



REDE DISTRIBUÍDA PARA SENSORIAMENTO DE ESPECTRO USANDO
ATUALIZAÇÃO SELETIVA

Francisco Carlos Ribeiro Junior

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: Marcello Luiz Rodrigues de
Campos
Stefan Werner

Rio de Janeiro
Março de 2013

REDE DISTRIBUÍDA PARA SENSORIAMENTO DE ESPECTRO USANDO
ATUALIZAÇÃO SELETIVA

Francisco Carlos Ribeiro Junior

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Marcello Luiz Rodrigues de Campos, Ph.D.

Prof. Paulo Sergio Ramirez Diniz, Ph.D.

Prof. José Antonio Apolinário Junior, D.Sc.

Prof. Charles Casimiro Cavalcante, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2013

Ribeiro Junior, Francisco Carlos

Rede Distribuída para Sensoriamento de Espectro usando Atualização Seletiva/Francisco Carlos Ribeiro Junior. – Rio de Janeiro: UFRJ/COPPE, 2013.

XI, 61 p.: il.; 29,7cm.

Orientadores: Marcello Luiz Rodrigues de Campos
Stefan Werner

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2013.

Referências Bibliográficas: p. 56 – 61.

1. Rádio cognitivo.
 2. Redes cooperativas.
 3. Filtragem adaptativa.
- I. Campos, Marcello Luiz Rodrigues de *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

À minha família.

Agradecimentos

Aos meus orientadores, professores Marcello e Stefan.

Aos colegas do Laboratório de Processamento de Sinais.

À Universidade Federal do Rio de Janeiro.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

REDE DISTRIBUÍDA PARA SENSORIAMENTO DE ESPECTRO USANDO ATUALIZAÇÃO SELETIVA

Francisco Carlos Ribeiro Junior

Março/2013

Orientadores: Marcello Luiz Rodrigues de Campos
Stefan Werner

Programa: Engenharia Elétrica

O rádio cognitivo introduz uma nova política de acesso ao espectro de frequências nos sistemas de comunicações. Usuários equipados com essa tecnologia são capazes de encontrar e acessar oportunisticamente as frequências livres da rede quando outros usuários, detentores da licença de uso dos canais, estiverem ausentes. Para não causarem interferência, os rádios realizam o sensoriamento do espectro e, a partir dos dados coletados do ambiente, decidem se há usuário licenciado ativo em cada frequência. O sensoriamento pode ser feito isoladamente pelos aparelhos ou eles podem se organizar em uma rede cooperativa, na qual compartilham informações em prol de uma decisão conjunta. Redes desse tipo promovem detecção mais confiável, mas trazem complexidades adicionais. Nas estratégias distribuídas, em que os rádios cooperam diretamente, cada nó precisa estar equipado com poder computacional para processar os dados vizinhos. Aliado a isso, muitas propostas distribuídas na literatura preveem longos períodos de cooperação entre eles, aumentando o tempo até a decisão final, o tráfego de informações pela rede e a carga de processamento no aparelho. Como alternativa, este trabalho propõe uma nova rede distribuída para sensoriamento, cuja cooperação em apenas dois passos, *soft* e *hard*, oferece simplicidade, rapidez na decisão e bom desempenho, especialmente quando implementada em dupla topologia. Um combinador adaptativo simples, desenvolvido para o passo *soft*, torna a estratégia proposta adaptável a ambientes dinâmicos e é comparável ao combinador linear ótimo. Quando empregado com um algoritmo baseado em *set-membership* para atualização seletiva dos coeficientes, ele ainda reduz consideravelmente o processamento em cada nó. Resultados são apresentados em termos de convergência dos coeficientes e de curvas de característica de operação do receptor.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DISTRIBUTED SPECTRUM SENSING NETWORK USING SELECTIVE UPDATING

Francisco Carlos Ribeiro Junior

March/2013

Advisors: Marcello Luiz Rodrigues de Campos
Stefan Werner

Department: Electrical Engineering

Cognitive radio introduces a new policy for spectrum access in communications systems. Users equipped with this technology are capable to find and access frequency holes for opportunistic transmission when other users, who detain the ownership of such channels, are absent. In order to avoid interference, cognitive radios employ spectrum sensing and, based on the data collected from the environment, decide if there is an active licensed user in each frequency band. Spectrum sensing can be done by each device separately or they can share information among themselves for a joint decision in a cooperative network. Cooperation improves detection reliability but also leads to additional complexity. For distributed strategies, in which radios cooperate directly, each node should be equipped with computational capabilities to process neighboring data. Furthermore, most distributed approaches in the literature require long-term cooperation among them for the final decision, increasing delay, information traffic along the network and amount of processing at the device. As an alternative, this work proposes a novel distributed spectrum sensing network, whose cooperation in only two steps, *soft* and *hard*, offers simplicity, rapid decision makings and good performance, especially when implemented in a double-topology scheme. A simple, adaptive combiner developed for the *soft* step makes the proposed strategy adaptable to changing environments and is comparable to the optimal linear combiner. When employed with a *set-membership*-based algorithm for selective coefficient updating, the combiner further reduces processing at each node considerably. Results are presented in terms of coefficient convergence behavior and of receiver operating characteristic curves.

Sumário

Lista de Figuras	x
Lista de Tabelas	xi
1 Introdução	1
1.1 Objetivos	3
1.2 Organização do Trabalho	4
2 Rádio Cognitivo	5
2.1 Ciclo Cognitivo	6
2.2 Sensoriamento de Espectro	7
2.2.1 Desempenho da Detecção	7
2.2.2 Técnicas de Sensoriamento	9
2.3 Detector de Energia	11
2.3.1 Desempenho do Detector de Energia	12
2.3.2 SNR <i>Wall</i> e a Incerteza do Ruído	15
3 Sensoriamento Cooperativo de Espectro	17
3.1 Estratégias de Cooperação	18
3.2 Ganho vs. <i>Overhead</i> de Cooperação	19
3.3 Seleção de Usuário	21
3.4 Tipos de Combinação	23
3.4.1 Combinação <i>Hard</i>	23
3.4.2 Combinação <i>Soft</i>	24
3.5 Combinação Linear	25
3.5.1 Desempenho da Detecção Conjunta	26
3.5.2 Combinador Linear Ótimo e Alternativas	27
4 Rede Distribuída Proposta	29
4.1 Cooperação em Dois Passos	30
4.1.1 Passo 1: Combinação <i>Soft</i>	31
4.1.2 Passo 2: Combinação <i>Hard</i>	34

4.1.3	Resultados	36
4.2	Combinador <i>Soft</i> com Atualização Seletiva	40
4.2.1	Algoritmo SU-LMS	42
4.2.2	Resultados	43
4.3	Cooperação com Dupla Topologia	45
4.3.1	Topologias Primária e Complementar	47
4.3.2	Eliminação da Redundância	49
4.3.3	Resultados	50
5	Conclusão	54
	Referências Bibliográficas	56

Lista de Figuras

2.1	Etapas do ciclo cognitivo.	6
2.2	Curvas de característica de operação do receptor.	9
2.3	Principais técnicas de sensoriamento; detector de energia em destaque.	10
2.4	Diagrama simples de um detector de energia.	11
3.1	Rede cognitiva, formada por usuários primários e secundários.	18
3.2	Estratégias para sensoriamento cooperativo.	19
3.3	Desafios para a seleção de usuário.	22
4.1	Rede distribuída com $M = 12$ nós.	31
4.2	Combinador linear adaptativo proposto.	33
4.3	Rede distribuída simulada e as SNR (em dB) dos nós.	37
4.4	Convergência do LMS e curvas C-ROC relativos ao Nó 4.	38
4.5	Convergência do LMS e curvas C-ROC relativos ao Nó 9.	39
4.6	Convergência do SU-LMS e curvas C-ROC relativos ao Nó 4.	44
4.7	Convergência do SU-LMS e curvas C-ROC relativos ao Nó 9.	45
4.8	Rede com $M = 12$ nós organizados em única topologia.	46
4.9	Rede com $M = 12$ nós organizados em dupla topologia.	48
4.10	Curvas C-ROC relativas aos Nós 4 e 9 usando única e dupla topologia.	51
4.11	Rede com dupla topologia simulada e as SNR (em dB) dos nós.	52
4.12	Variação de desempenho entre os nós usando única e dupla topologia.	53

Lista de Tabelas

4.1	Algoritmo SU-LMS proposto.	42
4.2	Percentual de atualizações do combinador adaptativo do Nó 4.	44
4.3	Percentual de atualizações do combinador adaptativo do Nó 9.	45
4.4	Algoritmo sequencial gerador de topologias proposto ($T = 1, 2$).	49

Capítulo 1

Introdução

O espectro de frequências é um dos elementos mais importantes dos sistemas de comunicações sem fio. Graças a ele, é possível oferecer diferentes serviços e atender simultaneamente a vários usuários. Por outro lado, sua escassez natural tem se tornado um problema crítico diante da constante necessidade de ampliação dessas redes, seja na capacidade de assinantes, seja na oferta de aplicativos e taxas de transmissão. Torna-se, assim, crucial desenvolver soluções que permitam utilizar o espectro disponível com máxima eficiência.

A coordenação do uso do espectro eletromagnético fica a cargo, em nível mundial, da *International Telecommunications Union* (ITU) e, em nível brasileiro, da Agência Nacional de Telecomunicações (ANATEL). A política de concessão de frequências empregada por elas segue, atualmente, um paradigma denominado *Fixed Spectrum Access* (FSA), segundo o qual o espectro total é subdividido em bandas fixas e destinadas a cada tipo de serviço. Assim, durante a vigência de uma concessão, somente a prestadora autorizada pode usufruir de uma determinada faixa de frequências, independentemente de ela fazer muito ou pouco uso do recurso.

Naturalmente, embora tenha direito, a permissionária não utiliza plenamente sua banda durante todo o tempo. Conforme mostrado em estudo de 2002 da *Federal Communications Commission* (FCC), a taxa de ocupação espectral durante um dia pode variar entre 15 e 85%, dependendo do período e da posição geográfica [1]. Diante disso, a política de alocação fixa se mostra ineficaz ao longo dos anos: embora tenha representado uma solução simples e adequada à demanda inicial, ela não permite que frequências temporariamente ociosas do espectro possam ser aproveitadas por outros sistemas, gerando desperdício e agravando o problema da escassez de banda. Isso tem limitado a evolução das comunicações sem fio, a despeito dos esforços da pesquisa em desenvolver tecnologias que aumentem a eficiência espectral, mas que não constituem solução definitiva em longo prazo.

De modo a resolver esse problema, surgiu um novo paradigma para o uso do espectro, em que a alocação passa a ser feita de maneira livre e orientada pela

demanda. Conhecida como *Dynamic Spectrum Access* (DSA), essa nova filosofia permite uma utilização eficiente do recurso, na medida em que ele não é mais dedicado. Mas, para que isso seja possível, sistemas que implementarem acesso dinâmico ao espectro devem ser “inteligentes” o bastante para identificar, em dado momento, as frequências livres na rede, onde quer que elas estejam situadas na banda [2].

O advento do *rádio cognitivo* [3, 4] trouxe a “inteligência” que viabilizou a concepção das redes de acesso dinâmico. Dispositivos equipados com essa tecnologia são capazes de alterar seus parâmetros de transmissão via *software* e, mais além, podem fazê-lo com base em informações que eles mesmos “percebem” do canal de transmissão. Dessa maneira, por meio de uma observação (sensoriamento) do meio, o rádio cognitivo pode concluir, por exemplo, quais faixas de frequências estão ociosas e, com essa informação, sintonizar sua portadora local dentro dessas faixas.

O principal desafio em se desenvolver redes de acesso dinâmico ao espectro está no fato de que elas devem coexistir com as já estabelecidas redes de acesso fixo. Em outras palavras, o acesso à banda pelas redes DSA deve ocorrer de maneira oportunista, já que os usuários pertencentes às redes FSA – conhecidos como *usuários primários* – terão sempre a prioridade no uso das frequências. Aos usuários das redes DSA – ou *usuários secundários* –, cabe garantir mínima ou nenhuma interferência aos usuários primários enquanto estiverem aproveitando os recursos espectrais livres.

É, portanto, o *sensoriamento de espectro*, feito pelos rádios cognitivos, o responsável por garantir a interoperabilidade entre as duas redes, dinâmica e fixa. Ao observar o canal, um usuário secundário deve ser capaz não somente de detectar corretamente uma frequência ociosa, mas também de perceber quando um usuário primário ingressa na rede e começa a ocupá-la novamente. Por essa razão, desenvolver estratégias confiáveis de sensoriamento é de grande interesse das pesquisas envolvendo rádio cognitivo e gerenciamento dinâmico de espectro.

Diversas técnicas de sensoriamento já estudadas na literatura oferecem diferentes níveis de compromisso entre complexidade e poder de detecção, além de serem aplicáveis de acordo com o tipo de informação disponível *a priori* acerca da rede primária. A técnica baseada em detector de energia, por exemplo, é a mais simples e não requer qualquer informação prévia sobre o sinal primário, mas oferece o desempenho mais modesto. Em contrapartida, a técnica de detecção por filtro casado é considerada ótima em maximizar a razão sinal-ruído na saída do detector, desde que o sinal transmitido pela rede primária seja conhecido.

Por outro lado, independentemente do tipo de sensoriamento adotado, decidir pela presença ou ausência de usuário primário será uma tarefa tão mais confiável quanto maior for a integridade dos dados extraídos do canal pelo rádio cognitivo, o que nem sempre é possível em um ambiente sujeito a desvanecimento e interferências. Por conta disso, são também encontradas na literatura propostas de as-

sociação das técnicas de sensoriamento local com alguma estratégia de cooperação entre os usuários da rede secundária, de forma que a decisão final seja fruto das diversas medidas individuais processadas em conjunto. Isso permite, por exemplo, que um rádio geograficamente escondido do transmissor primário consiga detectá-lo usufruindo de informações mais acuradas provenientes de outros nós da rede.

Apesar de reduzir consideravelmente a probabilidade de interferência sobre as redes licenciadas, empregar *sensoriamento cooperativo de espectro* aumenta o grau de complexidade das redes cognitivas. Além disso, gera novos desafios para o seu planejamento, como determinar: quantos e quais nós da rede irão cooperar entre si, de que maneira – centralizada ou distribuída – suas informações serão concentradas, qual técnica de combinação de dados será utilizada ou, ainda, por quanto tempo os nós permanecerão interagindo até a decisão. Assim sendo, o projeto uma rede cooperativa deve levar em conta tanto os níveis de aproveitamento espectral e de interferência desejados, como o poder computacional disponível.

1.1 Objetivos

Este trabalho propõe uma solução de baixa complexidade para sensoriamento cooperativo de espectro em redes cognitivas. No esquema proposto, cada nó da rede implementa um detector de energia para sensoriamento, com o qual produz, periodicamente, estimativas de energia do canal. Em seguida, realiza cooperação do tipo distribuída, isto é, diretamente entre os seus vizinhos na rede, dispensando a necessidade de uma central para a fusão das informações.

A cooperação proposta se dá em dois passos: no primeiro, chamado combinação *soft*, cada nó recebe as estimativas de energia dos seus vizinhos e, a partir de uma combinação delas com sua estimativa local, toma uma primeira decisão, binária, acerca da disponibilidade do canal. No segundo passo, denominado combinação *hard*, cada nó reúne sua própria decisão binária com as dos demais rádios, de maneira que a fusão delas leve a uma decisão consensual – canal “livre” ou “ocupado”.

Com essa configuração, a estratégia de cooperação proposta neste trabalho busca oferecer, como contribuições principais:

1. *Menor tráfego entre os nós*: outros esquemas de sensoriamento distribuído encontrados na literatura, principalmente os baseados em técnicas de estimação de parâmetros, preveem longos períodos de compartilhamento de informações entre os rádios [5–7]. A estratégia proposta, por sua vez, oferece detecção em apenas duas iterações, permitindo que a rede gaste menos tempo (e recursos) decidindo e mais aproveitando o espectro para transmissões;
2. *Menor complexidade no nó*: para a combinação *soft*, é também desenvolvido

um combinador linear adaptativo utilizando o algoritmo *Least-Mean Squares* (LMS), mais simples e com bom desempenho frente a outras técnicas *soft* existentes [8–10]. Aliada ao combinador LMS, uma estratégia de seleção baseada em *set-membership* permite que o nó processe apenas dados “conjuntamente informativos” provenientes dos vizinhos, reduzindo a quantidade de processamento local e, conseqüentemente, garantindo ao dispositivo móvel menor complexidade e maior autonomia.

1.2 Organização do Trabalho

O restante do texto está organizado da seguinte forma. O Capítulo 2 introduz alguns fundamentos de rádio cognitivo, em particular os diretamente ligados à identificação de oportunidades de transmissão: sensoriamento de espectro e teste de hipóteses.

O Capítulo 3 aborda sensoriamento cooperativo de espectro. São citados alguns desafios inerentes à montagem de uma rede cooperativa, com destaque para a seleção de usuário. Também são apresentadas as principais estratégias de cooperação e técnicas de combinação de dados encontradas na literatura.

O Capítulo 4 descreve a rede distribuída em dois passos e exhibe alguns resultados. São detalhados os passos de cooperação *soft* e *hard*, bem como o combinador linear adaptativo desenvolvido para o passo *soft*. O algoritmo LMS com atualização seletiva dos coeficientes e uma variação da cooperação empregando topologias de rede diferentes em cada passo também são investigados nas simulações.

O Capítulo 5 apresenta as conclusões.

Capítulo 2

Rádio Cognitivo

Em seu trabalho pioneiro no assunto, Mitola introduz o termo rádio cognitivo como um elemento de comunicação capaz de “aprender pela interação com o usuário e com o ambiente” [4]. Haykin estende essa definição em [11], apresentando-o como um “sistema de comunicação ciente do ambiente externo, [...] que aprende com o meio e adapta seus estados internos às variações estatísticas nos estímulos de radiofrequência, através da alteração de certos parâmetros de transmissão (potência, portadora, modulação) em tempo real”. Por conta dessa flexibilidade, a principal contribuição da tecnologia de rádio cognitivo para os sistemas de comunicações atuais é possibilitar uma utilização mais eficiente dos recursos de radiofrequência, especialmente dentro do novo paradigma de acesso dinâmico ao espectro.

O rádio cognitivo é um dispositivo “inteligente”, no sentido de que ele, de maneira autônoma, procura as melhores oportunidades de transmissão, planeja suas próprias diretrizes de funcionamento e as altera conforme novas oportunidades são encontradas. Para isso, ele conta com duas capacidades principais [11]:

- *Capacidade cognitiva*: significa que ele é capaz de perceber o canal de comunicação e, a partir do que é observado, extrair informações que orientem o seu funcionamento;
- *Reconfigurabilidade*: diz respeito à capacidade do rádio em se reprogramar para atender dinamicamente a novas diretrizes de operação.

Essas duas características – cognição e reconfigurabilidade – aparecem de maneira consecutiva durante o funcionamento do rádio cognitivo: primeiramente, ele compreende o meio; em seguida, reprograma-se de acordo com o que aferiu. Graças à evolução das técnicas de processamento de sinais e de aprendizagem de máquina, o rádio é capaz de obter, a partir de dados coletados do ambiente, informações como frequências ocupadas da rede, posição dos outros usuários ou mesmo o tipo de sinal transmitido por eles. Por outro lado, com o advento da tecnologia de rádio definido

por *software* (*Software-Defined Radio* – SDR) [12], o dispositivo pode aproveitar essas informações para ajustar seus parâmetros locais de transmissão e recepção (potência, modulação, frequência da portadora etc.) via *software* e, assim, operar seguindo, em tempo real, as mudanças observadas na rede durante a cognição.

2.1 Ciclo Cognitivo

As funcionalidades do rádio que envolvem interação com o ambiente estão associadas à sua capacidade cognitiva. Elas são executadas periodicamente, e podem ser organizadas na forma de um ciclo cognitivo, dentro do qual o rádio observa o meio, orienta-se, cria planos, toma decisões e age com base nelas, além de aprender com a experiência [4]. Em uma versão simplificada, o ciclo cognitivo pode ser dividido em três etapas [11]: *sensoriamento*, *análise* e *gerenciamento* do espectro. Um esquema com as etapas do ciclo cognitivo é mostrado na Figura 2.1.

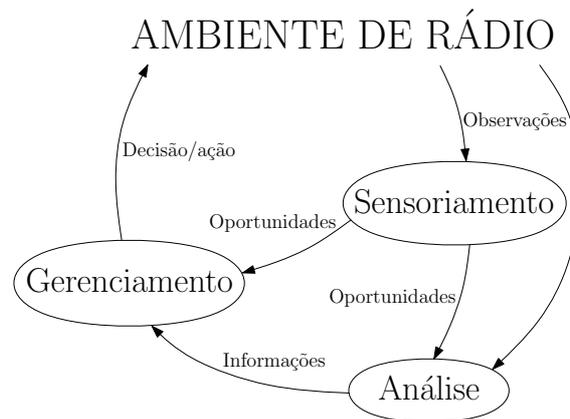


Figura 2.1: Etapas do ciclo cognitivo.

Na etapa de sensoriamento, que é o foco deste trabalho, o aparelho recolhe observações do ambiente com o objetivo de detectar faixas de frequências livres no espectro, consideradas oportunidades de transmissão para o rádio. Na etapa seguinte, a de análise, novas observações são coletadas do ambiente nas faixas selecionadas durante o sensoriamento. O intuito é estimar a duração dessas oportunidades, calcular parâmetros de qualidade como nível de interferência, perda de pacotes e taxa de erros e, com isso, avaliar a capacidade de transmissão que elas oferecem. De posse dos dados do sensoriamento e da análise, e ciente da qualidade de serviço que deve entregar ao usuário em dado momento, o rádio decide, na etapa de gerenciamento, quais oportunidades utilizar e como ajustar seus parâmetros de transmissão e recepção para ocupá-las com máxima eficiência. Ao fim do ciclo cognitivo, as decisões do gerenciamento orientam a reconfigurabilidade do aparelho.

2.2 Sensoriamento de Espectro

O novo paradigma de acesso dinâmico ao espectro prevê a operação concomitante, em um mesmo ambiente, de duas redes de comunicação distintas: a rede primária, detentora da licença de uso do espectro eletromagnético; e a rede secundária, que não possui a concessão de uso. Com o avanço da tecnologia de rádio cognitivo, tornou-se possível à rede secundária aproveitar os recursos espectrais temporariamente não utilizados pela rede primária. Para isso, os usuários secundários devem lançar mão da capacidade cognitiva de seus rádios para identificar as faixas ociosas do canal, coordenar entre si o acesso oportunista a esses recursos e abandoná-los assim que um usuário licenciado reivindicar o uso da banda.

Assim sendo, de modo a perceber a presença (ou ausência) de usuário ativo na frequência desejada, um rádio cognitivo i faz o sensoriamento do canal dentro de um intervalo de tempo e em determinada posição geográfica. Nessas condições, ele capta do ambiente amostras de um sinal modelado, no instante discreto k , segundo duas hipóteses possíveis [8]:

$$x_i(k) = \begin{cases} v_i(k) & , \text{ se } \mathcal{H}_0, \\ h_i s(k) + v_i(k) & , \text{ se } \mathcal{H}_1. \end{cases} \quad (2.1)$$

Sob a hipótese \mathcal{H}_0 , correspondente ao canal livre, o sinal $x_i(k)$ é apenas o ruído do ambiente $v_i(k)$, Gaussiano, de variância $\sigma_{v_i}^2$. Já sob a hipótese \mathcal{H}_1 , correspondente ao canal ocupado, $x_i(k)$ é uma versão escalada (pelo ganho do canal h_i) do sinal transmitido pelo usuário primário, $s(k)$, mais o ruído. Observe que h_i e $\sigma_{v_i}^2$ são grandezas que variam de acordo com a posição relativa entre usuário e rádio, além de dependerem do perfil do meio de transmissão.

O problema de detecção recai, então, em um teste de hipóteses binário: com as amostras de $x_i(k)$, o aparelho produz uma estatística de teste, $T(x_i)$, a partir da qual decide em que caso, \mathcal{H}_0 ou \mathcal{H}_1 , enquadra-se o sinal coletado naquela banda. E essa decisão não é única, mas deve ser atualizada regularmente por conta da dinâmica de alocação da rede primária.

2.2.1 Desempenho da Detecção

A coexistência das duas redes de serviço no mesmo ambiente está condicionada à qualidade do sensoriamento dos rádios cognitivos, isto é, quão confiáveis eles são em apontar uma frequência livre ou um usuário primário ativo. Nesse aspecto, é importante acompanhar a eficácia da rede secundária. Em aplicações de classificação binária, duas métricas são úteis na avaliação do desempenho [13]: as probabilidades

de *detecção* (P_d) e de *alarme falso* (P_f), definidas como

$$P_d = P[\text{decidir } \mathcal{H}_1 \mid \mathcal{H}_1 \text{ é verdadeiro}], \quad (2.2a)$$

$$P_f = P[\text{decidir } \mathcal{H}_1 \mid \mathcal{H}_0 \text{ é verdadeiro}]. \quad (2.2b)$$

A probabilidade de detecção é um indicador da eficiência do rádio em encontrar o usuário primário ativo. Quanto maior o seu valor, menor a chance de interferência, já que o dispositivo descarta uma frequência realmente em uso. Por outro lado, a probabilidade de alarme falso é um indicador de desperdício: ele mede a chance de o rádio apontar erroneamente um usuário primário e, assim, deixar de utilizar uma banda disponível. Reduzindo-se o seu valor, aumenta-se o aproveitamento da rede secundária, o que melhora a eficiência espectral do sistema.

Obviamente, o cenário ideal seria aquele em que o rádio conseguisse garantir probabilidade de detecção igual a um (interesse da rede primária) e de alarme falso igual a zero (desejável pela rede secundária). No entanto, há dois inconvenientes: o primeiro são os desafios inerentes à transmissão sem fio, que impedem que o aparelho detecte sem erros. O segundo reside no fato de que, para um intervalo fixo de sensoriamento, não é possível maximizar um indicador e minimizar o outro simultaneamente. Como ficará mais claro adiante, ambas as probabilidades respondem no mesmo sentido a ajustes no limiar de decisão do classificador e a variações no meio de transmissão, de maneira que otimizar um lado implica, necessariamente, assumir certo prejuízo de desempenho no outro.

Por permitir uma visualização intuitiva da influência dos parâmetros de ajuste sobre os indicadores, é comum utilizar curvas de característica de operação do receptor (*Receiver Operating Characteristic* – ROC) para avaliar a qualidade da detecção [13]. Uma curva ROC é um gráfico de pontos sobre o espaço de coordenadas $P_f \times P_d$, cada um deles correspondendo ao par de desempenho (P_f, P_d) dado por um limiar de decisão específico do classificador. Alternativamente, pode-se recorrer às curvas ROC complementares (*Complementary ROC* – C-ROC), em que os pontos são plotados sobre o espaço $P_f \times (1 - P_d)$ [14]. Exemplos das duas curvas são mostrados na Figura 2.2.

Note que tanto a curva ROC quanto a C-ROC permitem verificar a variação, no mesmo sentido, dos indicadores de desempenho. De fato, ambas as ferramentas ajudam a traçar um perfil de desempenho máximo alcançável pelo detector em dado ambiente a partir de um certo conjunto de limiares de decisão. Assim, o rádio cognitivo realiza ajustes no sensoriamento – ou, equivalentemente, altera o seu ponto de operação – conforme a necessidade.

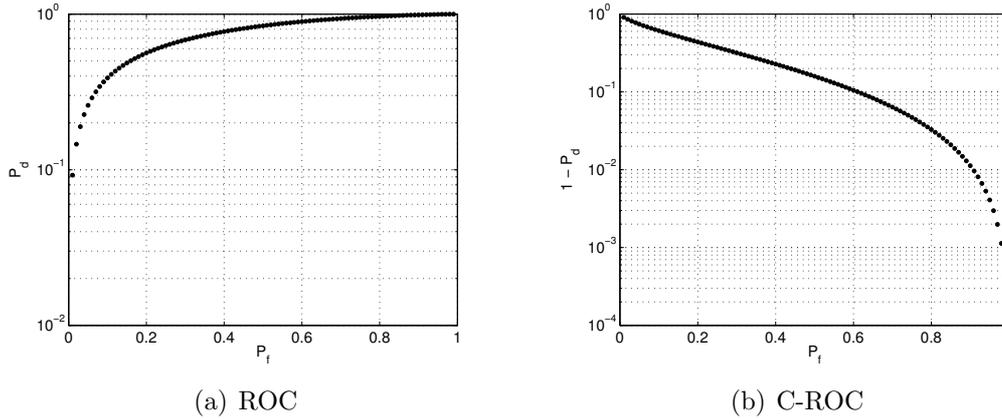


Figura 2.2: Curvas de característica de operação do receptor.

2.2.2 Técnicas de Sensoriamento

Quanto às técnicas para sensoriamento de espectro existentes, elas são geralmente classificadas de acordo com a quantidade de faixas simultâneas sensoriadas (*banda estreita* e *banda larga*) e a partir do nível de conhecimento prévio requerido pelo detector acerca do sinal da rede primária (*coerentes* e *não-coerentes*). O esquema da Figura 2.3 [15] organiza as principais delas utilizando os dois critérios.

Nas técnicas de sensoriamento de banda estreita, o detector, por meio de um filtro passabanda sintonizável, percorre o espectro processando uma faixa estreita de cada vez. Já as técnicas de banda larga usualmente empregam bancos de filtros passabanda em paralelo ou arquiteturas de banda larga com processadores digitais de alta velocidade. Embora estas agilizem o sensoriamento de todo o espectro de interesse, sua carga computacional é muito maior, seja pelo grande número de elementos no *frontend* do detector, seja pelas altas taxas de amostragem desempenhadas pelos processadores [15]. Algumas soluções de banda larga na literatura buscam contornar essas limitações com o uso de *detecção wavelet* [16], em substituição aos múltiplos filtros passabanda; e de *compressed sensing* [17], pela subamostragem. Ainda assim, maior atenção é dada às soluções de banda estreita, dentre as quais se destacam: o *detector por filtro casado*, o *detector cicloestacionário* e o *detector de energia*.

O detector por filtro casado é uma técnica de sensoriamento do tipo coerente, ou seja, ele requer algum nível de informação *a priori* sobre o sinal primário. Mais precisamente, seu funcionamento depende do conhecimento integral da forma de onda $s(k)$ transmitida pelo usuário licenciado, com a qual um detector i correlaciona sua observação $x_i(k)$ durante uma janela de sensoriamento de N amostras [18],

$$T(x_i) = \sum_{k=1}^N x_i(k)s^*(k),$$

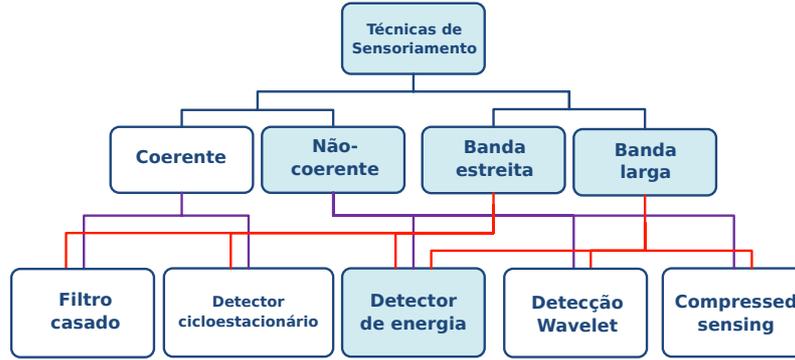


Figura 2.3: Principais técnicas de sensoriamento; detector de energia em destaque.

e em seguida classifica o teste $T(x_i)$ usando um limiar de decisão. Esta técnica é considerada ótima em maximizar a razão sinal-ruído recebida (*Signal-to-Noise Ratio* - SNR) e oferece bom desempenho de detecção com poucas amostras de sensoriamento [19]. Por outro lado, implementar filtro casado requer não apenas um alto custo computacional e energético, como também um perfeito sincronismo entre detector e usuário primário [20].

Uma opção menos restritiva para sensoriamento coerente é o detector cicloestacionário. Diferentemente do filtro casado, que precisa de informações específicas (portadora, tipo de modulação, formatação de pulso etc.) para reproduzir localmente o sinal primário $s(k)$, esta técnica aproveita as periodicidades observadas nos parâmetros estatísticos de $s(k)$, decorrentes do seu formato de onda sinusoidal, da presença de símbolos-piloto, de preâmbulos, dentre outros. Elas podem ser exploradas, no domínio da frequência, através da função correlação espectral $S_s^\alpha(f)$, obtida pela transformada de Fourier da função autocorrelação cíclica de $s(k)$ (para mais detalhes, consulte [18]). Se um detector i conhecer $S_s^\alpha(f)$ *a priori*, poderá compará-la a uma estimativa da função correlação espectral do sinal sensoriado $x_i(k)$,

$$T(x_i) = \sum_f \hat{S}_{x_i}^\alpha(f) [S_s^\alpha(f)]^*,$$

produzindo o teste $T(x_i)$ que levará à decisão [18]. Dessa forma, o rádio será capaz de distinguir o sinal em meio ao ruído, visto que este não apresenta periodicidade. Mas a desvantagem é o elevado processamento associado ao método, além de ser necessário um grande intervalo de sensoriamento para uma detecção eficiente [15].

O grande inconveniente das técnicas de sensoriamento coerentes é que, via de regra, não há comunicação entre redes primária e secundária, de maneira que obter qualquer informação sobre o sinal dos usuários licenciados é difícil na prática. Ademais, e especialmente acerca do filtro casado, caso o sensoriamento seja realizado em uma faixa espectral ocupada por vários padrões de serviço, o rádio deve imple-

mentar um *frontend* voltado à detecção de cada um deles separadamente [19]. Por isso, apesar de oferecerem, em geral, desempenho inferior, as técnicas não-coerentes despontam como opções sob a perspectiva de tornar o sensoriamento – apenas o primeiro passo do ciclo cognitivo – o mais simples possível.

Não por acaso, a técnica de detecção de energia [21] é a mais recorrente na literatura. Além de ser do tipo não-coerente, isto é, não depender do tipo de sinal a ser sensoriado, sua implementação requer muito pouco processamento. É aplicável tanto para sensoriamento em banda estreita quanto em banda larga, e seu desempenho limitado pode ser compensado com estratégias de cooperação. Por essas razões, é também a técnica adotada neste trabalho.

2.3 Detector de Energia

Considere a aplicação de sensoriamento de espectro em banda estreita. A estrutura básica de um detector de energia desse tipo é apresentada na Figura 2.4, consistindo em um filtro passabanda, um dispositivo de elevação quadrática e um integrador [22]. A função do filtro, além de sintonizar o detector na frequência de interesse, é limitar a banda do ruído $v_i(k)$ e normalizar a sua variância $\sigma_{v_i}^2$.

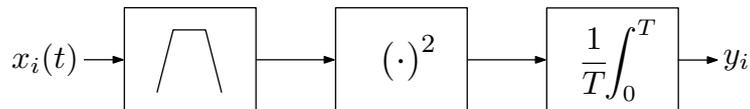


Figura 2.4: Diagrama simples de um detector de energia.

Embora a estrutura da Figura 2.4 esteja representada no tempo contínuo t , é possível mostrar [21] que uma estimativa da energia no canal, y_i , feita por um detector i durante um intervalo de sensoriamento, pode ser calculada pela média do quadrado de N amostras da observação discreta $x_i(k)$:

$$y_i = \frac{1}{N} \sum_{k=0}^{N-1} |x_i(k)|^2. \quad (2.3)$$

Em seguida, uma decisão sobre o estado do canal é tomada comparando-se a estimativa y_i a um limiar de decisão γ_i :

$$y_i \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\gtrless}} \gamma_i. \quad (2.4)$$

Portanto, na detecção de energia, a medida y_i é a estatística de teste do classificador binário. Note que este método é não-coerente porque o cálculo de y_i em (2.3) não

envolve nenhuma informação sobre o sinal primário, diferentemente do que ocorre nas técnicas por filtro casado e cicloestacionária. Em contrapartida, a simples estimação da energia não permite ao rádio cognitivo diferenciar um canal ocupado de um fortemente contaminado com ruído ou interferências, o que é um limitante desta técnica frente às demais.

Outro inconveniente em se empregar uma detecção cega é a possibilidade de o rádio confundir a transmissão de um usuário primário com a de outro rádio cognitivo. Para contornar esse problema, redes secundárias que utilizarem detecção de energia devem recorrer a períodos de “silêncio”, dentro dos quais todos os aparelhos simultaneamente observam o ambiente, sem transmitir nada [15]. De qualquer maneira, a despeito dessas limitações, a simplicidade e a não-coerência desta técnica ainda encorajam o seu uso dentro da pesquisa em sensoriamento de espectro.

2.3.1 Desempenho do Detector de Energia

As probabilidades de detecção e de alarme falso apresentadas na Seção 2.2.1 podem ser definidas em função de densidades de probabilidade condicionadas, respectivamente, às hipóteses \mathcal{H}_1 e \mathcal{H}_0 . No caso do detector de energia, elas ficam

$$P_{d,i} = P(y_i \geq \gamma_i | \mathcal{H}_1) = \int_{\gamma_i}^{\infty} p(y_i | \mathcal{H}_1) dy_i, \quad (2.5a)$$

$$P_{f,i} = P(y_i \geq \gamma_i | \mathcal{H}_0) = \int_{\gamma_i}^{\infty} p(y_i | \mathcal{H}_0) dy_i. \quad (2.5b)$$

Assim, o desempenho da técnica de detecção de energia está associado ao comportamento estocástico das estimativas y_i . Considerando que todas as N amostras em (2.3) correspondam a uma única hipótese, isto é, o canal não mude de estado durante o sensoriamento, y_i será uma soma do quadrado de N variáveis aleatórias Gaussianas. Nesse caso, a estatística $y_i/\sigma_{v_i}^2$ seguirá, sob a hipótese \mathcal{H}_0 , uma distribuição Chi-quadrada central com N graus de liberdade e, sob a hipótese \mathcal{H}_1 , uma distribuição Chi-quadrada não-central com N graus de liberdade e parâmetro η_i [8]:

$$\frac{y_i}{\sigma_{v_i}^2} \sim \begin{cases} \chi_N^2 & , \text{ se } \mathcal{H}_0, \\ \chi_N^2(\eta_i) & , \text{ se } \mathcal{H}_1, \end{cases} \quad (2.6)$$

em que η_i é a SNR na entrada do i -ésimo rádio, definida como

$$\eta_i = \frac{P_i}{\sigma_{v_i}^2}, \text{ onde } P_i = \frac{|h_i|^2}{N} \sum_{k=0}^{N-1} |s(k)|^2. \quad (2.7)$$

Por outro lado, de acordo com o Teorema do Limite Central, para um número de amostras N suficientemente grande, as distribuições em (2.6) podem ser aproximadas para distribuições Normais [23]. Dessa maneira, y_i assume as estatísticas [24]

$$y_i \sim \begin{cases} \mathcal{N}\left(\sigma_{v_i}^2, \frac{2}{N}\sigma_{v_i}^4\right) & , \text{ se } \mathcal{H}_0, \\ \mathcal{N}\left((1 + \eta_i)\sigma_{v_i}^2, \frac{2}{N}(1 + \eta_i)^2\sigma_{v_i}^4\right) & , \text{ se } \mathcal{H}_1, \end{cases} \quad (2.8)$$

em que $\mathcal{N}(a, b)$ denota distribuição Normal de média a e variância b . Isso permite escrever as probabilidades de detecção e de alarme falso em (2.5) na forma de funções *distribuição cumulativa complementar*, $Q(\cdot)$:

$$P_{d,i} = P(y_i \geq \gamma_i | \mathcal{H}_1) = Q\left(\frac{\gamma_i - \mu_{y_i,1}}{\sqrt{\sigma_{y_i,1}^2}}\right), \quad (2.9a)$$

$$P_{f,i} = P(y_i \geq \gamma_i | \mathcal{H}_0) = Q\left(\frac{\gamma_i - \mu_{y_i,0}}{\sqrt{\sigma_{y_i,0}^2}}\right), \quad (2.9b)$$

onde a média $\mu_{y_i,h}$ e a variância $\sigma_{y_i,h}^2$ da variável y_i sob a hipótese \mathcal{H}_h foram definidas em (2.8); e $Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty e^{-\tau^2/2} d\tau$.

Observando (2.9), é possível apontar a janela de sensoriamento N e o limiar de decisão γ_i como parâmetros que influem no desempenho do detector de energia. Sobre a primeira, pode-se, inclusive, estabelecer uma relação direta entre valores desejados para $P_{d,i}$ e $P_{f,i}$ e o número necessário de amostras de sensoriamento [18]:

$$N = 2 \left[Q^{-1}(P_{f,i}) - Q^{-1}(P_{d,i}) \sqrt{1 + 2\eta_i} \right]^2 \eta_i^{-2}. \quad (2.10)$$

Conforme a expressão (2.10) sugere, qualquer desempenho seria alcançável pelo rádio cognitivo, desde que ele pudesse desenvolver o intervalo de sensoriamento que precisasse. Mas, na prática, o tempo de operação do rádio em cada frequência deve ser administrado entre o sensoriamento e a transmissão: se ele gastar muito tempo avaliando o canal, pouco restará para utilizá-lo efetivamente, caso esteja livre. Em decorrência disso, a janela N é mantida tão pequena quanto possível.

Por sua vez, o limiar de decisão γ_i , parâmetro que delimita as regiões de observação do classificador associadas a \mathcal{H}_0 e \mathcal{H}_1 , é uma opção de ajuste mais flexível. Ainda assim, é preciso levar em conta que a sua influência sobre as probabilidades se dá no mesmo sentido (observe os limites de integração de $P_{d,i}$ e $P_{f,i}$ em (2.5)), o que significa que, ao se aumentar um indicador ajustando apenas o limiar, o outro, inevitavelmente, aumentará também. Deve-se, então, recorrer a um critério de

decisão, de modo que escolha de γ_i seja condicionada a alguma premissa de desempenho mínimo desejável pelo rádio, se for em termos de probabilidade de detecção; ou máximo aceitável, se em termos de probabilidade de alarme falso.

O *critério de Neyman-Pearson* adota esse princípio. Sua formulação estabelece que o limiar de decisão ótimo γ_{i_o} é aquele que maximiza a probabilidade de detecção, enquanto mantém a probabilidade de alarme falso igual ou inferior a um determinado valor, ε_i [25]:

$$\gamma_{i_o} = \arg \max P_{d,i}(\gamma_i) \quad \text{s.a.} \quad P_{f,i}(\gamma_i) \leq \varepsilon_i. \quad (2.11)$$

Trata-se, portanto, de um problema de otimização restrita, cuja solução se obtém utilizando o método dos multiplicadores de Lagrange. Assim, define-se a função

$$L(\gamma_i, \lambda) = P_{d,i}(\gamma_i) - \lambda [P_{f,i}(\gamma_i) - \varepsilon_i], \quad (2.12)$$

onde λ é o multiplicador de Lagrange. Substituindo as integrais de (2.5) e arrumando os termos, $L(\gamma_i, \lambda)$ fica

$$L(\gamma_i, \lambda) = \lambda \varepsilon_i + \int_{\gamma_i}^{\infty} [p(y_i | \mathcal{H}_1) - \lambda p(y_i | \mathcal{H}_0)] dy_i. \quad (2.13)$$

Como o objetivo é maximizar a função $L(\gamma_i, \lambda)$, deseja-se maximizar a integral em (2.13), que depende do parâmetro γ_i . Para isso, deve-se garantir a escolha de um valor γ_i tal que o integrando seja sempre positivo, isto é, $p(y_i | \mathcal{H}_1) - \lambda p(y_i | \mathcal{H}_0) > 0$. Considerando $\lambda > 0$, essa condição leva ao seguinte teste de razão de verossimilhança (*Likelihood-Ratio Test* – LRT):

$$\Lambda(y_i) = \frac{p(y_i | \mathcal{H}_1)}{p(y_i | \mathcal{H}_0)} \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\gtrless}} \lambda, \quad (2.14)$$

onde λ é obtido pela restrição $P(\Lambda(y_i) \geq \lambda | \mathcal{H}_0) = \varepsilon_i$ [26].

Finalmente, é possível mostrar, após desenvolvimento matemático em (2.14), que as estimativas de energia y_i são estatísticas suficientes para o critério de Neyman-Pearson [25, 26], o que reduz o LRT à regra de decisão apresentada em (2.4):

$$y_i \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\gtrless}} \gamma_{i_o}.$$

Sendo assim, para y_i Gaussiana, a solução ótima do problema γ_{i_o} pode ser obtida

diretamente igualando-se (2.9b) a ε_i , ou seja,

$$P_{f,i}(\gamma_{i_o}) = Q\left(\frac{\gamma_{i_o} - \mu_{y_i,0}}{\sqrt{\sigma_{y_i,0}^2}}\right) = \varepsilon_i, \quad (2.15)$$

e o valor ótimo $P_{d,i}(\gamma_{i_o})$ correspondente é dado diretamente através de (2.9a):

$$P_{d,i}(\gamma_{i_o}) = Q\left(\frac{\gamma_{i_o} - \mu_{y_i,1}}{\sqrt{\sigma_{y_i,1}^2}}\right). \quad (2.16)$$

Isolando-se γ_{i_o} em (2.15), uma expressão que retorna o limiar de decisão ótimo em função da restrição ε_i é dada por

$$\gamma_{i_o} = \mu_{y_i,0} + Q^{-1}(\varepsilon_i)\sqrt{\sigma_{y_i,0}^2}, \quad (2.17)$$

em que $Q^{-1}(\cdot)$ é a função *distribuição cumulativa complementar* inversa [27].

Portanto, nessa abordagem do problema de sensoriamento segundo Neyman-Pearson, a operação do rádio cognitivo usando detecção de energia consiste, essencialmente, em achar o limiar que assegure uma meta fixa de alarmes falsos através de (2.17), e que, conseqüentemente, levará o sistema ao desempenho teórico de detecções conforme (2.16). Esse princípio de funcionamento é conhecido como princípio da taxa constante de alarme falso (*Constant False Alarm Rate* – CFAR) [28]. Outra alternativa, menos comum, é o princípio da taxa constante de detecção (*Constant Detection Rate* – CDR), no qual a meta pré-estabelecida é sobre a probabilidade de detecção, e a de alarme falso é minimizada [28].

2.3.2 SNR *Wall* e a Incerteza do Ruído

Seja qual for a abordagem adotada para o sensoriamento, CFAR ou CDR, calcular o limiar ótimo do detector de energia requer o valor exato da variância do ruído do ambiente, $\sigma_{v_i}^2$. Na prática, o detector não conhece $\sigma_{v_i}^2$, mas estima essa estatística – assim como as estatísticas de y_i em (2.8), que são funções dela – por meio de amostras coletadas durante períodos de inatividade primária conhecidos pela rede secundária [8, 18]. Inevitavelmente, como o ruído total engloba componentes térmicos e de recepção e interferências de outros sistemas, todos variantes com o tempo, qualquer estimativa $\hat{\sigma}_{v_i}^2$ carregará uma imprecisão, ou *incerteza*, em relação ao valor real [24].

Para entender o efeito dessa incerteza, considere os dois casos extremos: $\hat{\sigma}_{v_i,I}^2$, correspondente à estimativa inferior de $\sigma_{v_i}^2$ quando não há interferência de outros dispositivos; e $\hat{\sigma}_{v_i,S}^2$, que é a estimativa superior, feita sob máxima interferência. Seja

ρ_i o nível de incerteza, em dB, no i -ésimo detector. Assim,

$$\hat{\sigma}_{v_i,S}^2 = \hat{\sigma}_{v_i,I}^2 \times 10^{\frac{\rho_i}{10}}. \quad (2.18)$$

Em (2.7), definiu-se a potência do sinal primário na entrada do i -ésimo rádio, P_i . Caso ela seja igual ou inferior à diferença entre esses dois extremos, isto é, $P_i \leq \hat{\sigma}_{v_i,S}^2 - \hat{\sigma}_{v_i,I}^2$, o detector confundirá o usuário com ruído e não conseguirá detectá-lo [29]. Isso sugere existir um valor limite para a SNR, abaixo do qual não há qualquer precisão nas decisões do classificador. Esse limite é denominado SNR *wall*, e pode ser calculado, em dB, como [29]

$$\eta_{i,wall} = 10 \log_{10}(10^{\frac{\rho_i}{10}} - 1). \quad (2.19)$$

A SNR *wall* representa a principal limitação do detector de energia. Abaixo dela, o sinal primário é indistinguível, mesmo recorrendo a longos intervalos de sensoriamento [24]. Além disso, a expressão (2.19) aponta uma forte sensibilidade da técnica à incerteza do ruído. Por exemplo, mesmo para um pequeno nível de incerteza, $\rho_i = 0.1$ dB, a SNR *wall* é relativamente alta: -16.33 dB; com $\rho_i = 1$ dB, esse limite sobe para $\eta_{i,wall} = -5.87$ dB.

Diante de tão pouca robustez a cenários de baixa SNR, usar detecção de energia se torna inviável em muitos sistemas reais, principalmente se cada rádio fizer o sensoriamento de maneira independente. Por conta disso, é fundamental considerar, em conjunto com a detecção de energia, a implementação de uma rede cooperativa de sensoriamento, assunto do próximo capítulo.

Capítulo 3

Sensoriamento Cooperativo de Espectro

A técnica de detecção de energia oferece, ao rádio cognitivo, a grande prerrogativa de não precisar conhecer o usuário que se deseja detectar. Essa característica é plenamente compatível com a premissa, adotada pela maioria dos autores, de que as redes primária e secundária compartilharão o meio de modo separado, sem comunicação entre si. Em compensação, o detector de energia não reconhece a fonte da energia estimada e, por isso, deixa o rádio mais suscetível a um alarme falso, caso o canal livre esteja, na verdade, sob forte interferência; ou a uma não-deteção, caso a SNR observada no canal ocupado seja inferior à SNR *wall*.

Algumas situações práticas das redes de comunicação sem fio podem agravar esses problemas e trazer outros. Observe, por exemplo, a rede cognitiva ilustrada na Figura 3.1, composta por dois usuários primários – um transmissor (UPt) e um receptor (UPr) – e três usuários secundários implementando rádio cognitivo (RC). Nesse cenário hipotético, o rádio RC_1 está em posição privilegiada para detectar o transmissor UPt , por se encontrar sob a área de cobertura dele e em linha de visada.

Já o rádio RC_2 , embora também esteja no interior da zona primária, não consegue estabelecer visada direta com UPt , caracterizando o *problema do terminal escondido*. Suas observações coletadas do canal são fruto de atenuação e multipercursos, o que, se por um lado não afeta a taxa de alarmes falsos do detector, invariante com a SNR, por outro compromete o seu desempenho em detecções, altamente sensível às variações da SNR em canais com desvanecimento (veja (2.8) e (2.9)) [14, 30].

Outra situação peculiar é representada pelo receptor UPr e pelo rádio RC_3 . Por estar longe da área de cobertura do transmissor UPt , RC_3 não encontra a rede primária e começa a transmitir em sua rede secundária. Entretanto, ele não tem como perceber a presença de UPr , que, estando no interior das duas redes, receberá ambos os sinais. Esse é o *problema da incerteza do receptor*.

Assim, com suas capacidades individuais de detecção comprometidas, os rádios

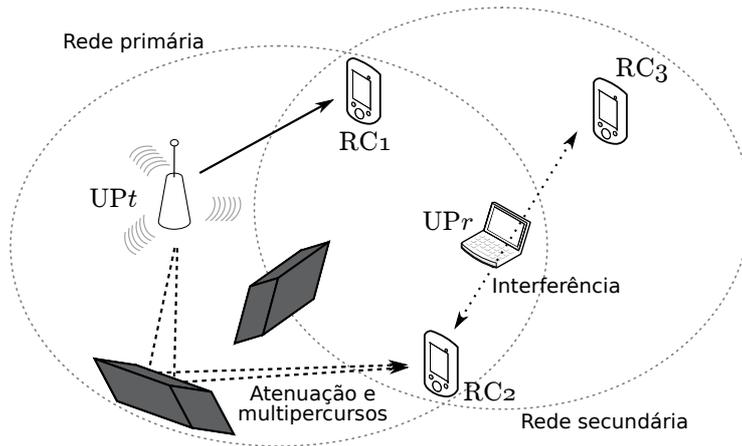


Figura 3.1: Rede cognitiva, formada por usuários primários e secundários.

RC_2 e RC_3 eventualmente irão interferir na rede primária. Se, por outro lado, ambos tivessem acesso ao sensoriamento privilegiado do rádio RC_1 , certamente detectariam a atividade primária e, tal como ele, não entrariam indevidamente em operação. Esta é a ideia principal do sensoriamento cooperativo de espectro: permitir à rede secundária tomar proveito da diversidade espacial dos seus diferentes rádios (ou *nós*), de modo que ela produza decisões conjuntas e, conseqüentemente, mais confiáveis [15]. Além disso, como essas decisões estarão disponíveis a todos os nós, implementar cooperação é também uma solução eficaz contra os problemas do terminal escondido e da incerteza do receptor.

3.1 Estratégias de Cooperação

Para reunir as informações dos diversos nós e realizar cooperação, a rede secundária pode recorrer a duas principais estratégias: em uma delas, denominada cooperação *centralizada*, a rede concentra os dados dos nós em uma central, que deve combinar as informações, tomar uma decisão global e a repassar a todos os rádios. Já na estratégia conhecida como cooperação *distribuída*, a rede se organiza em vizinhanças, e a troca de informações se dá diretamente – e apenas – entre nós pertencentes a uma mesma vizinhança. Ambas as ideias estão ilustradas na Figura 3.2.

Cada uma delas oferece vantagens e desvantagens. No caso centralizado, por exemplo, concentrar todo o processamento (combinação e teste de hipóteses) em uma central simplifica o projeto e o custo do rádio, cuja incumbência passa a ser, no cenário mais simples, apenas produzir as estimativas de energia e as reportar por um canal específico de controle. Por outro lado, a topologia de uma rede centralizada é pouco flexível, já que qualquer ajuste nela fica condicionado à disponibilidade geográfica de centrais, que são estações fixas. Ademais, se a rede for composta por um

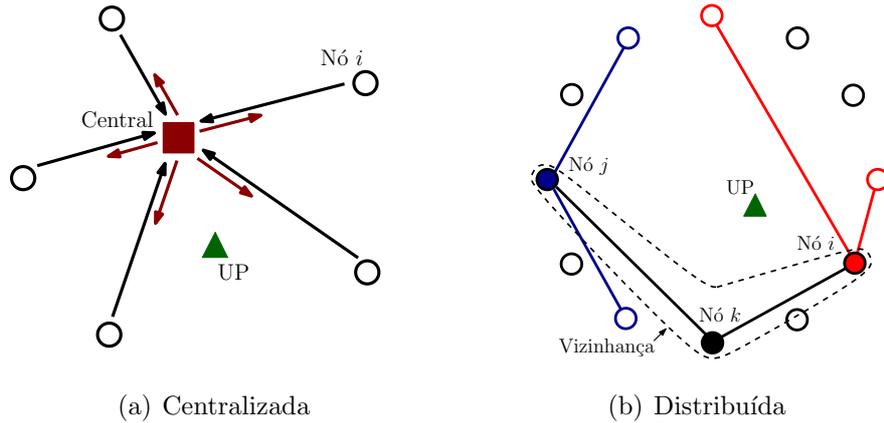


Figura 3.2: Estratégias para sensoriamento cooperativo.

grande número de nós, a carga de processamento requerida na central pode tornar a estratégia computacionalmente proibitiva. Se esses nós estiverem muito longe, também precisarão utilizar mais potência para enviar suas observações, reduzindo a vida útil da bateria dos rádios [31].

A estratégia distribuída, por sua vez, dispensa a necessidade de uma central fixa e oferece mais possibilidades para o ajuste dinâmico da topologia da rede. Em compensação, cada rádio passa a funcionar como um “nó central” da sua vizinhança, pois acumula as funções de coletar e processar localmente as informações dos vizinhos, além de também enviar seus dados a cada um deles, e não mais a um único ponto. Isso sofisticou o projeto da rede e aumentou os requisitos computacional, energético e de banda dos dispositivos. Por fim, a maioria dos trabalhos com arquitetura distribuída aborda o problema de sensoriamento cooperativo como um problema de estimação de parâmetros [15]; nesse caso, a interação entre os nós deve perdurar até um consenso, podendo levar mais recursos (principalmente, tempo) até a decisão.

3.2 Ganho vs. *Overhead* de Cooperação

Independentemente da estratégia considerada, fazer sensoriamento cooperativo comprovadamente melhora o desempenho dos rádios cognitivos [14, 32]. Além de sobrepor os efeitos degenerativos do canal com desvanecimento [33], também reduz a SNR *wall* “equivalente” do sistema, tornando a detecção mais robusta à incerteza do ruído [34]. No entanto, a complexidade da rede cresce à medida que ela incorpora mais funcionalidades, necessárias para a coordenação entre os nós. A esses conjuntos de benefícios e de processamento extra inerentes à cooperação, dão-se os nomes, respectivamente, de *ganho* e *overhead* de cooperação [15].

Com relação ao ganho, cada rádio cognitivo da rede pode se beneficiar do sensori-

amento cooperativo de diversas formas. A mais imediata delas é através da melhoria dos indicadores de desempenho: se o princípio utilizado for o CFAR, há um aumento da probabilidade de detecção; se for CDR, ocorre uma diminuição da probabilidade de alarme falso. Em outras palavras, o rádio protege mais a rede primária (CFAR) ou melhora o aproveitamento na identificação de oportunidades (CDR).

Alternativamente, o dispositivo pode utilizar o ganho na detecção para reduzir o tempo de sensoriamento. Conforme mostrado pela expressão em (2.10), existe uma relação direta entre a janela N e os indicadores de desempenho. Se o rádio abrir mão de parte da melhora obtida nos indicadores, reduzindo-os até valores toleráveis pela rede cognitiva, poderá encurtar a janela de sensoriamento e, assim, transmitir no canal por mais tempo.

O *overhead* associado à cooperação também surge por vários fatores [15]. Em primeiro lugar, a rede precisa dedicar um canal de controle comum para que os nós reportem seus dados à central (no decorrer deste capítulo, o termo *central* poderá também se referir ao “nó central” do caso distribuído). Sua limitada largura de banda restringe o tipo e o volume de informação que pode ser compartilhado na rede. Além disso, mecanismos de qualidade e segurança devem ser implementados para proteger os dados no canal de controle contra efeitos do ambiente, fraudes etc.

Uma vez reunidas, as medidas provenientes dos nós devem ser submetidas a uma técnica de combinação. Cada uma das técnicas disponíveis requer diferentes níveis de carga computacional da central. E, dependendo do tipo de informação dos nós que são combinados, elas podem demandar mais ou menos banda de controle. As principais técnicas serão apresentadas na Seção 3.4.

O intervalo total até a decisão também aumenta com o uso de cooperação, pois passa a incluir o tempo de sensoriamento de cada rádio, a demora até que os dados dos nós cheguem à central e o tempo que esta leva para processá-los. Nas estratégias distribuídas com estimação de parâmetros, que geralmente empregam algoritmos de consenso, esse intervalo é ainda multiplicado pelo número de vezes que os nós trocam informações até a convergência. Por conta disso, a rede precisa controlar essa demora até níveis que ainda viabilizem o uso oportunista do canal.

No caso do detector de energia, foi mencionado, na Seção 2.3, que as redes secundárias dedicam períodos de “silêncio” para o sensoriamento. Para garantir que todos os nós observem o ambiente simultaneamente, é necessário sincronizá-los. Além disso, os dados também devem chegar sincronizados na central, a fim de evitar que ela combine medidas tomadas em intervalos de sensoriamento diferentes.

Finalmente, ao fazer cooperação, os rádios gastam mais energia. Esse consumo extra é proporcional à frequência com que eles trocam informações, ao volume de dados compartilhados e à quantidade de processamento local, esta última especialmente crítica no caso distribuído. Soluções que agendem frequências adequadas

de sensoriamento e que reduzam a carga de processamento no rádio são úteis para garantir mínima perda de autonomia dos aparelhos móveis.

Apesar da sua importância, estabelecer métricas para quantificar o *overhead* associado a um método de cooperação não é uma tarefa fácil, motivo pelo qual ainda é um aspecto em aberto na literatura [15]. Como consequência, a maioria dos trabalhos propondo novas estratégias focam apenas a melhoria do desempenho. Isso dificulta desenvolver comparações, já que o ideal seria fazê-las dimensionando um ganho “real” que traduzisse o compromisso entre desempenho e aplicabilidade.

3.3 Seleção de Usuário

O *overhead* das redes cooperativas inclui também os algoritmos geradores de topologia, responsáveis por selecionar quais nós se conectam à central, no caso centralizado; ou quais formam as vizinhanças na rede, no caso distribuído. Como a seleção de usuário prevê o envolvimento de apenas alguns nós na cooperação, os primeiros trabalhos no tema visavam reduzir a complexidade da rede e, ao mesmo tempo, minimizar as perdas esperadas na detecção conjunta. No entanto, resultados mostraram que, escolhendo-se criteriosamente esses nós – de acordo com a SNR, por exemplo –, é possível obter um desempenho inclusive superior ao do caso em que todos cooperam [28, 35]. Já trabalhos mais recentes destacam outros fatores também importantes nessa seleção, como a integridade dos nós e, principalmente, a mobilidade dos usuários secundários.

Por integridade do nó, refere-se tanto à qualidade do seu enlace com a central quanto à segurança na própria informação que ele produz. Conforme ilustrado na rede da Figura 3.3, um cenário possível é aquele em que algum nó (RC_1) não compartilhe medidas corretas, seja por uma falha no dispositivo ou no canal de controle, seja por ele ter sido maliciosamente programado para repassar informações discrepantes. Embora, em esquemas distribuídos sem estimação de parâmetros, seja possível isolar esse tipo de defeito em uma vizinhança, nos centralizados ele reflete em todos os outros rádios. Por isso, é preciso que a rede identifique os nós defeituosos e os remova da seleção. Algumas propostas nesse sentido envolvem índices de reputação para ressaltar os nós “autênticos”, identificação de extremos em relação à média das demais contribuições, dentre outras estratégias [36, 37].

Já algoritmos que levem em consideração a mobilidade dos nós são necessários por uma série de fatores. Um deles é para determinar corretamente o *footprint* de cooperação, isto é, a região em torno da rede primária na qual os rádios cognitivos cooperam [33]. Para que ele acompanhe a área de cobertura do transmissor primário, a rede cooperativa deve considerar apenas nós que estejam em torno do transmissor em dado momento, desconectando-os à medida que eles se afastarem. Caso contrário,

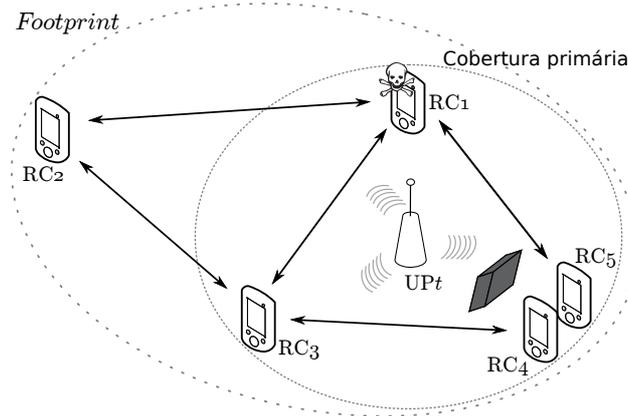


Figura 3.3: Desafios para a seleção de usuário.

situações como a do rádio RC_2 na Figura 3.3 podem ocorrer: mesmo distante o suficiente para fazer reuso da frequência, ele será impedido de transmitir sempre que os demais nós informarem que o transmissor UP_t está ativo. E o inverso também é possível, ou seja, RC_2 pode identificar uma transmissão primária em outro lugar e influenciar erroneamente no acesso oportunista dos que estão próximos de UP_t [38].

Ao mesmo tempo, é ideal que a rede cooperativa selecione nós bem distribuídos dentro do *footprint*, evitando casos como o ilustrado pelos rádios RC_4 e RC_5 na Figura 3.3. Isso porque, ao promover a maior diversidade espacial possível, ela reduz o risco de combinar informações correlacionadas, o que comprovadamente degrada o desempenho da detecção conjunta [33, 39]. Resultados em [39], por exemplo, mostram que utilizar poucos nós, porém bem espaçados, é mais eficiente do que selecionar muitos nós próximos e sujeitos aos mesmos sombreamentos (como obstáculos), que geram correlação entre as suas contribuições. Nesse sentido, ao adaptar a topologia à movimentação dos usuários no *footprint*, a rede precisa também monitorar o sombreamento correlacionado.

Na literatura, encontram-se algoritmos baseados na mobilidade assumindo diferentes graus de conhecimento sobre a posição dos nós. O trabalho [40], por exemplo, define uma “distância de decorrelação” – menor espaçamento entre dois nós decorrelacionados – e investiga três estratégias para escolher apenas os separados por essa distância, utilizando suas posições absolutas ou suas distâncias radiais para a central. Em [38], por sua vez, são propostos diferentes métodos de clusterização para redes de cooperação distribuída: aleatório, quando não há nenhuma informação de posição; baseado em referência, quando as posições relativas dos usuários secundários são conhecidas; ou baseado em distância, quando as posições dos usuários primários e secundários estão disponíveis. Já o algoritmo adaptativo desenvolvido em [41] estima diretamente as correlações entre os nós da rede, seguindo mudanças dinâmicas nesses valores sem precisar de nenhuma informação instantânea de posição.

3.4 Tipos de Combinação

Uma vez estabelecido o *footprint* e selecionados os usuários, a rede secundária procede à cooperação propriamente dita. Para isso, a central reúne as medidas dos nós escolhidos e implementa uma técnica de combinação, que, dependendo da natureza das medidas processadas, pode ser do tipo *hard* ou *soft*.

3.4.1 Combinação *Hard*

Na combinação *hard*, cada nó da rede cooperativa produz, por meio de sensoria-mento, uma decisão individual acerca da disponibilidade do canal e encaminha sua informação binária (“0” – livre ou “1” – ocupado) à central. Nesse caso, a técnica de combinação que a central emprega é uma regra de fusão. A mais comum delas é a *regra de votos* (*m-out-of-M*) [42], segundo a qual o canal é considerado ocupado se, pelo menos, m do total de M nós enviarem “1”; caso contrário, entende-se que o canal está livre.

Dentre os casos particulares da regra de votos, destacam-se as regras de fusão AND ($m = M$) e de fusão OR ($m = 1$). Na fusão AND, a rede descarta o canal para uso oportunista apenas se todos os rádios indicarem que ele está ocupado. Usando essa técnica e assumindo contribuições descorrelacionadas dos nós, as probabilidades de detecção e de alarme falso associados à decisão conjunta são [28]

$$P_{d,c} = \prod_{i=1}^M P_{d,i}, \quad (3.1a)$$

$$P_{f,c} = \prod_{i=1}^M P_{f,i}, \quad (3.1b)$$

onde $P_{d,i}$ e $P_{f,i}$ são os indicadores de desempenho individuais do i -ésimo nó, definidas em (2.9) para o caso em que ele implementa detector de energia.

Por outro lado, usando fusão OR, basta que um dos rádios informe que a frequência está ocupada para que ela seja desconsiderada por toda a rede secundária. Nesse caso, o desempenho associado à decisão conjunta, para contribuições descorrelacionadas dos nós, passa a ser dado pelas expressões [28]

$$P_{d,c} = 1 - \prod_{i=1}^M (1 - P_{d,i}), \quad (3.2a)$$

$$P_{f,c} = 1 - \prod_{i=1}^M (1 - P_{f,i}). \quad (3.2b)$$

Por consistir basicamente em uma contagem, a regra de votos é a técnica de

combinação mais simples de se implementar. Além disso, ela requer mínima largura de banda no canal de controle, uma vez que a informação proveniente de cada nó é apenas um bit. Com relação ao ganho de cooperação que oferece, resultados em [43] mostram que o valor de m que leva ao melhor desempenho varia de acordo com os limiares de decisão utilizados pelos rádios em suas classificações locais: para limiares pequenos, a fusão AND é mais adequada, mas, à medida que esses valores aumentam, a técnica ótima tende para a fusão OR.

Em contrapartida, a grande desvantagem de se realizar esse tipo de combinação é que ambas as probabilidades aumentam, inclusive a de alarme falso. Esse efeito indesejado, que pode ser notado tanto nas fórmulas em (3.1) para a regra AND quanto nas em (3.2) para o caso OR, limita o ganho de cooperação entregue à rede secundária. Outra consequência direta é que o limiar de cada rádio, que orienta o seu desempenho individual, não pode ser obtido diretamente a partir da restrição global de desempenho, seja ela segundo o princípio CFAR ou CDR. Pelo contrário, cada um precisa ser cuidadosamente ajustado a fim de que, após a cooperação, o indicador sob restrição permaneça dentro do limite tolerável pela rede primária.

3.4.2 Combinação *Soft*

Usar as decisões dos nós para combinação possui ainda outro inconveniente: a perda de informação inerente à conversão de uma medida *soft* (no caso, uma estimativa de energia) em um dado binário. Ao empregar uma simples contagem de votos, a central não faz qualquer distinção entre as decisões dos rádios, que podem ter sido tomadas, por exemplo, sob diferentes níveis de SNR. Nesse sentido, espera-se que uma técnica que combine diretamente as estimativas locais, sem processamento intermediário, alcance maior ganho de cooperação por aproveitar mais a diversidade de informação disponível.

De fato, as técnicas de combinação *soft* apresentam melhor desempenho de detecção que as técnicas *hard* [14, 44]. Além disso, elas oferecem outras vantagens: em redes centralizadas, dispensam o emprego de classificador binário no aparelho; em redes distribuídas, mesmo a classificação final sendo realizada pelos nós, os limiares de decisão locais podem ser calculados diretamente em função da restrição global imposta à sede secundária, diferentemente do que ocorre na combinação *hard*.

Naturalmente, é necessário mais banda de controle para transmitir informações *soft*, que são codificadas usando uma grande quantidade de bits. Mas o principal fator a se considerar com o emprego desse tipo de técnica é a maior carga computacional associada. Seguindo mais uma vez o critério de Neyman-Pearson, as melhores

técnicas de combinação *soft* são derivadas do LRT [18]

$$\Lambda(\mathbf{y}) = \frac{p(\mathbf{y} | \mathcal{H}_1)}{p(\mathbf{y} | \mathcal{H}_0)} \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\geq}} \lambda, \quad (3.3)$$

onde $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$ é o vetor com as M estimativas de energia acumuladas na central, obtidas através de (2.3), e o limiar λ é novamente calculado visando atender a uma restrição global de alarmes falsos. Juntamente com as medidas locais dos nós, a central reúne também as suas estatísticas de primeira e segunda ordem definidas em (2.8), formando o vetor média das estimativas sob a hipótese \mathcal{H}_h

$$\boldsymbol{\mu}_h = \left[\mu_{y_1,h} \quad \mu_{y_2,h} \quad \cdots \quad \mu_{y_M,h} \right]^T, \quad (3.4)$$

e a matriz covariância sob \mathcal{H}_h

$$\boldsymbol{\Sigma}_h = \begin{bmatrix} \sigma_{y_1,h}^2 & \cdots & \sigma_{y_1 y_M,h} \\ \vdots & \ddots & \vdots \\ \sigma_{y_M y_1,h} & \cdots & \sigma_{y_M,h}^2 \end{bmatrix}, \quad (3.5)$$

sendo que, para medidas descorrelacionadas ($\sigma_{y_i y_j,h} = 0$, $i \neq j$), $\boldsymbol{\Sigma}_h$ é diagonal [8].

De posse das definições em (3.4) e (3.5), e após algum desenvolvimento em (3.3), chega-se ao combinador *soft* ótimo baseado no LRT [18],

$$T(\mathbf{y}) = \mathbf{y}^T (\boldsymbol{\Sigma}_0^{-1} - \boldsymbol{\Sigma}_1^{-1}) \mathbf{y} + 2 (\boldsymbol{\mu}_1^T \boldsymbol{\Sigma}_1^{-1} - \boldsymbol{\mu}_0^T \boldsymbol{\Sigma}_0^{-1}) \mathbf{y}, \quad (3.6)$$

cuja natureza quadrática torna sua complexidade inviável para muitas aplicações, principalmente as que envolvem redes com um grande número de nós. Tal complexidade também é proibitivamente alta quando a rede emprega restrições globais extremas, como probabilidades de alarme falso muito pequenas [8].

3.5 Combinação Linear

Com vista a reduzir a carga computacional devido à combinação *soft*, uma das principais alternativas à técnica LRT encontradas na literatura é o combinador linear [8]. Usando esse método, a estatística de teste $T(\mathbf{y})$ é produzida a partir da soma das M estimativas individuais dos nós, cada uma das quais previamente multiplicadas por um coeficiente específico, w_i :

$$T(\mathbf{y}) = \sum_{i=1}^M w_i y_i = \mathbf{w}^T \mathbf{y}, \quad (3.7)$$

em que $\mathbf{w} = [w_1, w_2, \dots, w_M]^T$ é o vetor de coeficientes. Em seguida, no teste de hipóteses, o resultado da combinação é comparado a um limiar central, γ_c , e a decisão conjunta é tomada:

$$T(\mathbf{y}) \underset{\mathcal{H}_0}{\overset{\mathcal{H}_1}{\gtrless}} \gamma_c. \quad (3.8)$$

Por ser uma estrutura linear, e não quadrática, esse tipo de combinador é muito mais simples que o LRT. Sua eficácia está relacionada à influência atribuída a cada estimativa na decisão final, que é o papel dos coeficientes da combinação. Por essa razão, é importante escolhê-los de modo que eles favoreçam as “melhores” medidas locais, segundo algum critério preestabelecido.

3.5.1 Desempenho da Detecção Conjunta

Semelhantemente ao que ocorre no sensoriamento com um único rádio, o desempenho da detecção conjunta depende do comportamento estatístico do teste $T(\mathbf{y})$, produzido após a combinação em (3.7). Como $T(\mathbf{y})$ é uma transformação linear de M variáveis aleatórias Gaussianas (conforme discutido sobre y_i na Seção 2.3.1), ele também assume comportamento Gaussiano, com estatísticas [9]

$$T(\mathbf{y}) \sim \begin{cases} \mathcal{N}(\mathbf{w}^T \boldsymbol{\mu}_0, \mathbf{w}^T \boldsymbol{\Sigma}_0 \mathbf{w}), & \text{se } \mathcal{H}_0, \\ \mathcal{N}(\mathbf{w}^T \boldsymbol{\mu}_1, \mathbf{w}^T \boldsymbol{\Sigma}_1 \mathbf{w}), & \text{se } \mathcal{H}_1. \end{cases} \quad (3.9)$$

Dessa maneira, é possível aproximar, novamente, as probabilidades de detecção e de alarme falso por funções *distribuição cumulativa complementar*:

$$P_{d,c} = P(T(\mathbf{y}) \geq \gamma_c | \mathcal{H}_1) = Q\left(\frac{\gamma_c - \mathbf{w}^T \boldsymbol{\mu}_1}{\sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_1 \mathbf{w}}}\right), \quad (3.10a)$$

$$P_{f,c} = P(T(\mathbf{y}) \geq \gamma_c | \mathcal{H}_0) = Q\left(\frac{\gamma_c - \mathbf{w}^T \boldsymbol{\mu}_0}{\sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_0 \mathbf{w}}}\right). \quad (3.10b)$$

As expressões em (3.10) representam outra grande vantagem do combinador linear sobre o LRT. Com o detector quadrático, ajustar o sensoriamento se torna matematicamente intratável pelo fato de o cálculo do seu desempenho envolver muitas integrais. Mesmo para obter o limiar de decisão ótimo do classificador, é necessário realizar simulações de Monte Carlo [8]. Por outro lado, o combinador linear permite avaliar o desempenho da rede analiticamente e, com isso, ela pode adaptar o seu funcionamento com soluções em forma fechada. Por exemplo, para calcular o limiar de decisão central segundo o princípio CFAR, basta igualar a expressão em (3.10b)

ao limite global de alarmes falsos, ε_c , e isolar γ_c na fórmula:

$$\gamma_c = \mathbf{w}^T \boldsymbol{\mu}_0 + Q^{-1}(\varepsilon_c) \sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_0 \mathbf{w}}. \quad (3.11)$$

Por fim, nota-se que o principal parâmetro de ajuste do combinador linear é o vetor de coeficientes \mathbf{w} , cuja influência se dá tanto diretamente nas fórmulas dos indicadores em (3.10) quanto indiretamente através do parâmetro γ_c em (3.11). Seu papel é fundamental no desempenho do combinador linear, especialmente na comparação com o LRT: trabalhos como [8, 9] mostram que, desde que \mathbf{w} e γ_c sejam obtidos de maneira *ótima*, é possível alcançar ganhos de cooperação muito próximos aos do detector quadrático.

3.5.2 Combinador Linear Ótimo e Alternativas

Para realizar combinação linear ótima, a rede deve recorrer às expressões analíticas dadas em (3.10) e encarar o sensoriamento cooperativo como um problema de otimização. Ou seja, o objetivo da central passa a ser encontrar os parâmetros \mathbf{w} e γ_c que maximizem a probabilidade de detecção conjunta $P_{d,c}$, sujeita a que a probabilidade de alarme falso conjunta $P_{f,c}$ se mantenha dentro da restrição ε_c :

$$\max_{\mathbf{w}, \gamma_c} P_{d,c} \quad \text{s.a.} \quad P_{f,c} \leq \varepsilon_c. \quad (3.12)$$

Da forma como apresentado em (3.12), trata-se de um problema de otimização restrita com duas variáveis. Mas, para simplificá-lo, pode-se inserir a restrição na função objetivo, substituindo (3.11) em (3.10a). Assim, o problema passa a ser de otimização irrestrita com uma variável:

$$\max_{\mathbf{w}} Q \left(\frac{Q^{-1}(\varepsilon_c) \sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_0 \mathbf{w}} - \mathbf{w}^T (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_0)}{\sqrt{\mathbf{w}^T \boldsymbol{\Sigma}_1 \mathbf{w}}} \right), \quad (3.13)$$

cujas solução ótima, \mathbf{w}_o , leva também ao limiar ótimo, γ_{co} , por meio de (3.11) [8].

Infelizmente, a grande dificuldade do combinador linear ótimo está no fato de que o problema (3.13) é não-convexo; logo, obter sua solução ótima não é trivial. Para tentar contornar isso, o trabalho [8] divide o problema em três regiões de operação: conservativa ($P_{d,c} > 0.5$ e $P_{f,c} \geq 0.5$), agressiva ($P_{d,c} > 0.5$ e $P_{f,c} < 0.5$) e hostil ($P_{d,c} \leq 0.5$ e $P_{f,c} < 0.5$), e propõe diferentes procedimentos de otimização para cada caso. Em [9], os autores simplificam a análise, mostrando que a solução do problema geral pode ser calculada usando programação semidefinida. Entretanto, ambas as propostas assumem que as matrizes covariância $\boldsymbol{\Sigma}_0$ e $\boldsymbol{\Sigma}_1$ são diagonais, o que não é uma premissa razoável se as estimativas de energia locais forem correlacionadas (veja (3.5)). Já o trabalho [10] generaliza [8] e inclui as matrizes covariância não-

diagonais, além de oferecer um método analítico que calcula a solução ótima do problema sem precisar dividi-lo em regiões de operação.

Ao mesmo tempo, outros trabalhos na literatura investigam estratégias sub-ótimas. Em [45], o problema é particularizado para cenários de baixa SNR; seus resultados sugerem que, nessas circunstâncias, o combinador linear ótimo pode ser aproximado por um simples *combinador de máxima razão* (*Maximum Ratio Combiner* – MRC), que emprega coeficientes proporcionais às SNR individuais. Também em [45], é mostrado que mesmo o combinador linear mais simples, o *combinador de ganho igual* (*Equal Gain Combiner* – EGC), já oferece resultados satisfatórios e consideravelmente superiores às técnicas *hard*.

Finalmente, alternativas mais recentes envolvem *combinadores lineares adaptativos*, especialmente atrativos por suas capacidades de seguir mudanças dinâmicas no ambiente. Os autores em [46], por exemplo, introduzem um algoritmo adaptativo para convergência dos coeficientes baseado em projeções ortogonais sobre conjuntos convexos, e sua validação é feita experimentalmente. Neste trabalho, é proposto também um combinador adaptativo com decisão *online* utilizando o algoritmo LMS, como parte de uma nova estratégia para cooperação distribuída que será apresentada em detalhes a seguir.

Capítulo 4

Rede Distribuída Proposta

As contribuições que serão descritas ao longo deste capítulo foram desenvolvidas para redes de sensoriamento de espectro distribuídas, isto é, aquelas em que as informações são compartilhadas diretamente entre os rádios. As vantagens desse tipo de configuração, conforme já mencionado, incluem dispensa de estação central para fusão dos dados, maior flexibilidade de ajuste da topologia e maior robustez a problemas como falhas de link, nós maliciosos, dentre outros. Nesse sentido, este trabalho focou duas das principais limitações observadas nas estratégias distribuídas na literatura: os longos intervalos de cooperação até a decisão conjunta e o grande volume de processamento realizado por cada nó da rede.

Sobre a primeira limitação, a maioria das propostas em sensoriamento distribuído busca compensar a ausência da central implementando algoritmos de consenso [47], por meio dos quais todos os nós da rede convergem para uma mesma estatística de teste e, conseqüentemente, para uma mesma decisão sobre o estado do canal. Para isso, após cada intervalo de sensoriamento, os rádios começam a compartilhar medidas até que haja convergência nessa estatística, e só então é feito o teste de hipóteses. Os trabalhos [6, 7], por exemplo, utilizam algoritmos de consenso para estimar, respectivamente, a energia e o sinal primário observados por meio de sensoriamento em banda estreita e em banda larga. Entretanto, como a convergência pode levar muitas iterações (de 5 a 30 em [6], e de 7 a 10 em [7]), a detecção conjunta pode não ser rápida o bastante para seguir as mudanças de estado do canal, além de comprometer o tempo de aproveitamento útil do espectro livre.

A segunda limitação é inerente à ausência da central em esquemas distribuídos, uma vez que a tarefa de processar as diversas informações de sensoriamento fica a cargo dos nós. Tal acúmulo de funções no rádio – processamento local, mais comunicação com os vizinhos da rede – exige deles maior poder computacional e consumo de bateria em comparação com os esquemas centralizados. Alguns trabalhos existentes na literatura já focam a eficiência energética desses dispositivos. Na tentativa de reduzir o uso de recursos para transmissão, técnicas de “censura” podem ser im-

plementadas nos nós, a fim de que cada um avalie previamente o nível de relevância das suas medidas antes de compartilhá-las com a rede. De acordo com a técnica proposta em [48], o teste de hipóteses local é feito com dois limiares de decisão, e estimativas de energia dentro do intervalo delimitado por eles não precisam ser transmitidas. Outros trabalhos transformam a questão energética em um problema de otimização, maximizando o desempenho conjunto sob restrições de consumo [49] ou encontrando o mínimo gasto individual de energia que ainda leve à capacidade de detecção desejada [50].

De modo a oferecer uma alternativa aos esquemas baseados em estimação de parâmetros, este trabalho propõe uma nova estratégia para sensoriamento distribuído, cuja cooperação se dá em dois passos [51]: no primeiro, chamado combinação *soft*, cada nó da rede combina sua estimativa de energia com as dos seus vizinhos e, por meio de teste de hipóteses, toma uma *decisão binária local* sobre o estado do canal. No segundo passo, chamado combinação *hard*, cada nó emprega regra de fusão para combinar sua decisão binária local com as dos vizinhos, de maneira a produzir uma *decisão consensual local*. O intuito é reduzir o intervalo de cooperação para oferecer decisões mais rápidas aos nós. Além disso, também há economia de banda de controle e de energia pelo menor tráfego de informações e pelo menor uso de recursos para transmissão.

Ao mesmo tempo, com o objetivo de reduzir a carga de processamento no rádio, este trabalho investiga o uso de *atualização seletiva* em redes de sensoriamento distribuídas [52]. Para isso, cada nó emprega uma estratégia de seleção semelhante a filtragem *set-membership*, de forma que o combinador linear adaptativo desenvolvido para o primeiro passo não precise atualizar os coeficientes em todos os intervalos de cooperação. Isso oferece ao dispositivo economia de recursos computacionais e maior eficiência no consumo de energia.

Por fim, é também apresentada uma variação da cooperação proposta utilizando duas topologias de rede diferentes, uma para cada passo (*soft* e *hard*) [53]. O objetivo é eliminar contribuições redundantes que, como será visto, limitam o ganho de cooperação da estratégia em dois passos. Além disso, usar dupla topologia permite que mais nós participem de cada decisão e dá à rede secundária mais possibilidades no sentido de minimizar as variações de detecção entre os rádios, efeito característico em redes distribuídas que não se baseiam em algoritmos de consenso [54].

4.1 Cooperação em Dois Passos

Para a cooperação em dois passos, considere, inicialmente, uma rede com topologia fixa composta por M rádios espacialmente distribuídos no *footprint*, a exemplo da rede ilustrada na Figura 4.1 [55]. Na estratégia proposta, todos os nós implementam

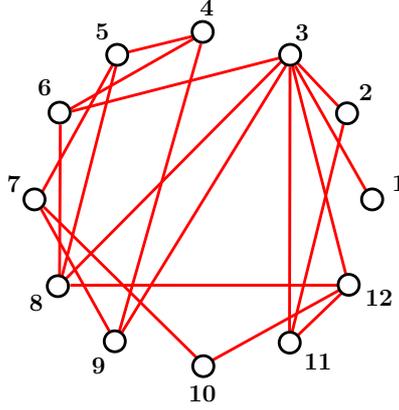


Figura 4.1: Rede distribuída com $M = 12$ nós.

detecção de energia e observam o canal durante o mesmo intervalo de sensoriamento. Após produzir sua estimativa de energia local, cada nó, referido a partir de agora como Nó k , inicia cooperação em dois passos com a vizinhança \mathcal{V}_k , definida como o conjunto dos nós conectados ao Nó k , incluindo ele mesmo [55].

4.1.1 Passo 1: Combinação *Soft*

Considere ainda, por simplicidade, a vizinhança do Nó k como sendo o conjunto $\mathcal{V}_k = \{1, 2, \dots, |\mathcal{V}_k|\}$, em que $|\mathcal{V}_k|$ é a cardinalidade do conjunto. No primeiro passo, cada nó combina diretamente as informações *soft* provenientes dos vizinhos. Para esse fim, este trabalho considerou combinação linear: o Nó k reúne as estimativas de energia dos nós $i \in \mathcal{V}_k$ e produz o teste local $T(\mathbf{y}_k)$ fazendo

$$T(\mathbf{y}_k) = \sum_{i \in \mathcal{V}_k} w_i y_i = \mathbf{w}_k^T \mathbf{y}_k, \quad (4.1)$$

onde $\mathbf{w}_k = [w_1, w_2, \dots, w_{|\mathcal{V}_k|}]^T$ é o vetor local de coeficientes e $\mathbf{y}_k = [y_1, y_2, \dots, y_{|\mathcal{V}_k|}]^T$ é o vetor das estimativas em \mathcal{V}_k . Em seguida, o Nó k classifica o teste usando um limiar local, γ_k , e assim produz uma *decisão binária local*, $u_k \in \{0, 1\}$:

$$T(\mathbf{y}_k) \underset{u_k=0}{\overset{u_k=1}{\gtrless}} \gamma_k. \quad (4.2)$$

Para tornar mais simples a obtenção dos parâmetros \mathbf{w}_k e γ_k por cada rádio, foi desenvolvido um combinador linear adaptativo. Combinadores desse tipo vêm atraindo interesse recente em sensoriamento cooperativo de espectro. Um dos primeiros trabalhos no tema investiga seu uso em redes centralizadas [46]. O método proposto em [54], por sua vez, implementa algoritmos de difusão adaptativos para detecção distribuída em redes de sensores e estende sua aplicabilidade para redes

cognitivas. Porém, trata-se de um método coerente, em que se assume prévio conhecimento sobre o sinal a ser detectado (sinal primário).

A estratégia adaptativa desenvolvida para esta etapa parte do fato de que a soma das estimativas de energia em \mathcal{V}_k varia em torno da soma das suas respectivas médias sob ambas as hipóteses. Ou seja,

$$\mathbf{1}^T \mathbf{y}_k \approx \mathbf{1}^T \boldsymbol{\mu}_{k,h}, \quad (4.3)$$

onde $\mathbf{1}$ é o vetor $|\mathcal{V}_k| \times 1$ com todos os elementos iguais a 1 e $\boldsymbol{\mu}_{k,h}$ é o vetor média $|\mathcal{V}_k| \times 1$ das estimativas em \mathcal{V}_k sob a hipótese \mathcal{H}_h , semelhante ao definido em (3.4). Seja $\boldsymbol{\Sigma}_{k,h}$ a matriz covariância $|\mathcal{V}_k| \times |\mathcal{V}_k|$ das estimativas em \mathcal{V}_k sob \mathcal{H}_h , também semelhante à definida em (3.5). A aproximação em (4.3) é comprometida pela contribuição conjunta das variâncias em $\boldsymbol{\Sigma}_{k,h}$, e cada uma delas é função da SNR primária e do nível de ruído do ambiente observados pelo seu respectivo nó (veja (2.8)).

Para reduzir o efeito das variâncias, pode-se montar, no Nó k , um problema de otimização do tipo

$$\min_{\mathbf{w}_k} E \left[(r_k - \mathbf{w}_k^T \mathbf{y}_k)^2 \right], \quad (4.4)$$

isto é, cuja solução ótima – um vetor local de coeficientes – é a que minimiza o erro quadrático médio (*Mean Squared Error* - MSE) entre o teste $T(\mathbf{y}_k)$ e um sinal de referência local r_k , modelado como

$$r_k = \begin{cases} \mathbf{1}^T \boldsymbol{\mu}_{k,0}, & \text{se } \mathcal{H}_0, \\ \mathbf{1}^T \boldsymbol{\mu}_{k,1}, & \text{se } \mathcal{H}_1. \end{cases} \quad (4.5)$$

Assim, obtém-se um problema de otimização que, embora leve a uma solução sub-ótima em comparação com (3.13), é convexo e mais simples de se resolver. Especificamente, o vetor que minimiza o MSE em (4.4) corresponde à solução de Wiener, \mathbf{w}_{k_o} , que é calculável no combinador linear local empregando um algoritmo adaptativo [56]. Mas, primeiramente, é necessário remodelar a referência r_k : note que ela não está disponível na forma como definida em (4.5), uma vez que não há como saber *a priori* qual hipótese é verdadeira em dado intervalo de sensoriamento.

O combinador adaptativo proposto para resolver (4.4) é apresentado na Figura 4.2, e inclui uma estrutura para a obtenção de uma estimativa da referência, \hat{r}_k . De acordo com a Figura 4.2, cada vizinho $i \in \mathcal{V}_k$ encaminha não apenas sua medida y_i , mas também uma *decisão binária individual*, $d_i \in \{0, 1\}$, produzida por meio de teste de hipóteses com y_i . Uma vez reunidos no Nó k , o vetor das estimativas \mathbf{y}_k alimenta a entrada do combinador linear, enquanto o vetor das decisões individuais,

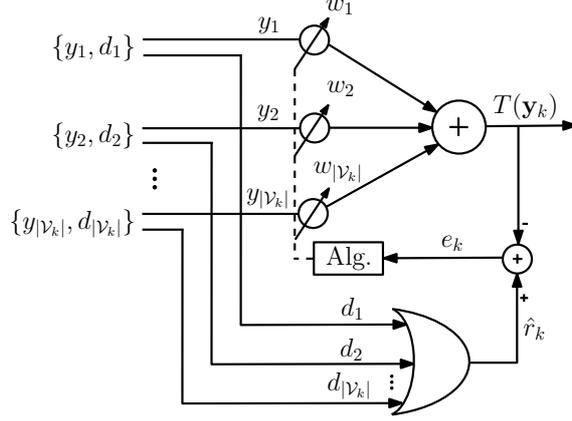


Figura 4.2: Combinador linear adaptativo proposto.

$\mathbf{d}_k = [d_1, d_2, \dots, d_{|\mathcal{V}_k|}]^T$, é usado para gerar \hat{r}_k através de fusão OR:

$$\hat{r}_k = \begin{cases} \mathbf{1}^T \boldsymbol{\mu}_{k,0}, & \text{se } \mathbf{OR}(d_1, d_2, \dots, d_{|\mathcal{V}_k|}) = 0, \\ \mathbf{1}^T \boldsymbol{\mu}_{k,1}, & \text{se } \mathbf{OR}(d_1, d_2, \dots, d_{|\mathcal{V}_k|}) = 1. \end{cases} \quad (4.6)$$

Naturalmente, deve-se garantir que a estimativa da referência \hat{r}_k seja suficiente para que o combinador adaptativo consiga convergir o vetor de coeficientes \mathbf{w}_k em direção à solução de Wiener. Isso pode ser um limitante da estrutura proposta, especialmente quando a SNR observada pelos rádios for muito baixa, já que, nessa situação, os erros nas decisões individuais d_i aumentam e comprometem a aproximação da referência ideal r_k . A despeito disso, como mostrarão os resultados ao longo deste capítulo, essa técnica funciona bem mesmo nas baixas SNR utilizadas nas simulações. Outrossim, por se tratar de uma estrutura adaptável, pode-se investigar variações com outras regras de votos, como a fusão AND, a fim de verificar quais se aplicam melhor em diferentes faixas de SNR.

Para obter a solução \mathbf{w}_{k_0} iterativamente, foi implementado o algoritmo *Least-Mean Squares* (LMS), que é um algoritmo adaptativo de baixa complexidade baseado no método do gradiente [56]. Assim, durante o n -ésimo intervalo de cooperação, o Nó k processa a informação instantânea de entrada conforme (4.1) e (4.2),

$$T(\mathbf{y}_k(n)) = \mathbf{w}_k^T(n) \mathbf{y}_k(n) \underset{u_k(n)=0}{\overset{u_k(n)=1}{\geq}} \gamma_k(n),$$

e então calcula o erro instantâneo, $e_k(n)$, que orienta a adaptação dos coeficientes:

$$e_k(n) = \hat{r}_k(n) - T(\mathbf{y}_k(n)), \quad (4.7)$$

$$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) + 2\mu_k e_k(n) \mathbf{y}_k(n), \quad (4.8)$$

onde μ_k é o fator de convergência do LMS [56].

Se substituirmos o vetor atualizado $\mathbf{w}_k(n+1)$ e as estatísticas locais $\boldsymbol{\mu}_{k,0}$ e $\boldsymbol{\Sigma}_{k,0}$ na expressão para o limiar de decisão central em (3.11), torna-se possível também obter atualizações instantâneas para o limiar local,

$$\gamma_k(n+1) = \mathbf{w}_k^T(n+1)\boldsymbol{\mu}_{k,0} + Q^{-1}(\varepsilon_k)\sqrt{\mathbf{w}_k^T(n+1)\boldsymbol{\Sigma}_{k,0}\mathbf{w}_k(n+1)}, \quad (4.9)$$

permitindo ao classificador produzir decisões sob a restrição local de alarmes falsos ε_k de maneira *online*, sem a necessidade de esperar até convergência do algoritmo. Note, entretanto, que isso só é possível mediante o acúmulo das informações $\boldsymbol{\mu}_{k,h}$ e $\boldsymbol{\Sigma}_{k,h}$ no Nó k da mesma forma como na central de fusão nas estratégias centralizadas.

Com a convergência do LMS, os parâmetros do combinador local serão o vetor ótimo \mathbf{w}_{k_o} e o seu correspondente limiar ótimo, γ_{k_o} . Logo, o desempenho de detecção teórico no Nó k após o primeiro passo será

$$P_{d,k,1} = P(T(\mathbf{y}_k) \geq \gamma_{k_o} | \mathcal{H}_1) = Q\left(\frac{\gamma_{k_o} - \mathbf{w}_{k_o}^T \boldsymbol{\mu}_{k,1}}{\sqrt{\mathbf{w}_{k_o}^T \boldsymbol{\Sigma}_{k,1} \mathbf{w}_{k_o}}}\right), \quad (4.10a)$$

$$P_{f,k,1} = P(T(\mathbf{y}_k) \geq \gamma_{k_o} | \mathcal{H}_0) = Q\left(\frac{\gamma_{k_o} - \mathbf{w}_{k_o}^T \boldsymbol{\mu}_{k,0}}{\sqrt{\mathbf{w}_{k_o}^T \boldsymbol{\Sigma}_{k,0} \mathbf{w}_{k_o}}}\right), \quad (4.10b)$$

ressaltando-se que, pelo princípio CFAR em (4.9), $P_{f,k,1} = \varepsilon_k$.

4.1.2 Passo 2: Combinação *Hard*

Após todos os rádios concluírem a combinação *soft*, a rede secundária procede à combinação *hard*. Neste segundo passo, cada nó emprega regra de fusão com as informações *hard* dos vizinhos (produzidas no primeiro passo) e, assim, toma uma *decisão consensual local*, definitiva, acerca do estado do canal. Neste trabalho, foi implementada uma regra de votos: o Nó k reúne as decisões binárias locais dos nós $i \in \mathcal{V}_k$ no vetor $\mathbf{u}_k = [u_1, u_2, \dots, u_{|\mathcal{V}_k|}]^T$ e aplica fusão OR ($m = 1$):

$$\text{Nó } k \text{ decide } \begin{cases} \mathcal{H}_0, & \text{se } \mathbf{OR}(u_1, u_2, \dots, u_{|\mathcal{V}_k|}) = 0, \\ \mathcal{H}_1, & \text{se } \mathbf{OR}(u_1, u_2, \dots, u_{|\mathcal{V}_k|}) = 1. \end{cases} \quad (4.11)$$

Observe que, em última análise, o segundo passo corresponde não somente a uma fusão de informações entre vizinhos, mas entre vizinhanças. Como as decisões binárias no vetor \mathbf{u}_k já são fruto de um processo intermediário de combinação, cada valor u_i carrega a influência (estimativa de energia) do sensoriamento realizado pelos seus respectivos vizinhos em \mathcal{V}_i . Por um lado, essa característica torna a estratégia proposta superior a outras baseadas em combinação *hard* convencional

(sem o primeiro passo) exatamente por promover maior diversidade de informação. Mas, por outro, também pode gerar correlação entre essas decisões binárias se suas vizinhanças de origem compartilharem nós em comum. Em outras palavras, o ganho de cooperação obtido com o segundo passo será tão menor quanto mais *redundância* houver entre as vizinhanças. Esse assunto será tratado em detalhes na Seção 4.3.

Por ora, é suficiente notar que, devido a essa redundância, não é possível aproximar o desempenho teórico no Nó k após o segundo passo diretamente pelas expressões para fusão OR em (3.2), válidas apenas para decisões descorrelacionadas. Ao invés de (3.2), deve-se recorrer à expansão de Bahadur-Lazarsfeld [57], que introduz o efeito da correlação entre as decisões dos vizinhos $i \in \mathcal{V}_k$ diretamente no cômputo dos indicadores de desempenho. Para isso, considere as seguintes fórmulas gerais para as probabilidades de detecção e alarme falso no Nó k após a fusão OR:

$$P_{d,k,2} = 1 - P(\mathbf{u}_k = [0, 0, \dots, 0] | \mathcal{H}_1), \quad (4.12a)$$

$$P_{f,k,2} = 1 - P(\mathbf{u}_k = [0, 0, \dots, 0] | \mathcal{H}_0). \quad (4.12b)$$

Para escrever $P(\mathbf{u}_k | \mathcal{H}_h)$ de uma maneira conveniente, é necessário primeiramente normalizar a variável aleatória binária u_i condicionada a cada hipótese separadamente. Sob a hipótese \mathcal{H}_h , u_i segue uma distribuição de Bernoulli de média $P(u_i = 1 | \mathcal{H}_h)$ e variância $P(u_i = 1 | \mathcal{H}_h)[1 - P(u_i = 1 | \mathcal{H}_h)]$; logo, pode-se fazer isso criando uma nova variável aleatória z_i^h ,

$$z_i^h = \frac{u_i - P(u_i = 1 | \mathcal{H}_h)}{\sqrt{P(u_i = 1 | \mathcal{H}_h)[1 - P(u_i = 1 | \mathcal{H}_h)]}}, \quad (4.13)$$

de média zero e variância unitária. Utilizando z_i^h , uma expressão mais geral para $P(\mathbf{u}_k | \mathcal{H}_h)$, de acordo com Bahadur-Lazarsfeld, é então dada por [57]

$$P(\mathbf{u}_k | \mathcal{H}_h) = \prod_{i,j,l,\dots \in \mathcal{V}_k} P(u_i | \mathcal{H}_h) \left[1 + \sum_{i < j} \rho_{ij}^h z_i^h z_j^h + \sum_{i < j < l} \rho_{ijl}^h z_i^h z_j^h z_l^h + \dots + \rho_{12\dots|\mathcal{V}_k}^h z_1^h z_2^h \dots z_{|\mathcal{V}_k}^h \right], \quad (4.14)$$

em que ρ^h são correlações entre as variáveis normalizadas: $\rho_{ij\dots l}^h = E[z_i^h z_j^h \dots z_l^h]$.

Note, com a ajuda de (4.13), que os termos ρ^h são coeficientes de correlação entre as variáveis originais u_i . Observe também que $P(u_i = 0 | \mathcal{H}_0) = (1 - P_{f,i,1})$ e $P(u_i = 0 | \mathcal{H}_1) = (1 - P_{d,i,1})$, onde $P_{f,i,1}$ e $P_{d,i,1}$ foram definidos em (4.10). Portanto, a expansão de Bahadur-Lazarsfeld permite contabilizar, no desempenho teórico final do Nó k em (4.12), tanto o desempenho parcial dos seus vizinhos $i \in \mathcal{V}_k$ após o primeiro passo quanto os níveis de correlação entre as suas decisões binárias.

4.1.3 Resultados

Esta seção busca avaliar a estratégia de cooperação em dois passos, bem como o combinador linear adaptativo desenvolvido para o primeiro passo, através de simulações. A avaliação da rede distribuída proposta é feita comparando-a com as estratégias isolada (sem cooperação) e centralizada. Para simular esta última, cada vizinhança realiza apenas o primeiro passo da cooperação (*soft*), equivalente ao procedimento de uma central que combina a mesma quantidade de informação disponível na vizinhança em questão; para simular a rede distribuída, ambos os passos (*soft* e *hard*) são considerados pelas vizinhanças. Por sua vez, a avaliação do combinador adaptativo se dá pela observação da convergência dos coeficientes usando o algoritmo LMS e, também, por comparação com o combinador linear ótimo, obtido maximizando-se o problema (3.13) numericamente. Ambas as comparações de desempenho – entre as redes e entre os combinadores – são feitas por meio de curvas C-ROC.

Uma rede secundária composta por 12 rádios cognitivos é simulada. Cada nó da rede produz 10^5 estimativas de energia sob mesma probabilidade *a priori* de ocorrência de \mathcal{H}_0 e \mathcal{H}_1 no canal sob sensoriamento. Cada conjunto individual de estimativas segue a aproximação gaussiana para y_i discutida na Seção 2.3.1: suas estatísticas de primeira ordem $\mu_{y_i,0}$ e $\mu_{y_i,1}$ estão apontados nos vetores média

$$\boldsymbol{\mu}_0 = [1 \quad 1 \quad \cdots \quad 1 \quad 1]^\text{T} \quad \text{e} \quad \boldsymbol{\mu}_1 = [1.2 \quad 1.4 \quad \cdots \quad 3.2 \quad 3.4]^\text{T},$$

enquanto suas estatísticas de segunda ordem $\sigma_{y_i,0}^2$ e $\sigma_{y_i,1}^2$ dependem do cenário de simulação considerado. No primeiro cenário, os nós sofrem apenas sombreamento descorrelacionado; nesse caso, as matrizes covariância $\boldsymbol{\Sigma}_0$ e $\boldsymbol{\Sigma}_1$ são matrizes identidade. No segundo cenário, nós espacialmente adjacentes estão sujeitos ao sombreamento correlacionado; isso é representado em ambas as hipóteses fazendo

$$\sigma_{y_i y_j,0} = \sigma_{y_i y_j,1} = 0.5,$$

em que, assumindo que o índice do nó corresponde à sua posição, i e j são índices tais que $|i - j| = 1$ ou $M - 1$. Vale enfatizar que as informações gerais $\boldsymbol{\mu}_h$ e $\boldsymbol{\Sigma}_h$ diferem das informações locais $\boldsymbol{\mu}_{k,h}$ e $\boldsymbol{\Sigma}_{k,h}$ mencionadas anteriormente, que contêm apenas estatísticas correspondentes aos nós $i \in \mathcal{V}_k$.

A topologia de rede fixa adotada para a cooperação entre os rádios é aquela da Figura 4.1, reproduzida na Figura 4.3 juntamente com as SNR individuais dos nós. Estas podem ser calculadas a partir das estatísticas de primeira e segunda ordem usando a fórmula [9]

$$\eta_i = \frac{2(\mu_{y_i,1} - \mu_{y_i,0})^2}{\sigma_{y_i,1}^2 + \sigma_{y_i,0}^2}.$$

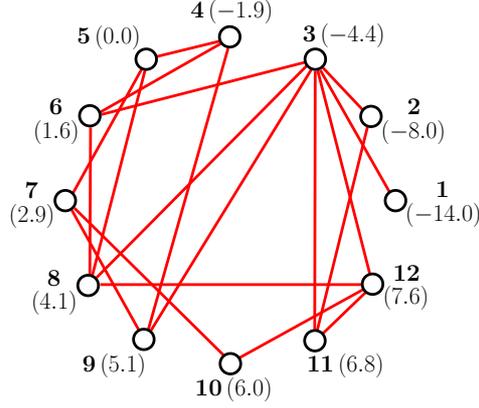


Figura 4.3: Rede distribuída simulada e as SNR (em dB) dos nós.

São apresentados os resultados relativos a dois nós em particular: o Nó 4 e o Nó 9. Conforme observado na Figura 4.3, a vizinhança do Nó 4 corresponde ao conjunto $\mathcal{V}_4 = \{4, 5, 6, 9\}$, enquanto a do Nó 9 é o conjunto $\mathcal{V}_9 = \{3, 4, 7, 9\}$. Para o combinador adaptativo do primeiro passo, todos os nós da rede rodam o algoritmo LMS com parâmetros locais que garantem qualidade de convergência similar entre eles tanto na simulação descorrelacionada quanto na correlacionada. No caso do Nó 4, os parâmetros do algoritmo são $\mu_4 = 1 \times 10^{-4}$ para o cenário descorrelacionado e $\mu_4 = 5 \times 10^{-4}$ para o cenário correlacionado; no Nó 9, esses parâmetros são $\mu_9 = 1 \times 10^{-4}$ (descorrelacionado) e $\mu_9 = 2 \times 10^{-4}$ (correlacionado). Por sua vez, todas as decisões binárias individuais d_i da rede (responsáveis pelas estimativas das referências \hat{r}_k dos combinadores locais) são produzidas com limiares calculados em (2.17) sob restrição de alarmes falsos igual a 0.01.

A Figura 4.4 mostra os resultados relativos ao Nó 4: curvas médias dos coeficientes após 20 convergências independentes e curvas C-ROC obtidas usando diferentes estratégias de sensoriamento. Os resultados das Figuras 4.4(a) e (b) correspondem à simulação com sombreamento descorrelacionado, enquanto os das Figuras 4.4(c) e (d) correspondem à simulação correlacionada. Para tornar a análise da convergência mais intuitiva, os coeficientes são apresentados normalizados, o que é indiferente para o desempenho final pois qualquer escalamento de um vetor \mathbf{w} produz o mesmo resultado em (3.10) e em (4.10) [8].

Analisando primeiramente os resultados do Nó 4 no cenário descorrelacionado, observa-se que os coeficientes da Figura 4.4(a) convergem de tal maneira que o combinador adaptativo favorece as contribuições *soft* com maior SNR, conforme desejado. Já as curvas C-ROC da Figura 4.4(b) confirmam o desempenho superior esperado usando cooperação em relação ao sensoriamento isolado. Note que o combinador adaptativo proposto oferece detecção comparável à do combinador linear ótimo em ambas as estratégias simuladas, centralizada e distribuída. Finalmente, é

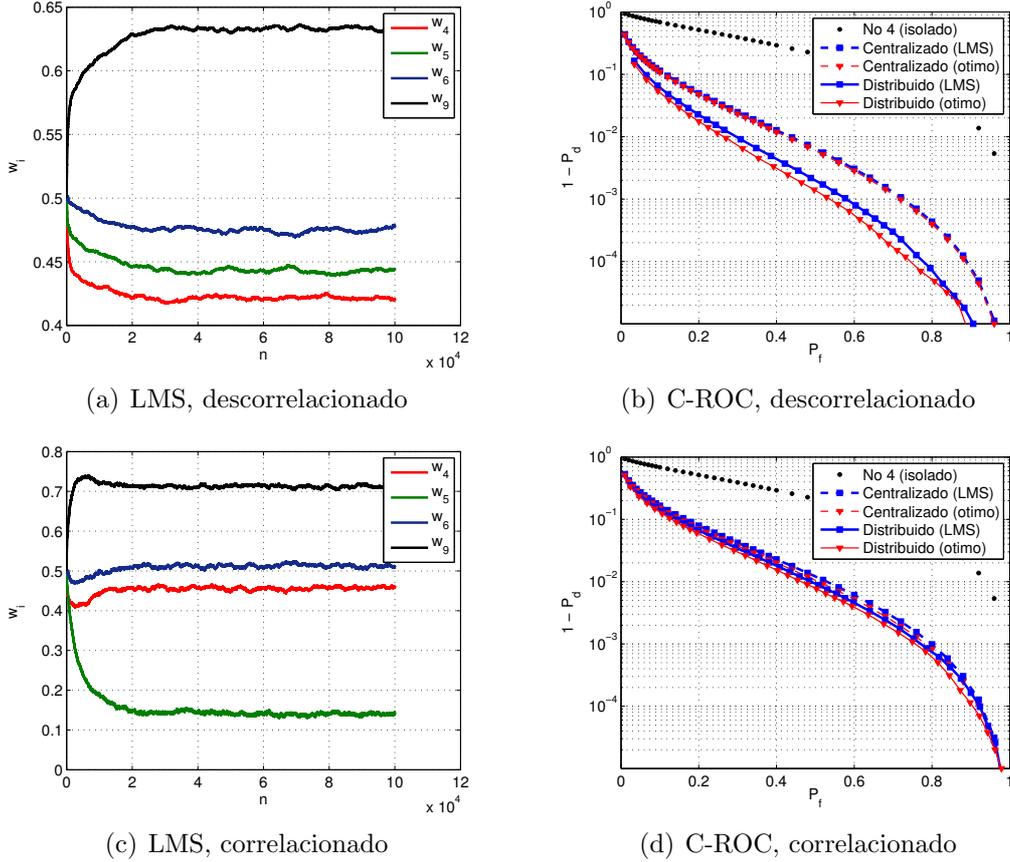


Figura 4.4: Convergência do LMS e curvas C-ROC relativos ao Nó 4.

possível verificar o ganho com a realização do segundo passo de cooperação (*hard*), indicando a superioridade da rede distribuída proposta sobre a rede centralizada equivalente (representada apenas pelo passo *soft*).

Os resultados do Nó 4 no cenário correlacionado também mostram alguns comportamentos importantes. Pela convergência dos coeficientes da Figura 4.4(c), nota-se que o combinador adaptativo não apenas favorece os nós segundo suas SNR individuais, mas também minimiza a influência daqueles cujas contribuições se correlacionam com as dos demais. Na vizinhança \mathcal{V}_4 , é o que ocorre com o Nó 5 em relação aos Nós 4 e 6. Com isso, o combinador proposto novamente garante desempenho comparável ao do combinador linear ótimo, como indicam as curvas C-ROC da Figura 4.4(d). Estas também confirmam a degradação que a cooperação, embora ainda superior ao sensoriamento isolado, sofre com o sombreamento correlacionado. A estratégia distribuída, em particular, sofre tanto com a correlação entre as estimativas dos nós adjacentes em \mathcal{V}_4 no primeiro passo quanto com a conseqüente correlação entre as suas respectivas decisões binárias no segundo. Por isso, ela praticamente não oferece ganho sobre a estratégia centralizada nessa simulação.

A Figura 4.5 apresenta os resultados relativos ao Nó 9, sendo os das Figuras 4.5(a) e (b) correspondentes à simulação descorrelacionada e os das Figuras 4.5(c) e (d) cor-

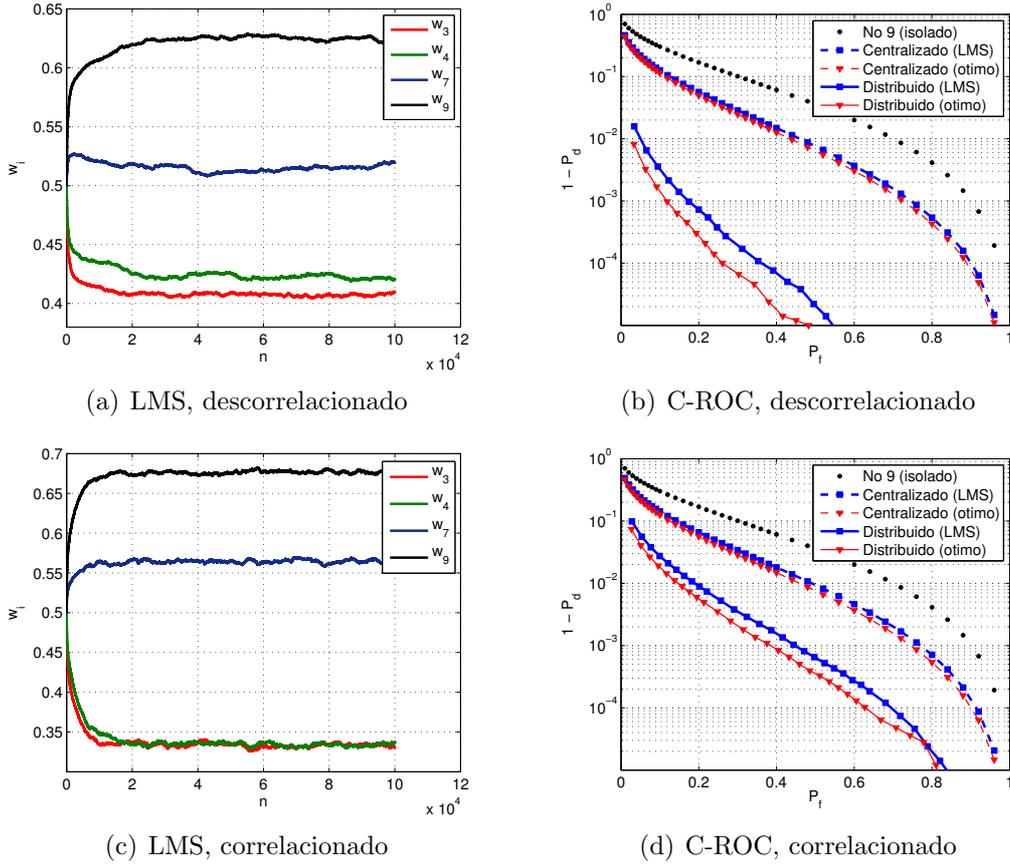


Figura 4.5: Convergência do LMS e curvas C-ROC relativos ao Nó 9.

respondentes à simulação correlacionada. As curvas de convergência são novamente médias de 20 simulações independentes, além de os coeficientes estarem normalizados, como no caso anterior. Note que as principais características dos resultados do Nó 4 se repetem no Nó 9: o combinador adaptativo proposto favorece as melhores contribuições *soft* na convergência, oferecendo desempenho próximo ao do combinador linear ótimo, enquanto a rede distribuída proposta se mostra superior à rede centralizada em ambos os cenários de simulação, apesar da considerável perda de desempenho no cenário correlacionado.

A diferença de comportamento mais notável entre os dois nós é o ganho muito mais significativo com a cooperação em dois passos no Nó 9. Essa variação de desempenho é observada ao longo de toda a rede, e pode ser explicada pelos diferentes conjuntos de vizinhos diretos e indiretos associados a cada nó. Como o segundo passo é, na verdade, uma fusão de informação entre vizinhanças, vários nós contribuem direta ou indiretamente para uma decisão consensual. Quanto mais diferentes forem esses conjuntos, seja em quantidade de vizinhos ou em SNR individuais, maior a discrepância entre as decisões dos rádios, como a que se verifica nos resultados dos Nós 4 e 9. Outro fator responsável por essas disparidades são os diferentes níveis de contribuição redundante em cada nó. Isso será visto na Seção 4.3.

4.2 Combinador *Soft* com Atualização Seletiva

Além de constituir uma solução mais simples e com bom desempenho frente ao combinador linear ótimo, o combinador linear adaptativo proposto para o primeiro passo oferece ainda meios para se investigar uma funcionalidade já observada em filtragem adaptativa *set-membership* [56, 58]: a atualização seletiva. Entenda-se, por atualização seletiva, a capacidade do filtro *set-membership* em adaptar os seus coeficientes apenas quando os dados de entrada são *conjuntamente informativos*, segundo um determinado critério. Como isso não se verifica em todas as iterações, o número de vezes em que ele atualiza os coeficientes é substancialmente reduzido em comparação com outros filtros convencionais, tornando sua demanda computacional menor [56]. Portanto, se estendermos esse conceito de “relevância” às contribuições *soft* (estimativas de energia) dos rádios cognitivos, pode-se obter o mesmo ganho em técnicas de cooperação envolvendo combinadores adaptativos, o que é especialmente útil se eles estiverem inseridos em estratégias distribuídas.

A filtragem *set-membership* parte do pressuposto de que o ruído adicional na entrada do filtro adaptativo é limitado, induzindo um limite estimável, $\bar{\gamma}$, também sobre o erro na saída do filtro. Nos casos em que tal premissa é válida, pode-se empregar uma estratégia de seleção que conduza a convergência dos coeficientes em direção a um conjunto limitado por $\bar{\gamma}$, denominado conjunto-viabilidade. Vetores \mathbf{w} contidos nesse conjunto são soluções aceitáveis para o filtro, correspondentes aos vetores que produzem um erro de saída igual ou inferior a $\bar{\gamma}$ [56]. Como o conjunto-viabilidade não está disponível na prática (isso requer o conhecimento de todos os dados de entrada possíveis), filtros *set-membership* implementam em seu lugar conjuntos-restrição, $\Theta(n)$, sob mesma definição, mas associados à informação de entrada em cada instante n . Assim, após uma quantidade suficiente de iterações, o filtro obtém uma solução ótima \mathbf{w}_o contida no interior da interseção entre os conjuntos-restrição, que, espera-se, corresponde a uma boa aproximação do conjunto-viabilidade [56].

Uma estratégia semelhante foi adotada para o combinador linear adaptativo da Figura 4.2. Seja o conjunto-restrição no Nó k , $\Theta_k(n)$, o conjunto dos vetores de coeficientes \mathbf{w}_k tais que o erro de saída do combinador local no intervalo de cooperação n seja limitado, em módulo, por um limiar de erro local, $\bar{\gamma}_k(n)$:

$$\Theta_k(n) = \{ \mathbf{w}_k \in \mathbb{R}^{|\mathcal{V}_k|} : |\hat{r}_k(n) - \mathbf{w}_k^T \mathbf{y}_k(n)| \leq \bar{\gamma}_k(n) \}. \quad (4.15)$$

Com base nessa definição, as contribuições instantâneas dos vizinhos $i \in \mathcal{V}_k$ serão consideradas “conjuntamente informativas” sempre que o conjunto-restrição $\Theta_k(n)$ associado ao par de entrada $\{\hat{r}_k(n), \mathbf{y}_k(n)\}$ não contiver o vetor de coeficientes atual $\mathbf{w}_k(n)$. Nesses casos, há inovação suficiente disponível para promover uma adaptação dos coeficientes, $\mathbf{w}_k(n+1)$, em direção a uma interseção mais próxima do conjunto-

viabilidade. Por outro lado, nos casos em que $\Theta_k(n)$ já contiver $\mathbf{w}_k(n)$, a informação dos vizinhos é descartada e nenhuma atualização é feita.

Observe que, nessa estratégia de seleção, o critério que determina se a informação de entrada é relevante ou não é representado pelo limiar de erro. Ajustá-lo corretamente é crucial: limiares grandes demais fazem com que o combinador atualize menos que o necessário, levando a uma convergência lenta e possivelmente inconsistente com a solução ótima; limiares muito pequenos restringem as soluções aceitáveis para o combinador, limitando o seu poder de seletividade [59]. Muitas aplicações em *set-membership* adotam um limiar de erro fixo, calculado com base na variância do ruído adicional de entrada. Outras, mais adequadas a ambientes dinâmicos, implementam limiares variantes no tempo, funções dos coeficientes em cada iteração e, portanto, capazes de acompanhar as mudanças no sistema [59].

O limiar de erro variante no tempo utilizado nesta aplicação, $\bar{\gamma}_k(n)$, é associado à perturbação na saída do combinador adaptativo. Para o Nó k , tal perturbação pode ser modelada, após a convergência, pelo sinal

$$\nu_k = r_k - \mathbf{w}_{k_o}^T \mathbf{y}_k, \quad (4.16)$$

cuja média, μ_{ν_k} , e variância, $\sigma_{\nu_k}^2$, são dadas pelas seguintes expressões:

$$\mu_{\nu_k} = \pi_0 \left((\mathbf{1} - \mathbf{w}_{k_o})^T \boldsymbol{\mu}_{k,0} \right) + \pi_1 \left((\mathbf{1} - \mathbf{w}_{k_o})^T \boldsymbol{\mu}_{k,1} \right), \quad (4.17)$$

$$\begin{aligned} \sigma_{\nu_k}^2 = & \pi_0 \left[\left((\mathbf{1} - \mathbf{w}_{k_o})^T \boldsymbol{\mu}_{k,0} - \mu_{\nu_k} \right)^2 + \mathbf{w}_{k_o}^T \boldsymbol{\Sigma}_{k,0} \mathbf{w}_{k_o} \right] \\ & + \pi_1 \left[\left((\mathbf{1} - \mathbf{w}_{k_o})^T \boldsymbol{\mu}_{k,1} - \mu_{\nu_k} \right)^2 + \mathbf{w}_{k_o}^T \boldsymbol{\Sigma}_{k,1} \mathbf{w}_{k_o} \right], \end{aligned} \quad (4.18)$$

onde π_0 e π_1 são, respectivamente, as probabilidades *a priori* de ocorrência de \mathcal{H}_0 e \mathcal{H}_1 no canal sob sensoriamento.

As estatísticas $\boldsymbol{\mu}_{k,h}$, $\boldsymbol{\Sigma}_{k,h}$, π_0 e π_1 estão disponíveis no Nó k . As duas primeiras, como já mencionado, são acumuláveis a partir dos nós vizinhos. Já as probabilidades π_0 e π_1 fazem parte do perfil da utilização primária do espectro traçado pela rede secundária ao longo do tempo; conhecê-las é útil no estabelecimento de políticas de sensoriamento e acesso [60], além de ser requisito para algumas técnicas de detecção, como as que envolvem o critério de Bayes [15, 61]. De posse delas, o Nó k pode obter estimativas instantâneas das estatísticas de ν_k , $\hat{\mu}_{\nu_k}(n+1)$ e $\hat{\sigma}_{\nu_k}^2(n+1)$, substituindo o vetor de coeficientes atualizado $\mathbf{w}_k(n+1)$ em (4.17) e (4.18), respectivamente.

Assim, pode-se implementar, no Nó k , um limiar de erro variante no tempo [56] como função da variância instantânea da perturbação ν_k ,

$$\bar{\gamma}_k(n+1) = \alpha_k \bar{\gamma}_k(n) + (1 - \alpha_k) \sqrt{\beta_k \hat{\sigma}_{\nu_k}^2(n+1)}, \quad (4.19)$$

em que α_k é um fator de esquecimento local e β_k é uma constante local. Em *set-membership*, essa constante é comumente ajustada em 5, embora isso, em geral, dependa da aplicação [56]. No caso do combinador adaptativo proposto, é necessário levar em conta a qualidade da estimativa da referência \hat{r}_k em (4.6), de modo que o ajuste de β_k não comprometa a robustez da convergência dos coeficientes principalmente em baixa SNR, quando os erros em \hat{r}_k aumentam.

4.2.1 Algoritmo SU-LMS

O algoritmo LMS com atualização seletiva (*Selective Updating LMS* – SU-LMS) proposto para o combinador *soft* da Figura 4.2 é apresentado na Tabela 4.1. Conforme observado, a estratégia de seleção introduzida com o SU-LMS se dá na comparação, em cada intervalo de cooperação n , entre o erro instantâneo $e_k(n)$ e o limiar instantâneo $\bar{\gamma}_k(n)$: novos parâmetros $\mathbf{w}_k(n+1)$ e $\bar{\gamma}_k(n+1)$ são calculados somente se o módulo de $e_k(n)$ for superior a $\bar{\gamma}_k(n)$.

Tabela 4.1: Algoritmo SU-LMS proposto.

Inicialize μ_k, α_k, β_k
Inicialize $\bar{\gamma}_k(0) = 0$
Para $n \geq 0$, faça
$e_k(n) = \hat{r}_k(n) - \mathbf{w}_k^T(n)\mathbf{y}_k(n)$
Se $ e_k(n) > \bar{\gamma}_k(n)$
$\mathbf{w}_k(n+1) = \mathbf{w}_k(n) + 2\mu_k e_k(n)\mathbf{y}_k(n)$
$\bar{\gamma}_k(n+1) = \alpha_k \bar{\gamma}_k(n) + (1 - \alpha_k) \sqrt{\beta_k \hat{\sigma}_{\nu_k}^2(n+1)}$
Senão
$\mathbf{w}_k(n+1) = \mathbf{w}_k(n)$
$\bar{\gamma}_k(n+1) = \bar{\gamma}_k(n)$

Note que esse algoritmo é semelhante ao algoritmo *Set-Membership Normalized LMS* (SM-NLMS) [56, 58]. A diferença é que ele não promove passo de atualização otimizado, uma vez que o fator de convergência μ_k não é ajustável segundo a diferença instantânea entre o erro $e_k(n)$ e o limiar $\bar{\gamma}_k(n)$, como ocorre no SM-NLMS. Conseqüentemente, o algoritmo proposto não garante vetores adaptados $\mathbf{w}_k(n+1)$ sobre a fronteira do conjunto-restrição $\Theta_k(n)$ e, portanto, a variação dos coeficientes não segue o princípio da mínima perturbação [58]. Embora isso impossibilite motivá-lo como um algoritmo *set-membership*, é importante, nesta aplicação, manter um passo de atualização fixo para minimizar a influência de grandes valores de $e_k(n)$ nos intervalos n em que houver erro na estimativa da referência $\hat{r}_k(n)$, prevenindo a ocorrência de inconsistências.

4.2.2 Resultados

Os resultados desta seção permitem avaliar a capacidade de seleção de informação do algoritmo SU-LMS proposto. Por meio de simulações, são obtidos percentuais de atualização efetuados pelo combinador linear adaptativo, bem como investigados eventuais efeitos que a seletividade possa causar na convergência dos coeficientes. Ao mesmo tempo, sem perder de vista o objetivo principal – o ganho de cooperação –, também são apresentados resultados em termos de curvas C-ROC, a fim de verificar se o algoritmo proposto afeta a detecção da rede distribuída em comparação com o algoritmo LMS convencional.

Para as simulações, considere novamente a rede secundária e os cenários de sombreamento descorrelacionado e correlacionado anteriores, além da topologia fixa e as SNR individuais apresentadas na Figura 4.3. O algoritmo LMS implementado pelo combinador *soft* é substituído pelo algoritmo SU-LMS, com parâmetros locais que garantem convergência com qualidade e robustez similares entre os nós. Mais uma vez, os resultados relativos aos Nós 4 e 9 são analisados. Para o Nó 4, os parâmetros do algoritmo local são: $\alpha_4 = 0.995$, $\beta_4 = 3$, $\mu_4 = 1 \times 10^{-4}$ (caso descorrelacionado) e $\mu_4 = 5 \times 10^{-4}$ (caso correlacionado). Para o Nó 9, esses parâmetros são: $\alpha_9 = 0.995$, $\beta_9 = 3$, $\mu_9 = 1 \times 10^{-4}$ (descorrelacionado) e $\mu_9 = 2 \times 10^{-4}$ (correlacionado).

A Figura 4.6 apresenta a convergência do algoritmo SU-LMS no Nó 4 e as curvas C-ROC obtidas pelo rádio nos cenários descorrelacionado (Figuras 4.6(a) e (b)) e correlacionado (Figuras 4.6(c) e (d)). As curvas dos coeficientes correspondem, mais uma vez, a uma média de 20 convergências independentes, além de eles serem apresentados normalizados. Já a Tabela 4.2 mostra os percentuais de atualização do combinador do Nó 4 durante os regimes transiente e permanente em ambos os cenários de simulação, também tomados como média das 20 simulações. O regime transiente compreende os 5% primeiros intervalos de cooperação, valor adotado com base no transiente da convergência do limiar de erro $\bar{\gamma}_4(n)$.

Observe, pelos percentuais da Tabela 4.2, a redução considerável de processamento no Nó 4 proporcionada pelo algoritmo SU-LMS tanto no cenário descorrelacionado quanto no correlacionado. Como esperado, o volume de atualizações dos coeficientes é sensivelmente maior durante o regime transiente, embora também em percentuais pequenos. Por outro lado, as Figuras 4.6(a) e (c) mostram que a seletividade de informação não altera o comportamento da convergência dos coeficientes em relação ao obtido com o algoritmo LMS. O mesmo se verifica na detecção: comparando-se as curvas C-ROC das Figuras 4.6(b) e (d) com as correspondentes às simulações anteriores (veja a Figura 4.4), nota-se que o algoritmo proposto não altera o desempenho do combinador adaptativo frente ao combinador linear ótimo, nem compromete o ganho de cooperação da rede distribuída em dois passos.

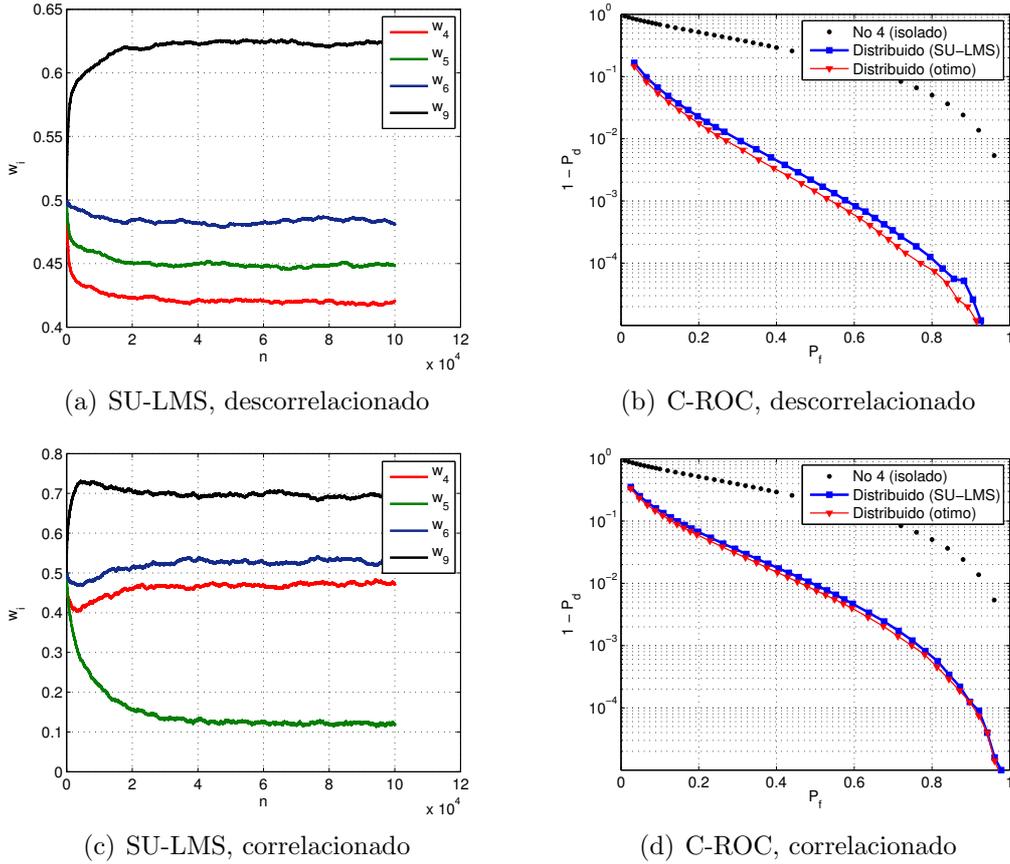


Figura 4.6: Convergência do SU-LMS e curvas C-ROC relativos ao Nó 4.

Tabela 4.2: Percentual de atualizações do combinador adaptativo do Nó 4.

Intervalo/Cenário	Descorrelacionado	Correlacionado
Transiente (primeiros 5%)	26.46%	20.00%
Permanente	17.00%	13.73%

A Figura 4.7 e a Tabela 4.3 apresentam os resultados das simulações descorrelacionada e correlacionada usando o algoritmo SU-LMS no Nó 9. As convergências dos coeficientes normalizados das Figuras 4.7(a) e 4.7(c), bem como os percentuais de atualização da Tabela 4.3, são novamente resultados médios de 20 simulações independentes. O regime transiente no Nó 9 (5% primeiras iterações) também é definido com base no transiente do seu limiar $\bar{\gamma}_9(n)$. Mais uma vez, observa-se a capacidade do algoritmo proposto em promover redução da carga de processamento no rádio em ambos os cenários, sem alterar o comportamento da convergência anterior, obtido sem seletividade de informação. Consequentemente, como mostram as curvas C-ROC das Figuras 4.7(b) e (d), o desempenho do combinador com atualização seletiva se mantém comparável ao do combinador linear ótimo, resultado idêntico ao das simulações da Figura 4.5.

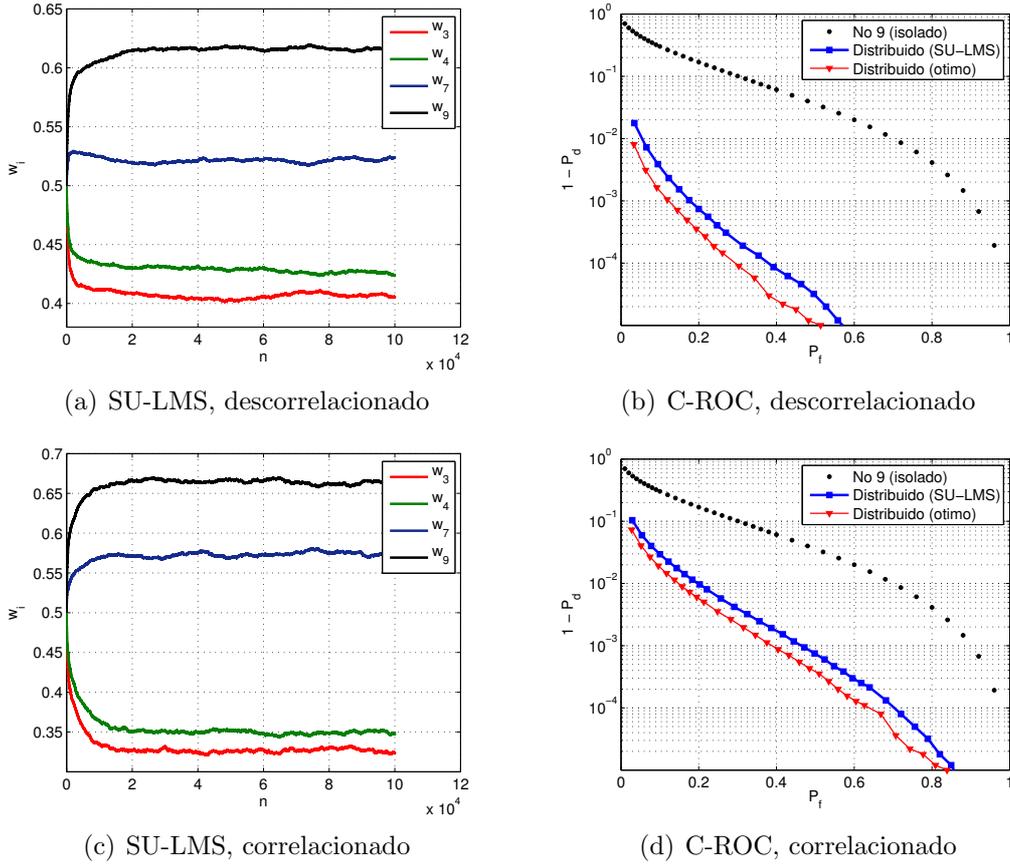


Figura 4.7: Convergência do SU-LMS e curvas C-ROC relativos ao Nó 9.

Tabela 4.3: Percentual de atualizações do combinador adaptativo do Nó 9.

Intervalo/Cenário	Descorrelacionado	Correlacionado
Transiente (primeiros 5%)	26.97%	22.92%
Permanente	16.50%	15.41%

4.3 Cooperação com Dupla Topologia

Os resultados das seções anteriores evidenciaram, dentre outros efeitos, a degradação de desempenho imposta a uma rede cooperativa de sensoriamento quando há correlação entre as contribuições dos nós. As simulações investigaram particularmente a correlação devida ao sombreamento, que, conforme discutido na Seção 3.3, ocorre quando dois ou mais rádios sofrem efeitos de sombreamento similares entre eles e o transmissor primário. Nessa situação, a correlação aparece diretamente entre os resultados do seu sensoriamento – no caso, suas estimativas de energia. Também conforme já mencionado, as técnicas propostas na literatura para evitar o sombreamento correlacionado envolvem, basicamente, estimação prévia da correlação entre os nós e subsequente seleção de usuário [40, 41].

Para a nova estratégia de cooperação em dois passos, considerou-se, até agora, a

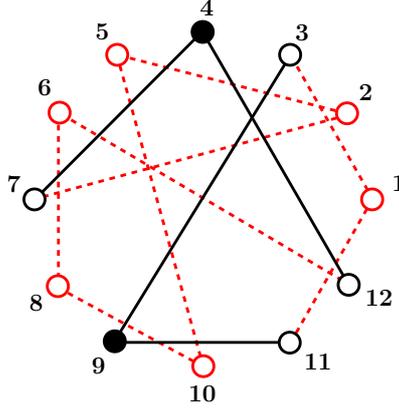


Figura 4.8: Rede com $M = 12$ nós organizados em única topologia.

utilização de uma topologia de rede fixa, por meio da qual cada nó se comunica com os mesmos vizinhos durante todo o processo até a decisão consensual. No entanto, observou-se que fixar a topologia introduz um novo tipo de correlação na rede: a *correlação devida à redundância*, que ocorre quando algum nó contribui mais de uma vez para a decisão. Na estratégia proposta, a redundância se manifesta através de vizinhos *diretos redundantes*, que são aqueles pertencentes à vizinhança do nó e que, portanto, cooperam com ele nos dois passos; e de vizinhos *indiretos redundantes*, correspondentes aos que, embora não pertençam diretamente à vizinhança do nó, cooperam com dois ou mais de seus vizinhos. Ambas as classes de redundância degradam o desempenho final da cooperação de maneira idêntica à correlação devida ao sombreamento. Também se observou que diferentes níveis de correlação devida à redundância sofridos pelos nós podem levar a grandes variações de desempenho entre eles, o que explica, em grande parte, os resultados discrepantes (mesmo sob sombreamento descorrelacionado) observados nas simulações anteriores.

Para explicar melhor esse problema, considere, a partir de agora, a topologia ilustrada na Figura 4.8. O inconveniente em se mantê-la fixa durante as combinações *soft* e *hard* decorre do fato de que, após o primeiro passo, as decisões binárias locais produzidas pelos vizinhos adquirem correlação entre si. Por exemplo, na vizinhança $\mathcal{V}_9 = \{3, 9, 11\}$, destacada na Figura 4.8, a decisão binária do Nó 9, u_9 , é correlacionada com a decisão binária do Nó 3, u_3 , porque ambas carregam a influência do sensoriamento (estimativa de energia) um do outro. O mesmo ocorre entre as decisões binárias dos Nós 9 e 11, u_9 e u_{11} . Já as decisões binárias dos Nós 3 e 11, u_3 e u_{11} , são correlacionadas porque ambas carregam a influência do sensoriamento do Nó 9 e também do Nó 1, que está conectado aos dois simultaneamente. Seguindo o mesmo raciocínio, pode-se observar que as decisões binárias locais dentro da vizinhança $\mathcal{V}_4 = \{4, 7, 12\}$, destacada na Figura 4.8, também se correlacionam: u_4 com u_7 e com u_{12} , e u_7 com u_{12} .

De um modo geral, decisões binárias locais adquirem correlação quando suas respectivas vizinhanças compartilham um ou mais nós em comum. Se decisões binárias desse tipo forem combinadas no segundo passo, os nós em comum responsáveis pela correlação serão *redundantes* sob o ponto de vista da decisão consensual, pois suas influências serão contabilizadas mais de uma vez. Seja $\mathcal{V}_{U,k}$ o conjunto total dos vizinhos – diretos e indiretos – que contribuem para a decisão consensual do Nó k usando única topologia. No exemplo do Nó 9, ao combinar u_3 , u_9 e u_{11} no segundo passo, sua decisão consensual local será fruto da influência do conjunto $\mathcal{V}_{U,9} = \{1, 3, 9, 11\}$, em que os Nós 3, 9 e 11 serão vizinhos diretos redundantes e o Nó 1 será um vizinho indireto redundante. Da mesma maneira, ao fazer combinação *hard* com u_4 , u_7 e u_{12} , o Nó 4 produzirá uma decisão consensual local sob influência do conjunto $\mathcal{V}_{U,4} = \{2, 4, 6, 7, 12\}$, em que os vizinhos indiretos 2 e 6 serão não-redundantes, mas os vizinhos diretos 4, 7 e 12 serão redundantes. A presença dessas redundâncias induzirá o efeito da correlação entre as decisões binárias locais sobre as decisões consensuais locais, degradando o desempenho final dos nós de forma idêntica à que ocorreria se a fonte da correlação fosse o sombreamento.

Na Seção 4.1.2, foi apresentada a expansão de Bahadur-Lazarsfeld, cujos coeficientes de correlação ρ^h , se associados às decisões binárias dos rádios, permitem avaliar o desempenho real de uma rede cooperativa de sensoriamento sujeita a correlação, independentemente da origem – redundância, sombreamento ou ambos. Alguns trabalhos na literatura, inclusive, empregam esses coeficientes no desenvolvimento de detectores *hard* mais adequados à fusão de informações correlacionadas. Por exemplo, o trabalho [57] generaliza a fusão *hard* ótima para redes de sensores reescrevendo o teste do detector em função da expansão de Bahadur-Lazarsfeld. Em [62], é desenvolvido um detector sub-ótimo, de natureza linear-quadrática, que requer apenas informação estatística parcial entre os nós em comparação com [57].

Detectores como os disponíveis em [57, 62] apresentam desempenho superior à regra de votos para fusão de dados correlacionados. Logo, certamente funcionariam melhor também para este novo caso, mas a um custo computacional muito maior. Ao invés de utilizá-los, este trabalho preserva a simplicidade da regra de votos e, assim como no caso do sombreamento correlacionado, oferece uma solução para o problema da redundância baseada em seleção de usuário.

4.3.1 Topologias Primária e Complementar

O esquema proposto para eliminar a redundância da rede consiste em utilizar duas topologias diferentes, chamadas *topologia primária* e *topologia complementar*, uma para cada passo de cooperação. Especificamente, o Nó k passa a realizar combinação *soft* com uma *vizinhança primária*, $\mathcal{V}_{k,1}$, e combinação *hard* com uma *vizinhança*

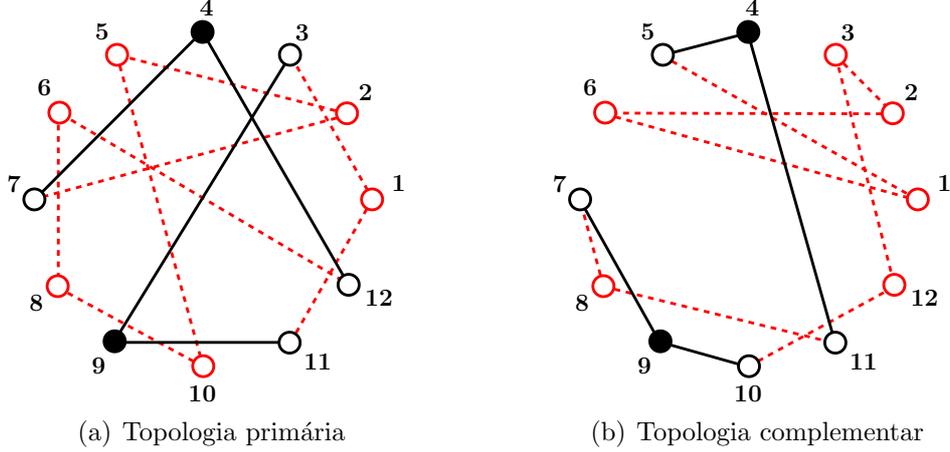


Figura 4.9: Rede com $M = 12$ nós organizados em dupla topologia.

complementar, $\mathcal{V}_{k,2}$. Essa ideia está ilustrada na rede da Figura 4.9. O projeto da topologia complementar é diretamente vinculado ao da primária. Além disso, ambas são geradas de maneira distribuída: cada nó individualmente determina candidatos a vizinhos utilizando critérios de seleção de usuário e, em seguida, escolhe alguns deles para montar suas vizinhanças.

Para a topologia primária, qualquer critério de seleção na literatura pode ser adotado pelo nó na determinação de possíveis vizinhos primários. No contexto do sombreamento correlacionado, por exemplo, ele pode implementar algoritmos estimadores de correlação como os propostos em [40, 41]. Neste trabalho, tem-se assumido, por simplicidade, que apenas nós espacialmente adjacentes estão suscetíveis à correlação devida ao sombreamento; logo, também deveriam ser evitados em uma mesma vizinhança primária. Usando esse critério, e novamente assumindo que o índice do nó corresponde à sua posição, o conjunto dos candidatos primários inicial do Nó k (conjunto dos candidatos a pertencerem a $\mathcal{V}_{k,1}$) pode ser definido como

$$\mathcal{C}_{k,1}(0) = \{i : 1 < |i - k| < M - 1\}. \quad (4.20)$$

Após todos os nós determinarem seus conjuntos iniciais de candidatos, a rede pode utilizar o algoritmo sequencial proposto na Tabela 4.4 para gerar a topologia primária de maneira distribuída: em cada iteração l , o Nó k chama um candidato i do conjunto $\mathcal{C}_{k,1}(l)$; uma vez este verificando que o Nó k também é um candidato seu em $\mathcal{C}_{i,1}(l)$, ambos incluem um ao outro em suas respectivas vizinhanças primárias. Os dois, então, atualizam seus candidatos primários: o Nó k recebe do Nó i o conjunto inicial $\mathcal{C}_{i,1}(0)$ para obter um novo conjunto $\mathcal{C}_{k,1}(l + 1)$, enquanto o Nó i recebe $\mathcal{C}_{k,1}(0)$ para calcular $\mathcal{C}_{i,1}(l + 1)$. O processo continua até que algum conjunto de candidatos se torne vazio ou até que a cardinalidade desejada seja alcançada em todas as vizinhanças. A topologia primária da Figura 4.9(a) foi obtida usando esse

Tabela 4.4: Algoritmo sequencial gerador de topologias proposto ($T = 1, 2$).

Inicialize $\mathcal{V}_{k,T} \leftarrow \{k\}$
Para $l \geq 0$, faça
Para cada Nó k , ainda não escolhido na iteração l , faça
(1) Nó k chama qualquer $i \in \mathcal{C}_{k,T}(l)$, ainda não escolhido na iteração l
(2) Nó i verifica: se $k \notin \mathcal{C}_{i,T}(l)$, retorna a (1). Senão,
(3) Nó k recebe $\mathcal{C}_{i,T}(0)$:
$\mathcal{V}_{k,T} \leftarrow \mathcal{V}_{k,T} \cup \{i\}$
$\mathcal{C}_{k,T}(l+1) \leftarrow \mathcal{C}_{k,T}(l) \cap \mathcal{C}_{i,T}(0)$
Nó i recebe $\mathcal{C}_{k,T}(0)$:
$\mathcal{V}_{i,T} \leftarrow \mathcal{V}_{i,T} \cup \{k\}$
$\mathcal{C}_{i,T}(l+1) \leftarrow \mathcal{C}_{i,T}(l) \cap \mathcal{C}_{k,T}(0)$

algoritmo, com cardinalidade desejada ajustada em $|\mathcal{V}_{k,1}| = 3$. Note que todas as vizinhanças primárias satisfazem o critério estabelecido em (4.20).

Com a topologia primária gerada, a rede inicia o projeto da topologia complementar. Diferentemente da primeira etapa, o critério de seleção de usuário adotado nesta segunda é bem específico: como a origem da redundância está na existência de nós em comum entre as vizinhanças primárias, o Nó k deve selecionar, como possíveis vizinhos complementares, apenas aqueles cujos vizinhos primários não coincidam com nenhum de seus vizinhos primários. Assim, o *conjunto dos candidatos complementares* inicial do Nó k é definido como

$$\mathcal{C}_{k,2}(0) = \{i : \mathcal{V}_{i,1} \cap \mathcal{V}_{k,1} = \emptyset\}. \quad (4.21)$$

Em seguida, a rede pode recorrer novamente ao algoritmo da Tabela 4.4 para gerar a topologia complementar. A Figura 4.9(b) apresenta uma das possíveis topologias complementares associadas à topologia primária da Figura 4.9(a), também obtida com o algoritmo proposto ajustando-se a cardinalidade em $|\mathcal{V}_{k,2}| = 3$. Note que todas as vizinhanças complementares satisfazem o critério adotado em (4.21).

4.3.2 Eliminação da Redundância

Para ilustrar os benefícios dessa nova estratégia, seja $\mathcal{V}_{D,k}$ o conjunto dos vizinhos diretos e indiretos que contribuem para a decisão consensual do Nó k usando dupla topologia. Considere as vizinhanças complementares dos Nós 9 e 4, $\mathcal{V}_{9,2} = \{7, 9, 10\}$ e $\mathcal{V}_{4,2} = \{4, 5, 11\}$, destacadas na Figura 4.9(b). No segundo passo, o Nó 9 passa a combinar as decisões binárias locais u_7 , u_9 e u_{10} , que, por sua vez, carregam a influência do sensoriamento proveniente de suas respectivas vizinhanças primárias: u_7 de $\mathcal{V}_{7,1} = \{2, 4, 7\}$, u_9 de $\mathcal{V}_{9,1} = \{3, 9, 11\}$ e u_{10} de $\mathcal{V}_{10,1} = \{5, 8, 10\}$ (veja a Figura 4.9(a)). Como nenhum nó se repete entre essas vizinhanças, a decisão

consensual do Nó 9 será produzida sob influência de um conjunto formado apenas por vizinhos não-redundantes, $\mathcal{V}_{D,9} = \{2, 3, 4, 5, 7, 8, 9, 10, 11\}$. De modo semelhante, pode-se observar que a decisão consensual do Nó 4 também carregará a influência apenas de vizinhos não-redundantes em $\mathcal{V}_{D,4} = \{1, 2, 4, 5, 7, 9, 10, 11, 12\}$.

Uma vez livres da redundância, se os rádios da rede também estiverem livres do sombreamento correlacionado, todos os coeficientes de correlação na expansão de Bahadur-Lazarsfeld em (4.14) se anulam. Com isso, o desempenho teórico final do Nó k em (4.12) após realizar combinação *hard* com $\mathcal{V}_{k,2}$ se reduz às fórmulas em (3.2) correspondentes a fusão OR com contribuições descorrelacionadas:

$$P_{d,k,2} = 1 - \prod_{i \in \mathcal{V}_{k,2}} (1 - P_{d,i,1}), \quad (4.22a)$$

$$P_{f,k,2} = 1 - \prod_{i \in \mathcal{V}_{k,2}} (1 - P_{f,i,1}), \quad (4.22b)$$

onde as probabilidades $P_{d,i,1}$ e $P_{f,i,1}$ correspondem ao desempenho parcial de cada Nó $i \in \mathcal{V}_{k,2}$ em (4.10) após realizar combinação *soft* com $\mathcal{V}_{i,1}$.

4.3.3 Resultados

Para verificar o ganho na detecção obtido com a eliminação da redundância, esta seção compara as estratégias de cooperação usando única e dupla topologia por meio de curvas C-ROC. São novamente simulados a rede secundária e os cenários de sombreamento descorrelacionado e correlacionado anteriores. Mas, inicialmente, a fim de que sejam observados apenas os efeitos da correlação, todos os nós da rede apresentam a mesma SNR: 0 dB. As topologias utilizadas na cooperação também mudam. Para as primeiras simulações, considere as mostradas na Figura 4.9: para simular a estratégia com única topologia, a rede adota a topologia primária da Figura 4.9(a), que é mantida durante ambas as combinações (*soft* e *hard*); para simular a estratégia com dupla topologia, a rede a substitui pela topologia complementar da Figura 4.9(b) durante a combinação *hard*.

A Figura 4.10 apresenta os resultados. Nas Figuras 4.10(a) e (b), são plotadas, respectivamente, as curvas C-ROC obtidas pelos Nós 4 e 9 na simulação com sombreamento descorrelacionado. Usando única topologia, fica clara, nos resultados dos dois nós, a perda de desempenho de detecção causada pela redundância. No caso do Nó 9, a perda é sensivelmente maior porque, como visto anteriormente, ele sofre com ambas as redundâncias, direta e indireta. Em compensação, as curvas C-ROC relativas à cooperação com dupla topologia praticamente coincidem com as curvas teóricas para contribuições descorrelacionadas em (4.22), confirmando a capacidade da estratégia proposta em evitar a correlação devida à redundância.

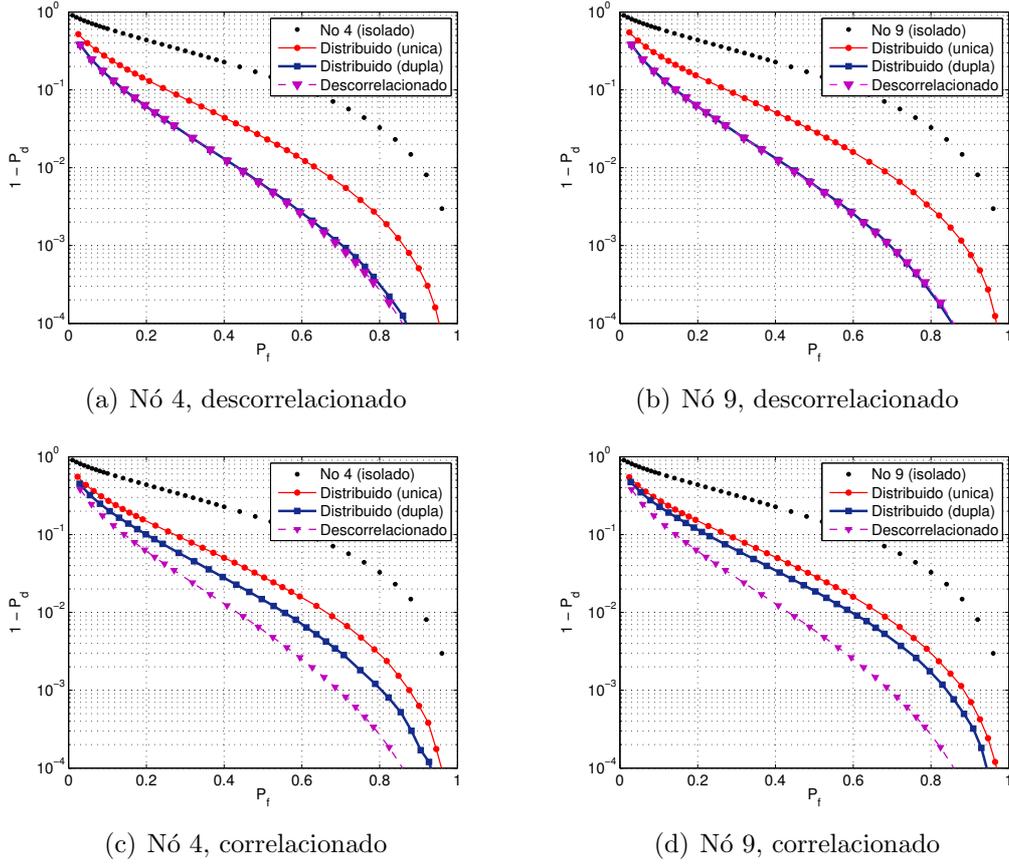


Figura 4.10: Curvas C-ROC relativas aos Nós 4 e 9 usando única e dupla topologia.

Por sua vez, as Figuras 4.10(c) e (d) mostram os resultados dos Nós 4 e 9 correspondentes à simulação correlacionada. Observe que a cooperação com dupla topologia se mantém superior à estratégia com única topologia, embora suas curvas não mais coincidam com as curvas teóricas em (4.22). Isso se deve ao fato de que a cooperação em dois passos, mesmo usando dupla topologia, permanece suscetível aos efeitos da correlação se o conjunto total de vizinhos diretos e indiretos envolver nós sob sombreamento correlacionado. Note que, das quatro curvas C-ROC obtidas com cooperação, a única inalterada de um cenário de simulação para o outro é a do Nó 9 usando única topologia, uma vez que o conjunto $\mathcal{V}_{U,9} = \{1, 3, 9, 11\}$ é o único que não possui nós adjacentes, enquanto os demais – $\mathcal{V}_{D,9}$, $\mathcal{V}_{U,4}$ e $\mathcal{V}_{D,4}$ – possuem. Apesar disso, é importante ressaltar que a dupla topologia também permite lidar com o sombreamento correlacionado, se forem inseridos critérios específicos para isso não apenas na seleção de candidatos primários em (4.20), mas também na de candidatos complementares em (4.21).

Ao substituir as conexões redundantes por conexões com outros nós diferentes, a estratégia de cooperação com dupla topologia também faz com que mais rádios contribuam para cada decisão consensual. No exemplo das topologias da Figura 4.9, o número de nós participantes da decisão do Nó 9 aumenta de $|\mathcal{V}_{U,9}| = 4$, usando

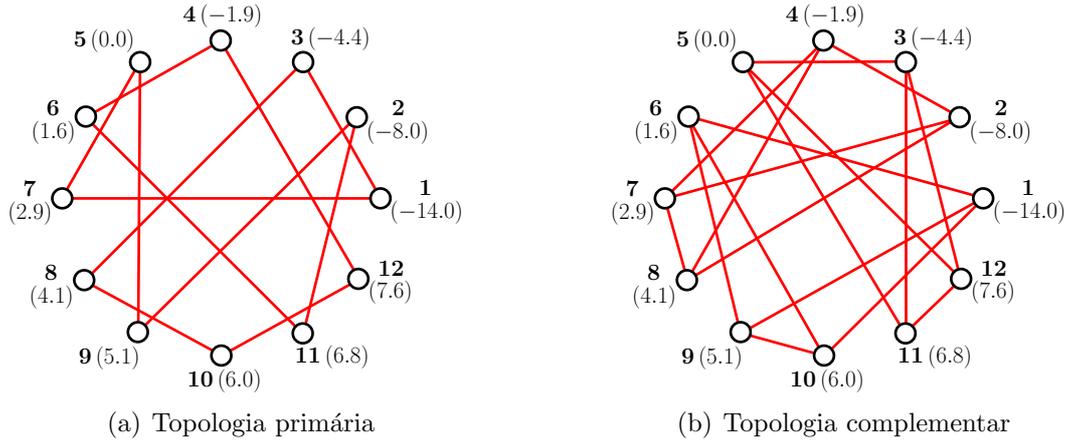
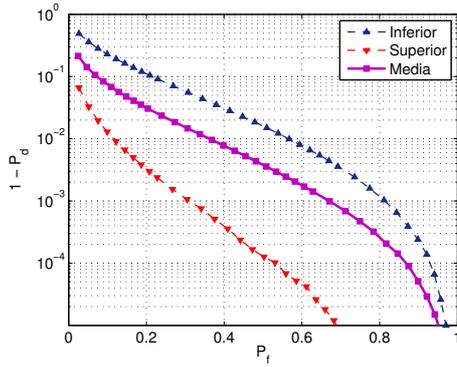


Figura 4.11: Rede com dupla topologia simulada e as SNR (em dB) dos nós.

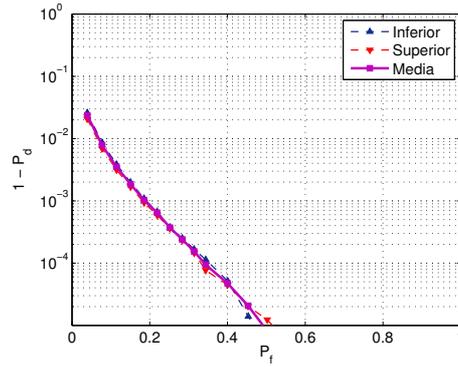
única topologia, para $|\mathcal{V}_{D,9}| = 9$, com dupla topologia; no caso do Nó 4, esse número aumenta de $|\mathcal{V}_{U,4}| = 5$ para $|\mathcal{V}_{D,4}| = 9$. Isso oferece à rede dois benefícios adicionais: maior diversidade de informação disponível em cada rádio para tomar sua decisão – que é o objetivo final do sensoriamento cooperativo – e maior uniformidade de desempenho entre os rádios pela participação de um maior percentual do total deles nas decisões de todos. O segundo é ainda corroborado pelo fato de que o algoritmo gerador de topologias proposto forma vizinhanças com a mesma cardinalidade, fixando o percentual de participação (neste caso, 9 de 12 nós, 75%).

Note que a dupla topologia garante essas vantagens sem aumentar o número de conexões por nó de uma topologia para a outra, o que também incorreria em um *overhead* de cooperação maior. Por outro lado, variar o tamanho das vizinhanças entre as topologias, assim como distribuir adequadamente os nós entre as vizinhanças, são recursos de que a rede passa a dispor no sentido de maximizar o percentual de participação em cada rádio. Em alguns casos, inclusive, é possível montar topologias que ofereçam participação total sem redundância. Considere, por exemplo, as mostradas na Figura 4.11: a partir da topologia primária da Figura 4.11(a), gerada ajustando-se a cardinalidade das vizinhanças em $|\mathcal{V}_{k,1}| = 3$, pode-se obter uma topologia complementar como a da Figura 4.11(b), de cardinalidade $|\mathcal{V}_{k,2}| = 4$. Com essas novas configurações de rede, o número de nós participantes das decisões consensuais aumenta para $|\mathcal{V}_{D,k}| = 12$, levando a 100% de participação em cada nó.

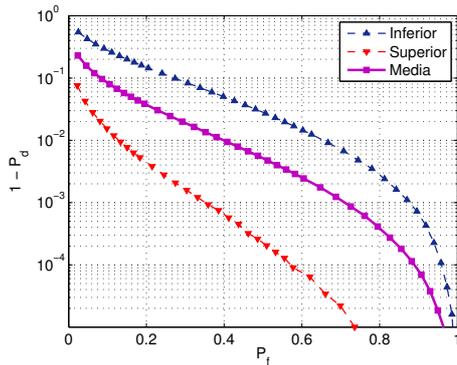
Para entender o que isso acarreta na detecção, são apresentados, na Figura 4.12, os resultados obtidos pela rede secundária das seções anteriores (incluindo as SNR individuais dos nós) após realizar cooperação em dois passos com as topologias primária e complementar da Figura 4.11. São plotadas as curvas C-ROC relativas aos desempenhos de detecção inferior, superior e médio observados entre os nós da rede, para cada estratégia de cooperação (com única e dupla topologia) e cenário



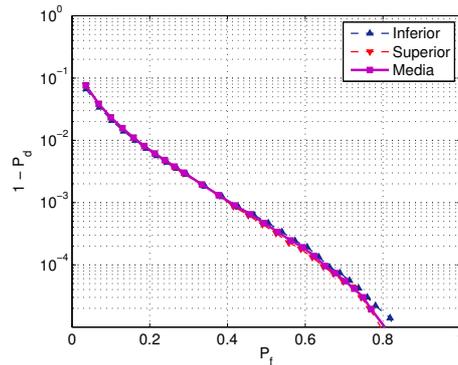
(a) Única topologia, descorrelacionado



(b) Dupla topologia, descorrelacionado



(c) Única topologia, correlacionado



(d) Dupla topologia, correlacionado

Figura 4.12: Variação de desempenho entre os nós usando única e dupla topologia.

de sombreamento (descorrelacionado e correlacionado) simulados. Note que a discrepância de desempenho usando única topologia continua, conforme já ocorrera anteriormente. Por outro lado, verifica-se, em ambos os cenários, não somente como usar dupla topologia melhora o desempenho geral da rede, mas também como topologias como as da Figura 4.11 proporcionam uniformidade de desempenho entre os nós, cujas curvas C-ROC passam a praticamente coincidir.

Garantir a participação de toda a rede em cada decisão consensual nem sempre é possível, uma vez que obter configurações como as da Figura 4.11 está condicionado a alguns fatores: número de rádios disponíveis para cooperação, quantidade de candidatos primários e complementares em cada nó, eventuais restrições impostas à rede quanto ao número máximo de conexões, dentre outros. Ainda assim, como sugerem os resultados da Figura 4.12, a cooperação com dupla topologia oferece mais possibilidades, no âmbito da seleção de usuário, em busca da redução das variações de detecção ao longo da rede secundária.

Capítulo 5

Conclusão

Os principais desafios da pesquisa em rádio cognitivo envolvem, direta ou indiretamente, o elemento central que é a identificação das oportunidades, isto é, das frequências livres para transmissão. Classificar corretamente os canais é pressuposto para viabilizar a ideia de exploração dinâmica do espectro e, nesse processo, cresce o interesse pelas redes cooperativas, superiores às redes com detecção individual. Ao mesmo tempo, definir a estratégia de cooperação mais adequada entre os rádios consiste, essencialmente, em avaliar duas questões: qual ganho em termos de detecção ela oferece a eles e qual custo (*overhead*) está associado à sua implementação.

Com a finalidade de propor um novo modelo de cooperação, este trabalho dirigiu seus estudos a três campos particulares em rádio cognitivo: sensoriamento, seleção de usuário e cooperação. O sensoriamento, campo fundamental tratado no Capítulo 2, diz respeito à observação do espectro para detecção de oportunidades. A escolha da técnica de sensoriamento a ser empregada pelos rádios influencia na maneira como eles irão cooperar entre si. Por sua vez, a seleção de usuário compreende os critérios relativos à escolha dos usuários da rede aptos a trocarem informações. Garantir a melhor seleção envolve compreender como diferentes perfis de usuário – alguns dos quais mencionados no Capítulo 3 (defeituosos, distantes, sujeitos a sombreamento etc.) – afetam a qualidade da detecção. Já aspectos ligados à cooperação propriamente dita (principais estratégias, técnicas de combinação etc.) também foram assunto do Capítulo 3. Entender como o tema vem sendo tratado na literatura é importante para identificar limitações entre os modelos já propostos.

O resultado da pesquisa é a rede distribuída descrita no Capítulo 4 [51–53]. A cooperação distribuída em dois passos constitui uma alternativa às estratégias baseadas em estimação de parâmetros, com alguns benefícios: menor volume de interação entre os rádios, flexibilidade de implementação com outras técnicas de combinação *soft* e *hard* existentes, simplicidade e bom desempenho. Sua variação com dupla topologia incrementa o ganho de cooperação pela eliminação de redundâncias e reduz as disparidades de detecção entre os nós, além de ser implementável por um

algoritmo para geração distribuída de topologias compatível com diversos critérios de seleção de usuário.

Por fim, o combinador linear adaptativo proposto torna mais simples a tarefa do rádio durante o passo *soft* de cooperação. Ele reúne a adaptabilidade a ambientes dinâmicos dos filtros adaptativos com a capacidade de favorecer as melhores e mais descorrelacionadas contribuições vizinhas do combinador linear ótimo, permitindo oferecer desempenho comparável a este. Quando empregado em conjunto com o algoritmo SU-LMS, o combinador proposto é ainda capaz de promover atualização seletiva dos coeficientes por meio de uma estratégia de seleção baseada na filtragem *set-membership*. Uma vez reduzindo seu processamento local, o rádio cognitivo gasta menos recursos computacionais e energia durante a cooperação, característica desejável principalmente no contexto das redes distribuídas.

Referências Bibliográficas

- [1] SPTF. *ET Docket no. 02-135*. Relatório técnico, FCC, nov. 2002.
- [2] NPRM. *ET Docket no. 03-322*. Relatório técnico, FCC, dez. 2003.
- [3] MITOLA, J. “Cognitive radio for flexible mobile multimedia communications”. In: *IEEE International Workshop on Mobile Multimedia Communications*, pp. 3–10, nov. 1999.
- [4] MITOLA, J. *Cognitive radio: An integrated agent architecture for software defined radio*. Tese de Doutorado, Royal Institute of Technology, Estocolmo, Suécia, maio 2000.
- [5] TIAN, Z. “Compressed wideband sensing in cooperative cognitive radio networks”. In: *IEEE Global Telecommunications Conference*, nov. 2008.
- [6] LI, Z., YU, F. R., HUANG, M. “A distributed consensus-based cooperative spectrum-sensing scheme in cognitive radios”, *IEEE Transactions on Vehicular Technology*, v. 59, pp. 383–393, jan. 2010.
- [7] ZENG, F., LI, C., TIAN, Z. “Distributed compressive spectrum sensing in cooperative multihop cognitive networks”, *IEEE Journal of Selected Topics in Signal Processing*, v. 5, pp. 37–48, fev. 2011.
- [8] QUAN, Z., CUI, S., SAYED, A. “Optimal linear cooperation for spectrum sensing in cognitive radio networks”, *IEEE Journal of Selected Topics in Signal Processing*, v. 2, pp. 28–40, fev. 2008.
- [9] QUAN, Z., MA, W.-K., CUI, S., et al. “Optimal linear fusion for distributed spectrum sensing via semidefinite programming”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, maio 2009.
- [10] TARICCO, G. “Optimization of linear cooperative spectrum sensing for cognitive radio networks”, *IEEE Journal of Selected Topics in Signal Processing*, v. 5, pp. 77–86, fev. 2011.

- [11] HAYKIN, S. “Cognitive radio: Brain empowered wireless communications”, *IEEE Journal on Selected Areas in Communications*, v. 23, pp. 201–219, fev. 2005.
- [12] MITOLA, J. “Software radios: Survey, critical evaluation and future directions”, *IEEE Aerospace and Electronics Systems Magazine*, v. 8, pp. 25–36, abr. 1993.
- [13] EGAN, J. P. *Signal Detection Theory and ROC Analysis*. Academic Press, 1975.
- [14] GHASEMI, A., SOUSA, E. S. “Opportunistic spectrum access in fading channels through collaborative sensing”, *Journal of Communications*, v. 2, pp. 71–82, mar. 2007.
- [15] AKYILDIZ, I. F., LO, B. F., BALAKRISHNAN, R. “Cooperative spectrum sensing in cognitive radio networks: A survey”, *Physical Communication*, v. 4, pp. 40–62, mar. 2011.
- [16] TIAN, Z., GIANNAKIS, G. B. “A wavelet approach to wideband spectrum sensing for cognitive radios”. In: *International Conference on Cognitive Radio Oriented Wireless Networks and Communications*, jun. 2006.
- [17] TIAN, Z., GIANNAKIS, G. B. “Compressed sensing for wideband cognitive radios”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, abr. 2007.
- [18] QUAN, Z., CUI, S., POOR, H. V., et al. “Collaborative wideband sensing for cognitive radios”, *IEEE Signal Processing Magazine*, v. 25, pp. 60–73, nov. 2008.
- [19] WANG, B., LIU, K. J. R. “Advances in cognitive radio networks: A survey”, *IEEE Journal of Selected Topics in Signal Processing*, v. 5, pp. 5–23, fev. 2011.
- [20] MA, J., LI, G. Y., JUANG, B. H. “Signal processing in cognitive radio”, *Proceedings of the IEEE*, v. 97, pp. 805–823, maio 2009.
- [21] URKOWITZ, H. “Energy detection of unknown deterministic signals”, *Proceedings of the IEEE*, v. 55, pp. 523–531, abr. 1967.
- [22] DIGHAM, F. F., ALOUINI, M.-S., SIMON, M. K. “On the energy detection of unknown signals over fading channels”. In: *IEEE International Conference on Communications*, maio 2003.

- [23] GENDENKO, B. V., KOLMOGOROV, A. N. *Limit Distributions for Sums of Independent Random Variables*. Addison-Wesley, 1954.
- [24] TANDRA, R., SAHAI, A. “SNR walls for signal detection”, *IEEE Journal of Selected Topics in Signal Processing*, v. 2, pp. 4–17, fev. 2008.
- [25] RICHARDS, M. A. *Fundamentals of Radar Signal Processing*. McGraw-Hill, 2005.
- [26] TREES, H. V. *Detection, Estimation, and Modulation Theory, Part I*. Wiley, 1968.
- [27] ALEMSEGED, Y. D., SUN, C., TRAN, H. N., et al. “Distributed spectrum sensing with two-stage detection for cognitive radio”. In: *IEEE Vehicular Technology Conference Fall*, set. 2009.
- [28] PEH, E., LIANG, Y.-C. “Optimization for cooperative sensing in cognitive radio networks”. In: *IEEE Wireless Communications and Networking Conference*, mar. 2007.
- [29] LIN, W., ZHANG, Q. “A design of energy detector in cognitive radio under noise uncertainty”. In: *IEEE International Conference on Communication Systems*, nov. 2008.
- [30] SUN, H. *Collaborative spectrum sensing in cognitive radio networks*. Tese de Doutorado, The University of Edinburgh, Edimburgo, Escócia, jan. 2011.
- [31] WERNER, S., HUANG, Y.-F., DE CAMPOS, M. L. R., et al. “Distributed parameter estimation with selective cooperation”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, maio 2009.
- [32] GHASEMI, A., SOUSA, E. S. “Collaborative spectrum sensing for opportunistic access in fading environments”. In: *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, nov. 2005.
- [33] MISHRA, S. M., SAHAI, A., BRODERSEN, R. W. “Cooperative sensing among cognitive radios”. In: *IEEE International Conference on Communications*, jun. 2006.
- [34] LIU, Q., GAO, J., GUO, Y., et al. “Robustness improvement against noise uncertainty by cooperative spectrum sensing”. In: *International Conference on Wireless Communications and Signal Processing*, out. 2010.

- [35] KHAN, Z., LEHTOMÄKI, J., UMEBAYASHI, K., et al. “On the selection of the best detection performance sensors for cognitive radio networks”, *IEEE Signal Processing Letters*, v. 17, pp. 359–362, abr. 2010.
- [36] CHEN, R., PARK, J.-M., BIAN, K. “Robust distributed spectrum sensing in cognitive radio networks”. In: *IEEE Conference on Computer Communications*, abr. 2008.
- [37] KALIGINEEDI, P., KHABBAZIAN, M., BHARGAVA, V. K. “Malicious user detection in a cognitive radio cooperative sensing system”, *IEEE Transactions on Wireless Communications*, v. 9, pp. 2488–2497, ago. 2010.
- [38] MALADY, A. C., DA SILVA, C. R. C. M. “Clustering methods for distributed spectrum sensing in cognitive radio systems”. In: *IEEE Military Communications Conference*, nov. 2008.
- [39] GHASEMI, A., SOUSA, E. S. “Asymptotic performance of collaborative spectrum sensing under correlated log-normal shadowing”, *IEEE Communications Letters*, v. 11, pp. 34–36, jan. 2007.
- [40] SELEN, Y., TULLBERG, H., KRONANDER, J. “Sensor selection for cooperative spectrum sensing”. In: *IEEE Symposium on New Frontiers in Dynamic Spectrum Access Networks*, out. 2008.
- [41] CACCIAPUOTI, A. S., AKYILDIZ, I. F., PAURA, L. “Correlation-aware user selection for cooperative spectrum sensing in cognitive radio ad hoc networks”, *IEEE Journal on Selected Areas in Communications*, v. 30, pp. 297–306, fev. 2012.
- [42] VARSHNEY, P. K. *Distributed Detection and Data Fusion*. Springer, 1997.
- [43] ZHANG, W., MALLIK, R. K., LETAIEF, K. B. “Cooperative spectrum sensing optimization in cognitive radio networks”. In: *IEEE International Conference on Communications*, maio 2008.
- [44] VISOTSKY, E., KUFFNER, S., PETERSON, R. “On collaborative detection of TV transmissions in support of dynamic spectrum sharing”. In: *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, nov. 2005.
- [45] MA, J., LI, Y. “Soft combination and detection for cooperative spectrum sensing in cognitive radio networks”. In: *IEEE Global Telecommunications Conference*, nov. 2007.

- [46] YARKAN, S., TOREYIN, B. U., QARAQE, K. A., et al. “An experimental validation of an online adaptive cooperation scheme for spectrum sensing”. In: *International Conference on Telecommunications*, maio 2011.
- [47] OLFATI-SABER, R., FAX, J. A., MURRAY, R. M. “Consensus and cooperation in networked multi-agent systems”, *Proceedings of the IEEE*, v. 95, pp. 215–233, jan. 2007.
- [48] CHEN, Y. “Analytical performance of collaborative spectrum sensing using censored energy detection”, *IEEE Transactions on Wireless Communications*, v. 9, pp. 3856–3865, dez. 2010.
- [49] CHEN, Y., ZHAO, Q., SWAMI, A. “Distributed spectrum sensing and access in cognitive radio networks with energy constraint”, *IEEE Transactions on Signal Processing*, v. 57, pp. 783–797, fev. 2009.
- [50] MALEKI, S., PANDHARIPANDE, A., LEUS, G. “Energy-efficient distributed spectrum sensing for cognitive sensor networks”, *IEEE Sensors Journal*, v. 11, pp. 565–573, mar. 2011.
- [51] RIBEIRO JR., F. C., DE CAMPOS, M. L. R., WERNER, S. “Distributed cooperative spectrum sensing with adaptive combining”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, mar. 2012.
- [52] RIBEIRO JR., F. C., DE CAMPOS, M. L. R., WERNER, S. “Distributed cooperative spectrum sensing with selective updating”. In: *European Signal Processing Conference*, ago. 2012.
- [53] RIBEIRO JR., F. C., DE CAMPOS, M. L. R., WERNER, S. “Distributed cooperative spectrum sensing with double-topology”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, maio 2013.
- [54] CATTIVELLI, F. S., SAYED, A. H. “Distributed detection over adaptive networks using diffusion adaptation”, *IEEE Transactions on Signal Processing*, v. 59, pp. 1917–1932, maio 2011.
- [55] LOPES, C. G., SAYED, A. “Diffusion least-mean squares over adaptive networks”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, abr. 2007.
- [56] DINIZ, P. S. R. *Adaptive Filtering: Algorithms and Practical Implementation*. Springer, 2008.

- [57] KAM, M., ZHU, Q., GRAY, W. S. “Optimal data fusion of correlated local decisions in multiple sensor detection systems”, *IEEE Transactions on Aerospace and Electronic Systems*, v. 28, pp. 916–920, jul. 1992.
- [58] GOLLAMUDI, S., NAGARAJ, S., KAPOOR, S., et al. “Set-membership filtering and a set-membership normalized LMS algorithm with an adaptive step size”, *IEEE Signal Processing Letters*, v. 5, pp. 111–114, maio 1998.
- [59] GUO, L., HUANG, Y.-F. “Set-membership adaptive filtering with parameter-dependent error bound tuning”. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*, mar. 2005.
- [60] ZHAO, Q., TONG, L., SWAMI, A., et al. “Decentralized cognitive MAC for opportunistic spectrum access in ad hoc networks: A POMDP framework”, *IEEE Journal on Selected Areas in Communications*, v. 25, pp. 589–600, abr. 2007.
- [61] GONG, S., LIU, W., YUAN, W., et al. “Threshold-learning in local spectrum sensing of cognitive radio”. In: *IEEE Vehicular Technology Conference*, abr. 2009.
- [62] UNNIKRISHNAN, J., VEERAVALLI, V. V. “Cooperative sensing for primary detection in cognitive radio”, *IEEE Journal of Selected Topics in Signal Processing*, v. 2, pp. 18–27, fev. 2008.