamento do espectro. Para tanto, este capítulo descreverá um método de sensoriamento do espectro baseado em inferência bayesiana e cálculo probabilístico para atingir um refinamento temporal do sensoriamento do espectro, ou seja, procurando aproximar os resultados dos sensoriamentos individuais de cada CR com o resultado de um método de sensoriamento cooperativo ao longo do tempo. Desta forma, assume-se o pressuposto de que a CN implementa um método de sensoriamento cooperativo qualquer e que o resultado deste sensoriamento “coletivo” serve de referência para o refinamento do resultado individual de cada CR. Este pressuposto fundamenta-se na eficácia de tais métodos cooperativos de detecção de PUs, dentre os quais, alguns constam citados no capítulo 2, seção 2.3.

Contudo, o sensoriamento proposto neste trabalho não se utiliza do modelo de sensoriamento ON/OFF como descrito em (HOYHTYA; POLLIN; MAMMELA, 2008). Em vez disto, propõe um modelo de sensoriamento composto por vários estados que descrevem a ocupação do canal. Visando a caracterização do espectro, necessária à decisão no espectro, o sistema de sensoriamento promove a caracterização instantânea do sinal, realizando seu armazenamento na forma de histórico. O acúmulo dos sensoriamentos instantâneos do espectro constituirá a caracterização do espectro, servindo como base para decisões futuras.

3.1 UNIFICANDO DADOS COM ESTADOS DO ESPECTRO

O primeiro conceito a ser introduzido é o conceito de *estado do canal*, que servirá para caracterizar a faixa de espectro analisada de forma instantânea. O conjunto de estados do canal pode ser apresentado como uma variável aleatória discreta, resultado do processo de análise de uma determinada faixa do espectro (canal). A figura 1 apresenta um hardware hipotético constituído por quatro sensores básicos: sensor de PU, sensor de SNR, sensor de potência e modem, presentes em qualquer CR. O sensor de PU, o de SNR e o modem apresentam dois estados distintos. Já o sensor de potência possui dois limiares, o de transmissão e o de recepção, podendo desta forma assumir três estados

distintos: ocioso (*idle*), sensoriando (*sensing*) ou recebendo (*receiving*). A partir daí pode-se inferir que o espectro pode ser percebido de $2^3 \times 3 = 24$ formas distintas pelo hardware proposto. Contudo, a combinação de alguns estados dos sensores acaba por não demonstrar mais utilidade semântica que outra combinação. Por exemplo, tendo o sensor de PU sido acionado, independentemente do estado que os demais sensores possam apresentar (bit = 1, SNR = 0 etc), deve-se concluir que o sinal provém de um PU e portanto prevenir qualquer possível interferência a este PU.




Figura 1: Hardware hipotético para elaboração da rede bayesiana.

É proposto então um conjunto de estados do canal que realmente são de interesse para sua caracterização instantânea, sendo este conjunto $EC = \{n, p, h, l, u\}$, em que:

- 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 indecidibilidade devido a ruído ou interferência (*unknow*);
- p - PU, correspondente à detecção de atividade de um PU (*primary user*).

A função de mapeamento que opera o domínio dos estados dos sensores para a respectiva imagem, em estados do canal, pode ser observada na tabela 1, onde é demonstrada cada combinação de possíveis valores.

Dispondo cada amostra instantânea, em função do tempo, será gerada uma seqüência de dados caracterizada pelo instante em que o espectro assumiu um determinado estado e o instante em que ele abandonou este estado. Definindo-se isto em linguagem formal, obter-se-á

uma série temporal composta por uma sequência de tuplas: $(t_{inicio}, t_{fim}, ec)$, em que ec é o estado do canal e t_{inicio} e t_{fim} são os instantes inicial e final, respectivamente, que o espectro assumiu tal estado. A figura 2 apresenta de forma gráfica o resultado do sensoriamento do espectro no tempo.




Figura 2: Sequência temporal de estados produzida pela inferência bayesiana.

Este conceito foi apresentado pela primeira vez em (MENDES; WESTPHALL; GARCIA, 2010), onde foi demonstrada uma sequência destes estados do canal que permitiria o reconhecimento por expressões regulares. Uma vez que a sequência destes estados fosse reconhecida, poderia ser classificada e encaminhada para o mecanismo apropriado à interpretação da mensagem: o mecanismo de tratamento dos dados ou o mecanismo de análise e estatística do espectro. Estes mecanismos deveriam ficar na camada de controle responsável por operar o CR. Esta camada de controle pode ser identificada na figura 3, que mostra a arquitetura proposta em (MENDES; WESTPHALL; GARCIA, 2010), na qual existe um controle que recolhe estatísticas e informações de todas as camadas para então ajustá-las conforme a necessidade.

A unificação dos estados de dados e dos estados do espectro é sobretudo importante pois unifica a aquisição de informação sobre o estado do canal, permitindo uma análise mais profunda do comportamento do espectro ao longo do tempo. O armazenamento destas informações históricas, de forma massiva ou através de medidas de síntese, constitui a perspectiva de *sensibilidade ao contexto*, que permitirá o efetivo desenvolvimento de mecanismos cognitivos mais sofisticados.

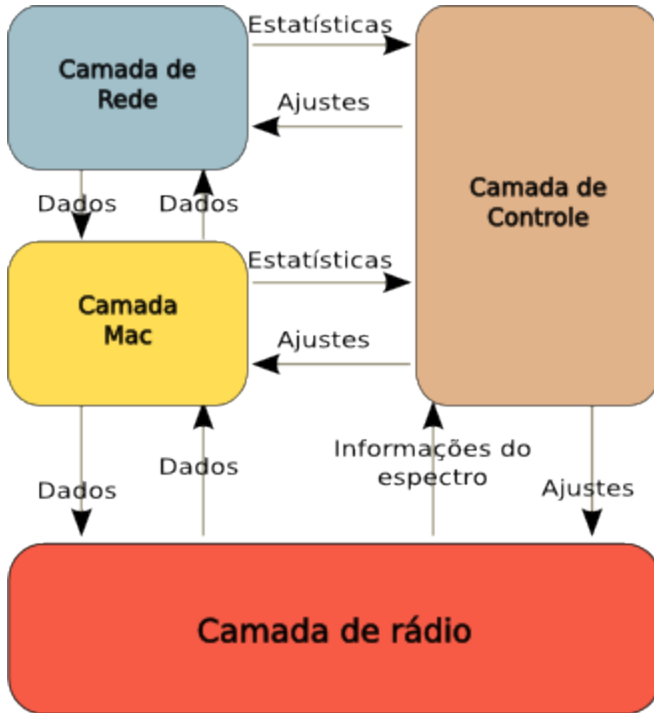


Figura 3: Arquitetura parcial a ser suportada por um *framework* para operação do rádio.

PU:Sensor	SNR:Sensor	Power:Sensor	Bit:Sensor	Channel	Channel:State
Detectado	Aceitável	Recebendo	Alto	Indiferente	p
Detectado	Aceitável	Recebendo	Baixo	Indiferente	p
Detectado	Aceitável	Sensoriando	Alto	Indiferente	p
Detectado	Aceitável	Sensoriando	Baixo	Indiferente	p
Detectado	Aceitável	Ocioso	Alto	Indiferente	p
Detectado	Aceitável	Ocioso	Baixo	Indiferente	p
Detectado	Não-aceitável	Recebendo	Alto	Indiferente	p
Detectado	Não-aceitável	Recebendo	Baixo	Indiferente	p
Detectado	Não-aceitável	Sensoriando	Alto	Indiferente	p
Detectado	Não-aceitável	Sensoriando	Baixo	Indiferente	p
Detectado	Não-aceitável	Ocioso	Alto	Indiferente	p
Detectado	Não-aceitável	Ocioso	Baixo	Indiferente	p
Não detectado	Aceitável	Recebendo	Alto	Indiferente	h
Não detectado	Aceitável	Recebendo	Baixo	Indiferente	l
Não detectado	Aceitável	Sensoriando	Alto	Indiferente	h
Não detectado	Aceitável	Sensoriando	Baixo	Indiferente	l
Não detectado	Aceitável	Ocioso	Alto	Indiferente	n
Não detectado	Aceitável	Ocioso	Baixo	Indiferente	n
Não detectado	Não-aceitável	Recebendo	Alto	Indiferente	u
Não detectado	Não-aceitável	Recebendo	Baixo	Indiferente	u
Não detectado	Não-aceitável	Sensoriando	Alto	Indiferente	u
Não detectado	Não-aceitável	Sensoriando	Baixo	Indiferente	u
Não detectado	Não-aceitável	Ocioso	Alto	Indiferente	n
Não detectado	Não-aceitável	Ocioso	Baixo	Indiferente	n

Tabela 1: Tabela de mapeamento estático de estados dos sensores para estado do canal.

3.1.1 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 adaptativo que efetivamente convertesse sequências de estímulos diversos, advindos de sensores independentes, em uma sequência única de percepções temporais acerca do canal sensoriado. Para tanto, baseado no hardware hipotético descrito na figura 1, foi modelada uma rede bayesiana que, tendo os estados dos sensores lançados como evidências em seus nós de entrada, produz em seu nó de saída uma distribuição probabilística acerca dos estados do canal. O hardware hipotético é formado por quatro sensores, sendo estes:

- sensor de bit - resultado do circuito de demodulação do rádio;
- sensor de SNR - resultado da aplicação do limiar de SNR ao valor percebido a partir do espectro;
- sensor de potência - resultado da aplicação dos limiares de potência à potência percebida a partir do espectro;
- sensor de PU - resultado da aplicação do limiar de detecção de PU ao valor percebido pelo circuito responsável por detectar PUs no espectro.

Contudo, o modelo apresenta mais um sensor que não provém do hardware e sim do mecanismo de análise estatística, o *sensor de histórico*. O diagrama com a rede bayesiana modelada pode ser visto na figura 4.

O histórico de ocupação do espectro é formado a partir da inferência cooperativa do estado do espectro. Contudo, aqui não será detalhado o mecanismo cooperativo de sensoriamento do espectro. Para fins de desenvolvimento deste trabalho, basta assumir que existem métodos para fazer a detecção cooperativa de um usuário primário (como os demonstrados em (ATAPATTU; TELLAMBURA; JIANG, 2011) e (ZHOU et al., 2010)); e que esta detecção é operada através de um canal de controle. Assim, uma vez que é realizada a detecção pelo CR e a detecção cooperativa, o resultado assumido como correto é o proveniente do método cooperativo. Desta forma, o histórico de detecção do método cooperativo é registrado no CR como a tupla $(t_{inicio}, t_{fim}, ch_n, pu_{coop})$, onde t_{inicio} e t_{fim} são os instantes inicial e final, respectivamente, em que o espectro assumiu este estado, ch_n é o canal para o qual a detecção foi

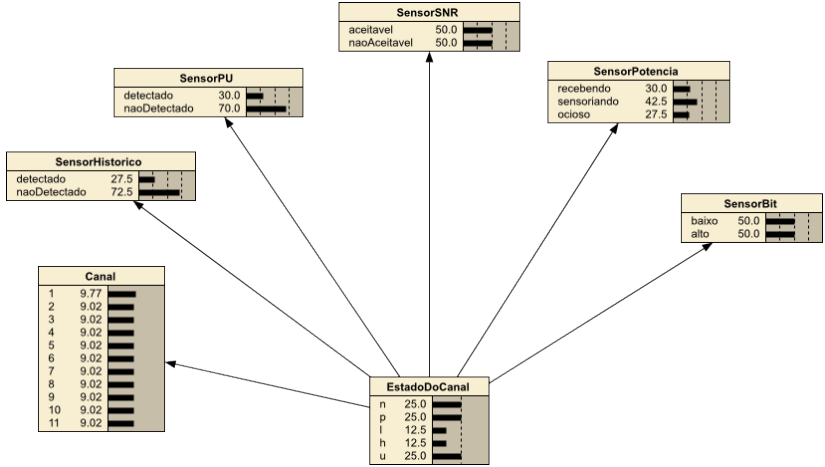


Figura 4: Inferência bayesiana a partir do estado dos sensores.

feita e pu_{coop} é um valor booleano (ON/OFF) que representa a detecção ou não de um PU no espectro.

A partir daí, uma vez que se constitui um histórico de detecções, pode-se minerar este histórico estratificando-o por um conjunto de fatores F , a definir por: mês do ano, semana do ano, dia do mês e hora do dia; garantindo assim uma correlação da aparição ou não de PUs com uma sazonalidade específica. Desta forma, pode-se inferir qual a maior probabilidade de ocupação do canal ($P(pu_{coop}^o | ch_n) | o \in \{on, off\}$) e então lançar o estado com maior probabilidade na forma de evidência, no nodo sensor de histórico da rede bayesiana. A figura 5 demonstra de forma visual esta estratificação para um dado canal.




Figura 5: Estratificação dos tempos de cada estado do canal pelos fatores temporais para composição da evidência no sensor de histórico.

A inferência da probabilidade da presença de PUs no canal é feita criando-se uma matriz de probabilidades PH_{ch_n} de 2×5 , cruzando os possíveis estados de detecção com os fatores analisados.

$$PH_{ch_n} = \begin{pmatrix} ph_{11}^{ch_n}, & ph_{12}^{ch_n} \\ ph_{21}^{ch_n}, & ph_{22}^{ch_n} \\ ph_{31}^{ch_n}, & ph_{32}^{ch_n} \\ ph_{41}^{ch_n}, & ph_{42}^{ch_n} \\ ph_{51}^{ch_n}, & ph_{52}^{ch_n} \end{pmatrix}$$

Nesta matriz, cada elemento $ph_{fo}^{ch_n}$ é obtido pela equação 3.1:

$$ph_{ij}^{ch_n} = \frac{t_{fo}^{ch_n}}{t_f^{ch_n}} \quad (3.1)$$

em que $t_{fo}^{ch_n}$ é o tempo total de detecção o para o fator f no canal n e $t_f^{ch_n}$ é o tempo total do fator f para o canal n .

Não obstante, pode-se também inferir uma probabilidade de um determinado canal apresentar uma ocupação por um PU ou não. O cálculo desta probabilidade dar-se-á pela equação 3.2:

$$P(o|ch_n) = \frac{t_{(o,ch_n)}}{t_{ch_n}} \quad (3.2)$$

em que $t_{(o,ch_n)}$ é o tempo total de estado o para o canal n e t_{ch_n} é o tempo total registrado de análise do canal n .

Adicionando-se o sensor de histórico ao hardware hipotético, pode-se vislumbrar um esquema mais completo deste hardware, como o apresentado na figura 6, onde aparece o sensor de histórico como um sensor “virtual”. Também é apresentada a camada de controle ligada à camada MAC, por onde trafegam os dados para a execução do método de detecção cooperativo.

3.2 CORRELAÇÕES E APRENDIZAGEM

Uma vez que haja a análise do histórico de detecções, é possível partir para o refinamento das inferências do estado do espectro. Este refinamento se dá pela alteração das probabilidades *a priori* que correlacionam o estado do canal com o sensor de PU, o sensor histórico e o canal. Desta forma, a rede bayesiana vai sendo adaptada para ter

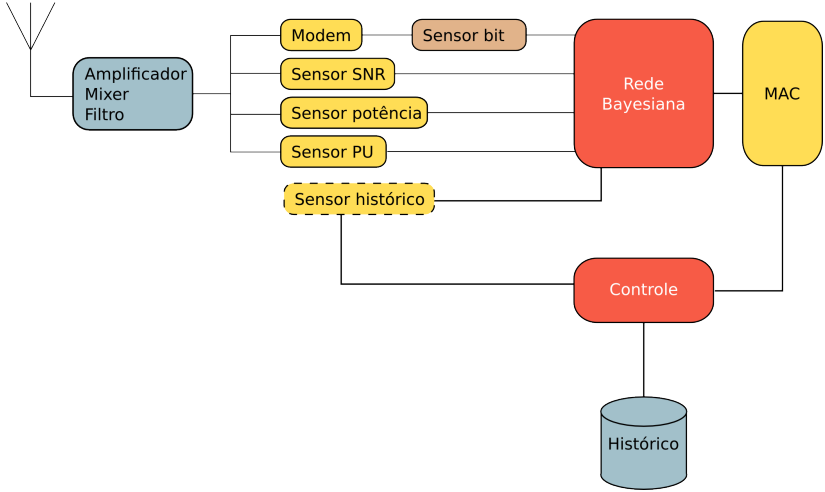


Figura 6: Hardware hipotético apresentando o sensor de histórico “virtual”.

seus resultados aproximados do resultado do método cooperativo de detecção.

O cálculo da probabilidade de cada estado do canal ec_k é feito pelo somatório de todas as probabilidades de ec_k para um determinado conjunto de evidências, ou seja, a probabilidade de cada estado do canal ec_k apresentado na figura 4 será dada pela equação 3.3:

$$P(ec_k|e_1, \dots, e_6) = \frac{P(e_1, \dots, e_6, |ec_k) \cdot P(ec_k)}{P(e_1, \dots, e_6)} \quad (3.3)$$

em que e_n são as evidências para cada um dos nodos da rede bayesiana, condicionalmente independentes ligados a EC .

Desta forma, as probabilidades *a priori* $P(SPU|EC)$, $P(SH|EC)$, $P(CH|EC)$, para os nodos sensor de PU (SPU), sensor de histórico (SH) e canal (CH), respectivamente, são atualizadas através da operação das frequências das evidências de cada sensor pelo resultado do método cooperativo, como mostram as equações 3.4, 3.5 e 3.6:

$$P(spu_i|ec_k) = \frac{n(i,k)}{n(k)} | i \in SPU, k \in EC, \quad (3.4)$$

$$P(sh_i|ec_k) = \frac{n(i,k)}{n(k)} | i \in SH, k \in EC, \quad (3.5)$$

$$P(ch_i|ec_k) = \frac{n(i,k)}{n(k)} | i \in CH, k \in EC, \quad (3.6)$$

A figura 7 mostra a contagem das frequências de cada um dos estados do canal versus o respectivo estado do sensor.

		Método Cooperativo				
		n	p	l	h	u
Sensor de PU	Detectado	10	40	0	0	10
	Não Detect.	50	0	20	20	5

		Método Cooperativo				
		n	p	l	h	u
Canal	Canal 1	10	40	0	0	10
	Canal 2	50	0	20	20	5
	Canal 3	10	40	0	0	10
	Canal 4	50	0	20	20	5

		Método Cooperativo				
		n	p	l	h	u
Sensor de histórico	Detectado	10	40	0	0	10
	Não Detect.	50	0	20	20	5

Figura 7: Cruzamento dos estados do canal com os sensores para obtenção das frequências estratificadas.

3.3 CARACTERIZAÇÃO DO ESPECTRO

A caracterização do espectro, que servirá como base para a tomada de decisão sobre qual canal escolher para a operação, pode ser encon-

trada na própria rede bayesiana modelada. Lançando-se no nodo *EC* a evidência da existência de um PU, pode-se obter a probabilidade de cada canal, ou seja: $P(ch_n|p)$, gerando um mapa dos canais com maior ou menor probabilidade de se encontrar um PU. A figura 8 mostra as probabilidades de cada canal, uma vez que é lançada a existência de um PU como evidência. O cálculo para a obtenção da probabilidade de um canal ser ocupado por um PU é dado pela equação 3.7:

$$P(ch_n) = P(ch_n|p)P(p) \quad (3.7)$$

Uma vez formado um vetor de canais, ordenado pela probabilidade de detecção de PU, basta escolher o canal com menor probabilidade.

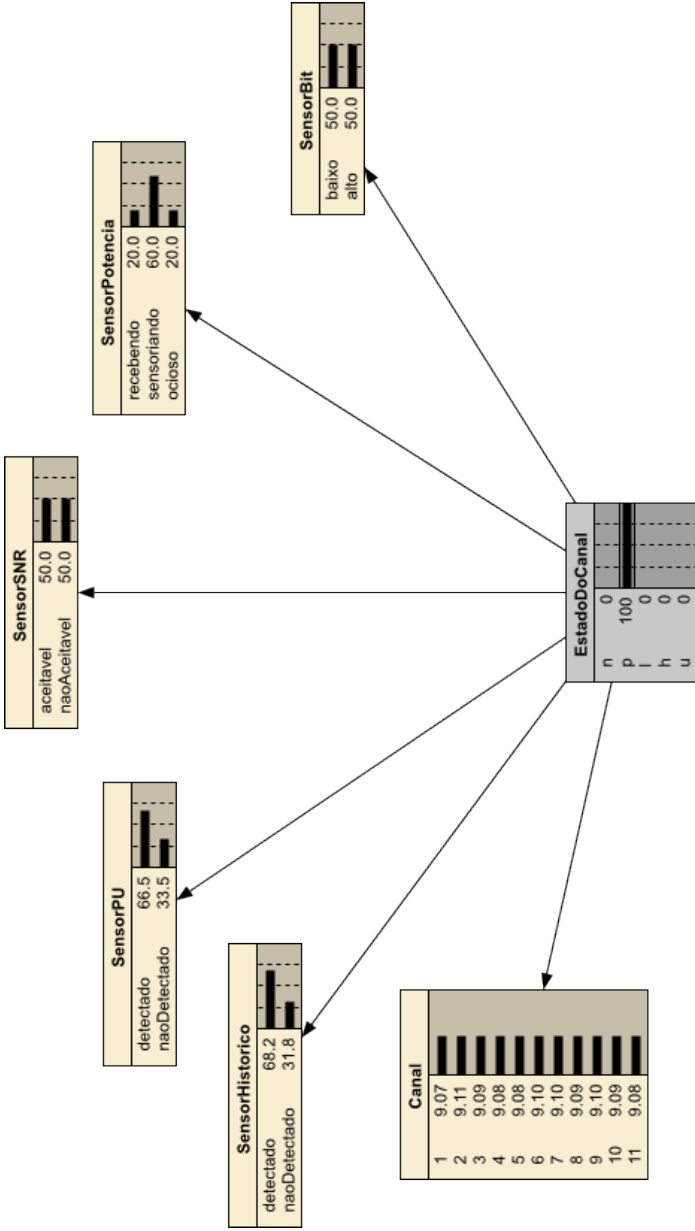


Figura 8: Inferência bayesiana da probabilidade de cada canal dada a evidência de um PU.

4 DECISÃO PROBABILÍSTICA NO ESPECTRO

Antes de abordar a tomada de decisão, o mecanismo aqui proposto requer uma adequação da caracterização do espectro para fins de tomada de decisão ou, por assim dizer, uma caracterização do espectro de segundo nível. Assim, a partir da série temporal discreta, formada pelos estados do canal selecionado dispostos no tempo, é possível inferir parte da *ocupação do canal* que será necessária à tomada de decisão. O conjunto de ocupações aqui definido será composto por quatro estados distintos, exclusivos entre si: *vazio*, *PU*, *PV* e *PB*. Desta forma, quando o estado do canal encontrar-se no estado n , significa que a ocupação do canal era *vazia*. No caso do estado do canal p , significa que o espectro está sendo ocupado por um *PU*. Já os dois últimos estados, *PV* e *PB*, podem ser inferidos a partir de sequências de estados h e/ou l , contudo, para a definição da demanda correta é necessária informação adicional da camada de controle para extração da informação do corpo do *frame* recebido. A figura 9 demonstra a série temporal de ocupações do canal gerada a partir da série de estados do canal (figura 2).




Figura 9: Série de estados do canal convertida em ocupação do canal.

Como citado na revisão da literatura, o processo de decisão no espectro pode ser subdividido em caracterização e decisão. A caracterização, neste trabalho, foi descrita no capítulo 3, formando-se uma lista de canais com as respectivas probabilidades $P(ch_n|p)$ que permitem a seleção do canal de acordo com a probabilidade da existência de *PU*. Também, no capítulo 3, foi descrito o mecanismo de caracterização do espectro a partir do histórico de cada canal. Desta forma, este capítulo tratará tão somente dos mecanismos de decisão, baseado na *utilidade esperada* de cada uma (loteria).

De acordo com a teoria da decisão, com base no princípio da utilidade esperada, é necessário primeiramente definir as possíveis decisões ou, conceitualmente falando, as *loterias* entre as quais o *CR* pode optar. São elas:

- varrer o espectro;
- ocupar um canal (trata-se da decisão de ocupar um canal qualquer, não exatamente um canal específico);

L_{11}	varrer o espectro
L_{12}	operar no espectro
L_{21}	abandonar o canal
L_{22}	continuar operando
L_{31}	admitir PBs
L_{32}	demitir PBs

Tabela 2: Loterias simples e seus respectivos significados.

- abandonar o canal;
- liberar o acesso a PBs;

decisões estas que, dentro do modelo probabilístico proposto, acabam convertendo-se em três decisões binárias (ou três loterias compostas por duas loterias), a citar:

- varrer o espectro ou operar no espectro;
- abandonar o canal ou continuar operando;
- admitir ou demitir PBs.

Define-se então o conjunto de loterias compostas $L = L_1, L_2, L_3$, passíveis de decomposição em $L = L_{11}, L_{12}, L_{21}, L_{22}, L_{31}, L_{32}$, como demonstrado na tabela 4.

Ademais, de cada loteria composta, pode-se inferir um contexto de consequências diferente. Cada contexto é na realidade um conjunto de consequências que pode ser aplicado à loteria composta L_x , sendo estas aplicáveis ou não a cada uma das loterias simples. Estes contextos formam um único conjunto global de consequências $C = C_1, C_2, C_3$, demonstrado na tabela 3. Cada contexto é decomposto e apresentado na tabela 4, com a respectiva utilidade associada à consequência, de acordo com o contexto.

Contudo, segundo a EU, é necessário que a utilidade de cada consequência seja multiplicada por sua respectiva probabilidade. Desta forma, foi criada uma rede bayesiana para realizar a inferência da probabilidade de cada consequência de acordo com a observação de determinados fatores, como: a demanda esperada, a qualidade da informação disponível, a ocupação do canal e a próxima ocupação do canal prevista.

A figura 10 apresenta a rede bayesiana modelada para operar a decisão no espectro, em que cada consequência e os respectivos fatores que influenciam em suas probabilidades são modelados como nós de

Consequências
aproveitarOportunidade
desperdicarOportunidade
interferirEmPU
operarSobPerformanceRuim
operarSobPerformanceBoa
negligenciarPV
negligenciarPB
atenderPV
atenderPB

Tabela 3: Consequências e suas respectivas utilidades.

Conjunto	Consequência	Definição	Utilidade
C_1	c_{11}	aproveitarOportunidade	100
	c_{12}	desperdicarOportunidade	-100
	c_{13}	interferirEmPU	-200
	c_{14}	operarSobPerformanceRuim	-50
	c_{15}	operarSobPerformanceBoa	100
	c_{16}	negligenciarPV	-100
	c_{17}	negligenciarPB	-10
	c_{18}	atenderPV	100
	c_{19}	atenderPB	80
C_2	c_{21}	interferirEmPU	-200
	c_{22}	negligenciarPV	-100
	c_{23}	negligenciarPB	-10
	c_{24}	atenderPV	100
	c_{25}	atenderPB	80
	c_{26}	aproveitarOportunidade	100
	c_{27}	desperdicarOportunidade	-100
C_3	c_{31}	negligenciarPV	-50
	c_{32}	negligenciarPB	-50
	c_{33}	atenderPB	100

Tabela 4: Consequências e suas respectivas utilidades.

entrada, as decisões são modeladas como nós de decisão (com o nome *Decisao_x*) e as respectivas tabelas de utilidade são mapeadas nos nós de utilidade (com o nome de U_x).

Nas seções a seguir será feito um aprofundamento sobre cada decisão, suas consequências e os fatores que influenciam na probabilidade de cada consequência.

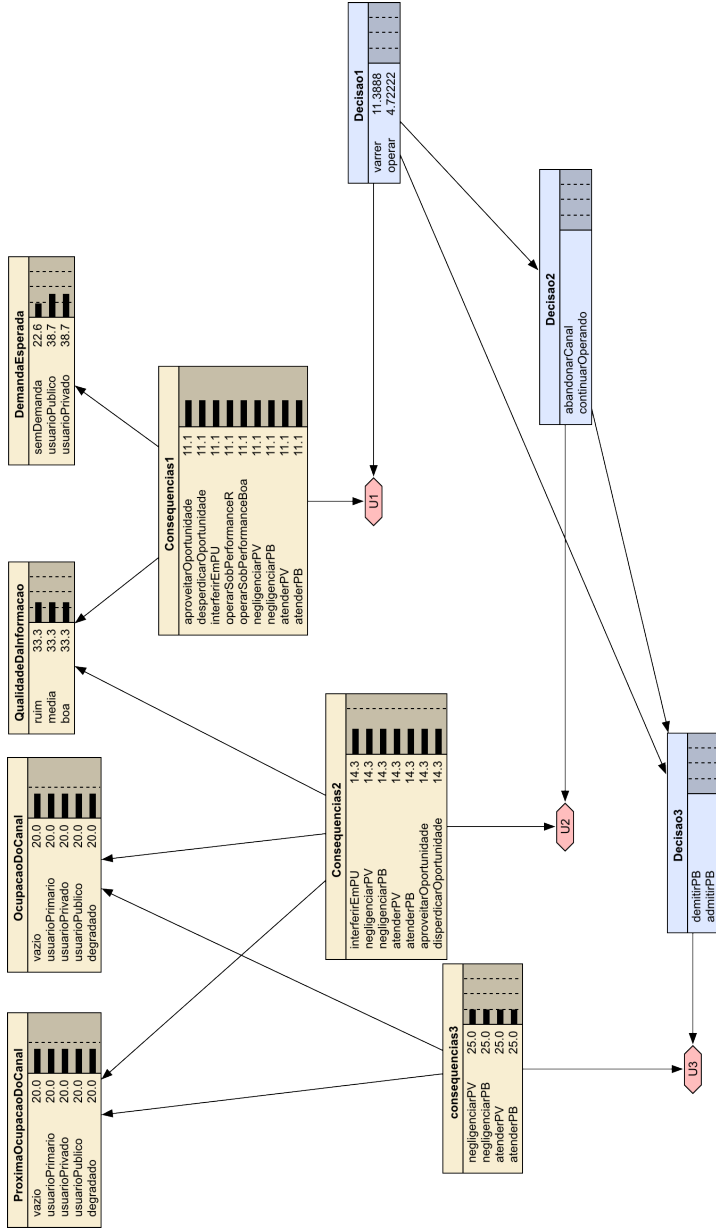


Figura 10: Rede com o modelo completo de deciso.

4.1 VARRER O ESPECTRO OU OPERAR NO ESPECTRO

A primeira decisão pode ser modelada na forma de uma loteria composta L_1 , com duas loterias simples L_{11} e L_{12} , em que L_{11} representa a decisão por *varrer* o espectro e L_{12} representa a decisão por *operar* no espectro. Na rede bayesiana que modela o problema de decisão, foram selecionados como fatores para a inferência da probabilidade de cada consequência a *demanda esperada* e a *qualidade da informação*.

A *demanda esperada* refere-se à previsão de demanda para o instante $t + n$, em que t é o instante de tempo atual e n é o intervalo de tempo do qual trata a previsão. A previsão é feita calculando-se a probabilidade de cada demanda d do espectro, estratificado por um conjunto de fatores F a definir por: mês do ano, semana do ano, dia da semana, dia do mês e hora do dia. A mineração do histórico de ocupações mantido pelo CR resultará em uma matriz de elementos pd_{fd} , em que:

$$PD = \begin{pmatrix} pd_{11} & pd_{12} & pd_{13} \\ pd_{21} & pd_{22} & pd_{23} \\ pd_{31} & pd_{32} & pd_{33} \\ pd_{41} & pd_{42} & pd_{43} \\ pd_{51} & pd_{52} & pd_{53} \end{pmatrix}$$

Este mecanismo de inferência será o mesmo utilizado para prever a *próxima ocupação do canal*, contudo, aqui ele é simplificado para apenas três tipos de ocupação: sem demanda, usuário primário, usuário público; e também é **independente de canal**. Desta forma, o termo “demanda” será utilizado quando a previsão for feita para o espectro como um todo, e o termo “ocupação” será utilizado para a previsão dado um canal selecionado.

Sendo a *próxima demanda* o que se deseja inferir, deve-se primeiramente classificar o instante $t + n$ de acordo com os fatores supracitados. Após isto, deve-se analisar os registros de ocupação do espectro, realizando-se a soma do montante de tempo que o rádio esteve sob uma determinada demanda, e em seguida normalizar o valor dividindo-o pelo total de tempo de operação para o respectivo estrato, como definido em 4.1.

$$pd_{fd} = \frac{t_{fd}}{t_f} \quad (4.1)$$

Após o cálculo de cada pd_{fd} , deve-se então somar todas as proba-

bilidades para cada uma das possíveis demandas e dividir pelo número de fatores, encontrando-se assim a probabilidade média de cada demanda. A demanda que obtiver maior probabilidade será escolhida como a demanda predominante e lançada na rede bayesiana na forma de evidência.

O passo seguinte é definir um mecanismo para a inferência da qualidade da informação. A qualidade da informação refere-se à proximidade ou afastamento temporal da última varredura. Após realizar uma varredura completa do espectro, a qualidade da informação deve ser classificada como boa, sendo neste instante o momento em que o CR está mais qualificado para tomar uma decisão de operar no espectro, pois o espectro está caracterizado da melhor forma possível. Com o afastamento temporal da última varredura, a informação vai tornando-se defasada até tornar-se efetivamente ruim.

Para a classificação da informação, foi escolhido um *quantum* de tempo, dado por um parâmetro $qt = 3$ horas, de onde o mapeamento para a variável qualitativa $QI = \{boa, media, ruim\}$ pode ser feito seguindo-se a função expressa em 4.2.

$$f(t_u, t) = \begin{cases} boa & , \text{ se } (t_u - t) \leq \frac{qt}{3} \\ media & , \text{ se } (t_u - t) > \frac{qt}{3} \wedge (t_u - t) \leq \frac{2qt}{3} \\ ruim & , \text{ se } (t_u - t) > \frac{2qt}{3} \end{cases} \quad (4.2)$$

onde t_u é o instante em que foi realizada a última varredura do espectro e t é o instante atual. Desta forma, a qualidade da informação pode ser definida e lançada na rede bayesiana como uma evidência.

Após o lançamento de cada evidência, o sistema calcula a probabilidade de cada consequência, dada a sua correlação com cada uma das evidências, ou seja, é necessário inferir $P(c_{1x}|pd, qi)$, em que, segundo o modelo proposto, a probabilidade de c_{1x} pode ser calculada pela equação 4.3.

$$P(c_{1x}|pd, qi) = \frac{P(pd|c_{1x}) \cdot P(c_{1x})}{P(pd)} + \frac{P(qi|c_{1x}) \cdot P(c_{1x})}{P(qi)} \quad (4.3)$$

Após o cálculo de cada uma das $P(c_{1x})$, deve-se então promover o cálculo da utilidade de cada uma das loterias simples L_{11} e L_{12} , obtido através do somatório da utilidade esperada para cada uma destas loterias. Com isso, $U(L_{1y})$ pode ser calculada pela equação 4.4.

$$U(L_{1y}) = \sum P(c_{1x}|pd, qi) \cdot u_{1x}^y \quad (4.4)$$

Na equação 4.4, a variável u_{1x}^y representa a utilidade para a consequência c_{1x} caso seja escolhida a loteria y .

Logo, será realizada a escolha por L_{11} caso $U(L_{11}) > U(L_{12})$ e por L_{12} caso $U(L_{12}) \geq U(L_{11})$. No caso de igualdade, pode-se observar a escolha por L_{11} , priorizando assim a operação em detrimento do sensoriamento.

4.2 ABANDONAR O CANAL OU CONTINUAR OPERANDO

Neste ponto, e como requisito para que L_2 possa ser avaliada, o rádio já deve ter passado pela decisão sobre L_1 . É isto que pode ser observado na figura 10, com o arco direcionado, de origem em *Decisao1* e destino em *Decisao2*. Contudo, o modelo gráfico da figura 10 não demonstra uma regra implícita ao modelo implementado: a segunda decisão só será avaliada caso o rádio esteja em operação, ou seja, só será decidido por continuar operando ou abandonar o canal caso o resultado da avaliação de L_1 seja L_{12} (operar no espectro).

A máquina de estados que apoia o controle do sistema de tomada de decisão pode ser vista na figura 11, onde cada loteria é mapeada para um estado diferente e cada decisão representa uma transição entre os estados. No desenho, a decisão 3 aparece pontilhada e contida dentro da decisão 2, pois ela constitui um subestado desta, de forma que, enquanto o sistema estiver avaliando continuar operando ou abandonar o espectro, também estará avaliando admitir ou demitir PBs; da mesma forma, deixando de avaliar a decisão 2, deixa também de avaliar a decisão 3.

Antes de apresentar o cálculo para a utilidade esperada das loterias que compõem L_1 , é necessário discorrer sobre as duas variáveis aleatórias do modelo bayesiano apresentado que não foram detalhadas até o momento. A ocupação do canal e a próxima ocupação do canal são duas variáveis que podem ocupar os mesmos valores discretos:

$$POC = OC = \{vazio, PU, PV, PB, degradado\}$$

Entretanto, enquanto a *ocupação do canal* refere-se à caracterização atual do espectro, e é atualizada a qualquer mudança atual do estado do espectro, a *próxima ocupação do canal* refere-se à expectativa de caracterização do canal para o próximo quantum de tempo. A exemplo da

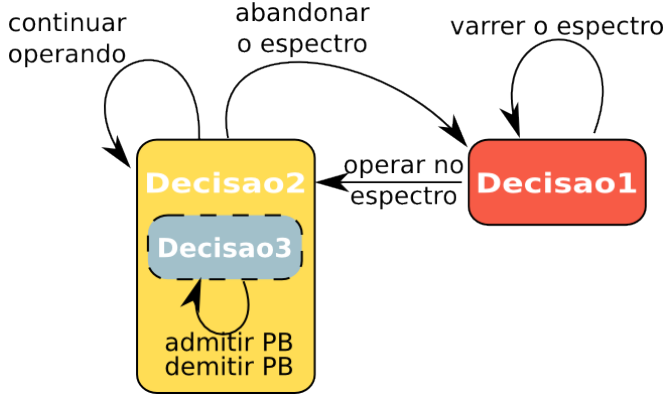


Figura 11: Máquina de estados de apoio ao sistema de tomada de decisão.

demanda esperada, a próxima ocupação do canal é dada pela mineração dos registros de ocupação, porém desta vez é levado em consideração o **canal** selecionado. Os registros de ocupação do canal devem ser estratificados pelo mesmo conjunto de fatores E , com fim de auferir a maior probabilidade de ocupação do canal para o instante $t + n$, com n igual a 1 hora. A matriz de probabilidades da ocupação, bem como a obtenção de cada probabilidade da ocupação predominante para o instante $t + n$ se dá de forma idêntica à demanda esperada a não ser pelo fato de que os registros minerados devem pertencer apenas ao canal sobre o qual o CR está operando. Após o cálculo, o sistema lança a ocupação predominante como uma evidência no nodo da rede bayesiana.

Definidas então todas as variáveis aleatórias que compõem o modelo, e sendo a loteria L_2 composta pelas duas loterias L_{21} e L_{22} , correspondentes respectivamente a *abandonar o canal* e *continuar operando*, como descrito na tabela 4, do mesmo modo como foi calculada a utilidade esperada das loterias que compunham L_1 podemos calcular as utilidades esperadas $U(L_{21})$ e $U(L_{22})$ a partir da equação 4.5.

$$U(L_{2y}) = \sum P(c_{2x}|poc, oc, qi) \cdot u_{2x}^y \quad (4.5)$$

$$P(c_{2x}|poc, oc, qi) = \frac{P(poc|c_{2x}) \cdot P(c_{2x})}{P(poc)} + \frac{P(oc|c_{2x}) \cdot P(c_{2x})}{P(oc)} + \frac{P(qi|c_{2x}) \cdot P(c_{2x})}{P(qi)} \quad (4.6)$$

Na equação 4.6, é apresentado o detalhamento do cálculo de $P(c_{2x}|poc, oc, qi)$. E, semelhantemente ao exposto na seção 4.1, u_{2x}^y representa a utilidade para a consequência c_{2x} caso seja escolhida a loteria y .

Por fim, a decisão por L_{21} ou L_{22} será tomada com base na comparação $U(L_{21}) \geq U(L_{22})$ ou $U(L_{22}) > U(L_{21})$, respectivamente. A preferência pela decisão de abandonar o canal deve-se à necessidade de prevenir a possível interferência em um PU, sendo assim, qualquer indeterminação (igualdade entre as utilidades esperadas) deve privilegiar o abandono do canal.

4.3 ADMITIR OU DEMITIR USUÁRIOS PÚBLICOS

A decisão sobre admitir ou demitir PBs constitui o artifício tecnológico chave para a proposta deste trabalho: viabilizar o altruísmo no compartilhamento dos recursos de internet. Neste ponto, o sistema necessita priorizar a utilização do espectro para os PVs, da mesma forma que as CNs priorizam o espectro para os PUs. Por este motivo, o mecanismo para decisão sobre a loteria L_3 é muito semelhante a L_2 , porém, não carece de evidências sobre a qualidade da informação para a tomada de decisão, considerando apenas a ocupação do canal e a próxima ocupação do canal. Como anteriormente apresentado na tabela 4, as loterias L_{31} e L_{32} , correspondem respectivamente a admitir PBs e demitir PBs. Os cálculos para a obtenção das utilidades esperadas $U(L_{31})$ e $U(L_{32})$ são apresentados na equação 4.7 e detalhados na equação 4.8.

$$U(L_{3y}) = \sum P(c_{3x}|poc, oc) \cdot u_{3x}^y \quad (4.7)$$

$$P(c_{3x}|poc, oc) = \frac{P(poc|c_{3x}) \cdot P(c_{3x})}{P(poc)} + \frac{P(oc|c_{3x}) \cdot P(c_{3x})}{P(oc)} \quad (4.8)$$

A escolha por L_{31} ou L_{32} se concretiza com base na comparação $U(L_{31}) > U(L_{32})$ ou $U(L_{32}) \geq U(L_{31})$, respectivamente. Novamente aqui pode-se observar a priorização de uma ação em detrimento de outra, ou seja, a ação de demitir PBs tem predominância devido à necessidade de proteger os PVs.

5 EXPERIMENTOS

O experimento realizado foi fruto de simulação computacional e teve como objetivo aferir a capacidade da detecção de PUs realizada pela rede bayesiana de aproximar-se do suposto resultado de um método cooperativo qualquer.

5.1 AMBIENTE DE SIMULAÇÃO

No início dos trabalhos houve a tentativa de utilizar o simulador Jist-Swans ?? para a realização das simulações. Entretanto, como a dissertação desenvolveu seu foco principal em torno da caracterização e decisão no espectro, não foi necessário o uso de um simulador de redes para a validação dos estudos aqui propostos.

Logo, a simulação foi desenvolvida para testar a acurácia da rede bayesiana de sensoriamento do espectro, em linguagem de programação Java (versão 1.6), utilizando a biblioteca NeticaJ ?? para a inferência bayesiana. Para geração de números aleatórios, foi utilizada a classe *Random*, que compõe a biblioteca padrão da linguagem Java desde sua versão 1.1.

5.2 MÉTODO DE EXPERIMENTAÇÃO

O método de experimentação constituiu-se da geração de uma massa de dados contendo valores para cada um dos nós da rede bayesiana de sensoriamento do espectro e o respectivo resultado esperado pelo nó de saída, que para uma detecção perfeita representa o mesmo resultado do método cooperativo. Desta forma, a acurácia da rede bayesiana pode ser medida comparando-se o resultado do nó de saída com o resultado esperado. Desta comparação pode-se tirar a porcentagem de detecções corretas, de falsos positivos e falsos negativos, para uma determinada amostra. Então, comparando-se várias amostras, é possível avaliar o desempenho de redes bayesianas com diferentes tratamentos.

Como tratamento foram utilizados dois mecanismos de controle para a rede bayesiana. O primeiro consistiu-se da recuperação de cada linha da massa de dados gerada e então do lançamento de cada célula como uma evidência nos nós de entrada da rede, para posteriormente comparar o resultado produzido com o resultado esperado e obter a

Estado do canal	Sensor de potência		
	recebendo	sensoriando	ocioso
n	0.1	0.2	0.7
p	0.2	0.6	0.2
l	0.7	0.2	0.1
h	0.7	0.2	0.1
u	0.2	0.7	0.1

Tabela 5: Tabela de probabilidades *a priori* do sensor de potência.

porcentagem de detecções corretas e de cada um dos tipos de erro. O segundo tratamento foi constituído de uma primeira inferência, tal qual o primeiro, seguida de uma atualização das probabilidades *a priori* da rede bayesiana, seguida de nova inferência e então obtenção das porcentagens de acertos e erros.

5.3 DADOS DO EXPERIMENTO

Foi gerada uma massa de dados contendo *dez* amostras de 1.000.000 registros cada, com evidências para cada um dos sensores da rede bayesiana e a respectiva existência ou não de um PU, que representa o resultado do método cooperativo. A existência de PU foi gerada com uma correlação de 98% em relação à detecção pelo sensor de histórico, uma correlação de 95% para o sensor de PU, de 90% para os canais 1 e 3 e de 99% para a combinação dos três fatores anteriores.

O experimento consistiu em acompanhar primeiramente a taxa de detecções corretas, falsos positivos e falsos negativos para a rede bayesiana com as probabilidades *a priori* configuradas de forma padrão (manual) e comparar com a evolução destas taxas de acordo com a aprendizagem de proposta do capítulo 3.

Inicialmente, a rede bayesiana com as probabilidades *a priori* iniciais (como pode ser visto nas tabelas 5, 6, 7, 8, 9) apresentou para cada uma das dez amostras as taxas de: *detecções corretas*, *falsos positivos* e *falsos negativos*, demonstradas na tabela 10.

Em seguida, foi aplicado o mecanismo de atualização das probabilidades *a priori* como descrito no capítulo 3, e então executada novamente a inferência bayesiana sobre a massa de dados de teste. Desta vez, porém, foi obtido um incremento na precisão das inferências (exceto pelo fator *falsos positivos*), como demonstrado na tabela 11.

Foi então realizado o teste *t* de Student sobre cada um dos fatores

Estado do canal	Sensor de SNR	
	aceitável	não-aceitável
n	0.5	0.5
p	0.5	0.5
l	0.9	0.1
h	0.9	0.1
u	0.1	0.9

Tabela 6: Tabela de probabilidades *a priori* do sensor de SNR.

Estado do canal	Sensor de PU	
	detectado	não detectado
n	0.1	0.9
p	0.9	0.1
l	0.1	0.9
h	0.1	0.9
u	0.1	0.9

Tabela 7: Tabela de probabilidades *a priori* do sensor de PU.

Estado do canal	Sensor de histórico	
	detectado	não detectado
n	0.05	0.95
p	0.95	0.05
l	0.05	0.95
h	0.05	0.95
u	0.05	0.95

Tabela 8: Tabela de probabilidades *a priori* do sensor de histórico.

Estado do canal	Sensor de Bit	
	baixo	alto
n	0.5	0.5
p	0.5	0.5
l	0.9	0.1
h	0.1	0.9
u	0.5	0.5

Tabela 9: Tabela de probabilidades *a priori* do sensor de bit.

Detecções corretas	52.94199%	Detecções corretas	55.00145%
Falsos positivos	0.02220672%	Falsos positivos	0.22410801%
Falsos negativos	33.27160%	Falsos negativos	35.12942%
Outros erros	9.246863%	Outros erros	9.929338%
Detecções corretas	54.53588%	Detecções corretas	51.91199%
Falsos positivos	1.23679509%	Falsos positivos	2.00226766%
Falsos negativos	34.76599%	Falsos negativos	32.58728%
Outros erros	10.205184%	Outros erros	7.595962%
Detecções corretas	54.90119%	Detecções corretas	54.33991%
Falsos positivos	1.27010332%	Falsos positivos	1.45993166%
Falsos negativos	33.03327%	Falsos negativos	33.25042%
Outros erros	10.456471%	Outros erros	9.353767%
Detecções corretas	54.20737%	Detecções corretas	55.13705%
Falsos positivos	0.42762712%	Falsos positivos	1.03879143%
Falsos negativos	35.09971%	Falsos negativos	36.61038%
Outros erros	9.548630%	Outros erros	13.634905%
Detecções corretas	57.81022%	Detecções corretas	54.80366%
Falsos positivos	0.19738732%	Falsos positivos	0.99142977%
Falsos negativos	31.67294%	Falsos negativos	36.88774%
Outros erros	11.981746%	Outros erros	10.093990%

Tabela 10: Estatísticas referentes à inferência bayesiana.

Detecções corretas	72.56142%	Detecções corretas	73.58277%
Falsos positivos	2.773733%	Falsos positivos	1.152547%
Falsos negativos	15.93073%	Falsos negativos	16.83848%
Outros erros	12.063496%	Outros erros	10.683766%
Detecções corretas	72.77425%	Detecções corretas	72.17432%
Falsos positivos	4.046229%	Falsos positivos	3.433341%
Falsos negativos	16.84034%	Falsos negativos	16.65270%
Outros erros	9.440015%	Outros erros	11.629258%
Detecções corretas	70.21707%	Detecções corretas	71.52208%
Falsos positivos	2.132026%	Falsos positivos	2.464341%
Falsos negativos	13.55488%	Falsos negativos	12.25033%
Outros erros	10.123213%	Outros erros	9.865570%
Detecções corretas	73.70314%	Detecções corretas	70.51181%
Falsos positivos	2.414858%	Falsos positivos	2.134628%
Falsos negativos	14.87663%	Falsos negativos	16.07501%
Outros erros	10.099685%	Outros erros	10.837753%
Detecções corretas	71.45496%	Detecções corretas	72.67558%
Falsos positivos	2.557608%	Falsos positivos	3.454120%
Falsos negativos	15.88878%	Falsos negativos	17.26755%
Outros erros	11.201546%	Outros erros	10.254139%

Tabela 11: Estatísticas referentes à aprendizagem das probabilidades *a priori*.

e comparado seu resultado, como pode ser visto no apêndice A, obtendo diferenças significativas em todos os fatores.

O experimento revelou melhoras significativas na acurácia da rede bayesiana após a aprendizagem das probabilidades *a priori*, contudo, infelizmente os experimentos não revelaram melhoras positivas em todos os fatores. O fator *falsos positivos* teve um incremento na porcentagem média de erros.

Apesar disto pode-se afirmar que a utilização de redes bayesianas para sensoriamento do espectro é suficientemente expressiva para sensoriar e caracterizar o espectro, ou seja, a partir de entradas discretas de sensores de um rádio cognitivo, é possível obter um diagnóstico sobre o estado do canal utilizando-se redes bayesianas. Pode-se também afirmar que, acompanhada de um método de aprendizagem, a rede bayesiana é capaz de melhorar seu desempenho em ambientes de incerteza.

Outra observação a ser feita em tempo é sobre a não-realização de experimentos sobre o módulo de tomada de decisão. Assim como relatado em (LEE; AKYLDIZ, 2011), em que é destacada a incapacidade de comparar seus resultados com outros trabalhos, devido à inexistência de trabalhos que possibilitassem tal comparação, até a data de confecção desta dissertação não foi possível estabelecer experimentos quantitativos relevantes a serem aplicados sobre a rede bayesiana de tomada da decisão, apesar de o modelo ter sido implementado e executado no software Netica (CORP.NORSYS, Última visita em 21 de maio de 2011.). Desta forma, o único experimento realizado sobre o modelo bayesiano para a tomada de decisão foi sua efetiva implementação na ferramenta Netica, confirmando assim a viabilidade prática da proposta apresentada.

6 CONCLUSÃO

Após estudar os mecanismos de cognição do espectro que vêm sendo desenvolvidos a fim de qualificar e dar tratamentos distintos a usuários primários e secundários, bem como as tecnologias cognitivas que vêm sendo gradativamente embarcadas nos dispositivos de rede sem fio, é possível concluir que as tecnologias de CNs podem extrapolar o campo tecnológico e apresentam um grande potencial para, até mesmo, inclusão digital.

Também pode-se observar uma escassez de pesquisadores da área da computação estudando CNs, concluindo-se assim a necessidade de mais estudos que privilegiem a incorporação de tecnologias oriundas da inteligência artificial para este tópico de pesquisa, que vem sendo abordado predominantemente por pesquisadores da área de engenharia elétrica e eletrônica.

Portanto, pode-se concluir que o presente trabalho atua no estado da arte, abordando a aplicação de modelos de inferência probabilística às redes cognitivas sem fio, que, atualmente, constituem a vanguarda da pesquisa científica no campo das redes sem fio.

6.1 PRINCIPAIS CONTRIBUIÇÕES

Nesta dissertação foi apresentado um método de sensoriamento do espectro que efetivamente qualifica a rede que o implementa como cognitiva. Também foi proposto um modelo de tomada de decisão que suporta os conceitos de usuário primário e os conceitos de usuário privado e usuário público, desenvolvidos no capítulo 1.

No que tange aos objetivos específicos, o sensoriamento mostrou-se adequado para evitar interferência em usuários primários, uma vez que o modelo bayesiano mostrado pode ser devidamente ajustado de forma a não apresentar qualquer diminuição da acurácia da detecção em relação à precisão do sensor de PU. Ainda, uma vez utilizada a aprendizagem das probabilidades *a priori*, o modelo apresentou possibilidade de ajuste da detecção em relação a uma detecção de referência.

A primazia dos PUs, por sua vez, foi garantida no modelo de tomada de decisão que executa a ação de abandonar o canal quando é detectada uma ocupação (presente ou futura) por parte de um PU.

Por fim, o mesmo modelo de tomada de decisão contemplou as ações de admitir ou demitir PBs, lançando bases para futuros trabalhos

que efetivamente estudem e desenvolvam este modelo com fins sociais, e quiçá de inclusão digital.

6.2 TRABALHOS FUTUROS

Trabalhos futuros devem aprofundar os algoritmos de aprendizagem, bem como os experimentos e simulações para investigar uma gama mais ampla de fatores que influenciam o sensoriamento e a decisão no espectro.

Um aprofundamento maior também deve ser dado ao modelo matemático que define as equações que tratam do cálculo das probabilidades acerca do sensoriamento e caracterização do espectro.

Ainda, no futuro, deve-se incluir estudos de psicologia comportamental, aprofundando os esforços para identificar a influência das tecnologias propostas no possível comportamento de pessoas efetivamente apropriadas de tais tecnologias.

REFERÊNCIAS BIBLIOGRÁFICAS

AKYILDIZ, I. F. *Broadband Wireless Networking Lab*. Disponível em: <<http://www.ece.gatech.edu/research/labs/bwn/>>.

AKYILDIZ, I. F.; LEE, W.-Y.; CHOWDHURY, K. R. Crahns: Cognitive radio ad hoc networks. *Ad Hoc Netw.*, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 7, p. 810–836, July 2009a. ISSN 1570-8705. Disponível em: <<http://portal.acm.org/citation.cfm?id=1508337.1508834>>.

AKYILDIZ, I. F.; LEE, W.-Y.; CHOWDHURY, K. R. Spectrum management in cognitive radio ad hoc networks. *Netw. Mag. of Global Internetwkg.*, IEEE Press, Piscataway, NJ, USA, v. 23, p. 6–12, July 2009b. ISSN 0890-8044. Disponível em: <<http://dx.doi.org/10.1109/MNET.2009.5191140>>.

AKYILDIZ, I. F. et al. Next generation/dynamic spectrum access/cognitive radio wireless networks: a survey. *Comput. Netw.*, Elsevier North-Holland, Inc., New York, NY, USA, v. 50, n. 13, p. 2127–2159, September 2006. ISSN 1389-1286.

AKYILDIZ, I. F. et al. A survey on spectrum management in cognitive radio networks. *IEEE Communications Magazine*, v. 46, p. 40–48, Apr. 2008 2008.

ATAPATTU, S.; TELLAMBURA, C.; JIANG, H. Energy detection based cooperative spectrum sensing in cognitive radio networks. *Wireless Communications, IEEE Transactions on*, 2011.

BARROS, R. P. de. *Pobreza, Estrutura Familiar e Trabalho*. 1995.

BRANDÃO, M. de F. R.; TRÓCCOLI, B. T. Um modelo de avaliação de projeto de inclusão digital e social: Casa brasil. *Anais do Simpósio Brasileiro de Informática na Educação, Anais do SBIE 2006*, p. 537–546, 2006.

CABRIC, D.; TKACHENKO, A.; BRODERSEN, R. W. Experimental study of spectrum sensing based on energy detection and network cooperation. In: *Proceedings of the first international workshop on Technology and policy for accessing spectrum*. New York, NY, USA: ACM, 2006. (TAPAS '06). ISBN 1-59593-510-X. Disponível em: <<http://doi.acm.org/10.1145/1234388.1234400>>.

CHOI, K. W. Adaptive sensing technique to maximize spectrum utilization in cognitive radio. *Vehicular Technology, IEEE Transactions on*, v. 59, n. 2, p. 992–998, 2010. ISSN 0018-9545.

CORP.NORSYS, S. *Netica Application*. Última visita em 21 de maio de 2011. Disponível em: <<http://www.norsys.com/netica.html>>.

CUSINATO, R. T. *Teoria da decisão sob incerteza e a hipótese da utilidade esperada : conceitos analíticos e paradoxos*. Porto Alegre, RS, BR: Elsevier North-Holland, Inc., September 2003. 2127–2159 p.

ENSERINK, S.; COCHRAN, D. A cyclostationary feature detector. In: *Signals, Systems and Computers, 1994. 1994 Conference Record of the Twenty-Eighth Asilomar Conference on*. [S.l.: s.n.], 1994. v. 2, p. 806–810 vol.2. ISSN 1058-6393.

FCC, F. C. C. *Report of the Spectrum Efficiency Working Group. ET Docket No. 02-135*. November 2002.

FIANI, R. *Teoria dos Jogos*. [S.l.]: Campus, 2009.

HOSSEINI, S.; TEIMOURI, M. Mathematical analysis of primary users characteristics effects on cognitive radios. In: *Advanced Communication Technology (ICACT), 2010 The 12th International Conference on*. [S.l.: s.n.], 2010. v. 2, p. 1252–1255. ISSN 1738-9445.

HOYHTYA, M.; POLLIN, S.; MAMMELA, A. Performance improvement with predictive channel selection for cognitive radios. In: *Cognitive Radio and Advanced Spectrum Management, 2008. CogART 2008. First International Workshop on*. [S.l.: s.n.], 2008. p. 1–5.

HU, F.; WANG, S. Energy detection for spectrum sensing in cognitive radio sensor network over fading channels. In: *Proceedings of the 5th International Conference on Wireless communications, networking and mobile computing*. Piscataway, NJ, USA: IEEE Press, 2009. (WiCOM'09), p. 1511–1514. ISBN 978-1-4244-3692-7. Disponível em: <<http://portal.acm.org/citation.cfm?id=1736862.1737228>>.

KAPLAN, M.; BUZLUCA, F. A dynamic spectrum decision scheme for heterogeneous cognitive radio networks. In: *Computer and Information Sciences, 2009. ISCIS 2009. 24th International Symposium on*. [S.l.: s.n.], 2009. p. 697–702.

LEE, C.; LEE, W. Exploiting spectrum usage patterns for efficient spectrum management in cognitive radio networks. In: *Advanced*

Information Networking and Applications (AINA), 2010 24th IEEE International Conference on. [S.l.: s.n.], 2010. p. 320–327. ISSN 1550-445X.

LEE, W.-Y.; AKYILDIZ, I. Optimal spectrum sensing framework for cognitive radio networks. *Wireless Communications, IEEE Transactions on*, v. 7, n. 10, p. 3845–3857, 2008. ISSN 1536-1276.

LEE, W.-Y.; AKYILDIZ, I. F. A spectrum decision framework for cognitive radio networks. *IEEE Transactions on Mobile Computing*, IEEE Educational Activities Department, Piscataway, NJ, USA, v. 10, p. 161–174, February 2011. ISSN 1536-1233. Disponível em: <<http://dx.doi.org/10.1109/TMC.2010.147>>.

LIU, X.; KRISHNAMACHARI, B.; LIU, H. Channel selection in multi-channel opportunistic spectrum access networks with perfect sensing. In: *New Frontiers in Dynamic Spectrum, 2010 IEEE Symposium on.* [S.l.: s.n.], 2010. p. 1–8.

MENDES, R. d. S.; WESTPHALL, C. B.; GARCIA, E. R. A framework to radio layer operation in cognitive networks. In: *Proceedings of the 2010 Sixth International Conference on Networking and Services.* Washington, DC, USA: IEEE Computer Society, 2010. (ICNS '10), p. 299–304. ISBN 978-0-7695-3969-0.

MITOLA, J. I. *Cognitive Radio An Integrated Agent Architecture for Software Defined Radio.* Tese (Doutorado) — Royal Institute of Technology (KTH), may 2000.

PEARL, J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference.* [S.l.]: Morgan Kaufmann, 1988.

SBC, S. B. de C. *Relatório Final dos Grandes Desafios da Pesquisa em Computação no Brasil - 2006 - 2016.* Última visita em 21 de maio de 2011. Disponível em: <[http://www.ic.unicamp.br/~cmbm/desafios_{5BC}/](http://www.ic.unicamp.br/~cmbm/desafios_{5BC}/>)>.

TEIXEIRA, E. D. *Uma análise experimental de alocação de canal para redes sem fio 802.11.* 65 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina (UFSC). Programa de Pós-Graduação em Ciência da Computação., 2010.

THOMAS, R. W.; DASILVA, L. A.; MACKENZIE, A. B. Cognitive networks. In: *Proceedings of IEEE DySPAN 2005.* [S.l.: s.n.], 2005. p. 352–360.

TURIN, G. An introduction to matched filters. *IEEE Transactions on Information Theory*, v. 6, p. 311–329, 1960.

ZHOU, X. et al. Probability-based combination for cooperative spectrum sensing. *Trans. Comm.*, IEEE Press, Piscataway, NJ, USA, v. 58, p. 463–466, February 2010. ISSN 0090-6778. Disponível em: <<http://dx.doi.org/10.1109/TCOMM.2010.02.080154>>.

APÊNDICE A – Experimentos realizados - testes t-Student

A.1 TESTE DAS DECISÕES CORRETAS

```
t.test(dc1,dc2)
```

```
Welch Two Sample t-test
```

```
data: dc1 and dc2\\
t = -28.7121, df = 16.925, p-value = 8.497e-16\\
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -18.84935 -16.26799
sample estimates:
mean of x mean of y
 54.55907  72.11774
```

A.2 TESTE DOS FALSOS POSITIVOS

```
t.test(fp1,fp2)
```

```
Welch Two Sample t-test
```

```
data: fp1 and fp2
t = -5.3486, df = 17.03, p-value = 5.288e-05
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -2.467097 -1.071459
sample estimates:
mean of x mean of y
0.8870648 2.6563431
```

A.3 TESTE DOS FALSOS NEGATIVOS

```
t.test(fn1,fn2)
```

```
Welch Two Sample t-test
```

```
data: fn1 and fn2
t = 24.8651, df = 17.897, p-value = 2.499e-15
alternative hypothesis: true difference in means is not equal to 0
```

95 percent confidence interval:

17.03999 20.18667

sample estimates:

mean of x mean of y

34.23087 15.61754

A.4 TESTE DOS OUTROS ERROS

t.test(oe1,oe2)

Welch Two Sample t-test

data: oe1 and oe2

t = -0.7184, df = 13.308, p-value = 0.4849

alternative hypothesis: true difference in means is not equal to 0

95 percent confidence interval:

-1.6607246 0.8304074

sample estimates:

mean of x mean of y

10.20469 10.61984